Tue. Jun 5, 2018

Room B

Oral presentation | General Session | [General Session] 5. Web Intelligence

[1B3] [General Session] 5. Web Intelligence

座長:大塚 淳史（NTT）

5:20 PM - 6:40 PM Room B (4F Moon Light)

[1B3-01] Burst Phenomenon Analysis in Social Tagging System using Hawkes Process

○Shota Ejima[1], Taichi Kosugi[1], Mizuki Oka[1], Masanori Miyake[2], Takashi Ikegami[2] （1. Graduate School of Systems and Information Engineering, University of Tsukuba, 2. Graduate School of Arts and Science, The University of Tokyo）

5:20 PM - 5:40 PM

[1B3-02] Analyzing the influence of human personality on SNS community formation

○Gaia Suzuki[1], Masanao Ochi[1], Takeshi Sakaki[1], Ichiro Sakata[1] （1. School of Engineering, The University of Tokyo）

5:40 PM - 6:00 PM

[1B3-03] An Evaluation System for Credibility of Fake News using Dynamic Relational Networks

Sanae Kuraya[1], ○Yoshiteru Ishida[1] （1. Toyohashi University of Technology）

6:00 PM - 6:20 PM

[1B3-04] A Consideration of Social Relationships and Social Support in a Virtual Society

○Masanori Takano[1], Kan Mizuno[1] （1. CyberAgent, Inc.）

6:20 PM - 6:40 PM

Oral presentation | Organized Session | [Organized Session] OS-11

[1B1-OS-11a] [Organized Session] OS-11

1:20 PM - 3:00 PM Room B (4F Moon Light)

[1B1-OS-11a-01] Proposal on incentive design for activation of shopping street using city walk application

○Yuya Ieiri[1], Yuu Nakajima[2], Reiko Hishiyama[1] （1. Waseda University, 2. Toho University）

1:20 PM - 1:40 PM

[1B1-OS-11a-02] Large Scale Terrain Modeling and Automatic Aerial Shooting with Multi-drone System

○Keiji Suzuki[1], Sho Yamauchi[2], Kouki Ogata[1], Toshio Kawashima[1] （1. Future University Hakodate, 2. KITAMI Institute of Technology）

1:40 PM - 2:00 PM

[1B1-OS-11a-03] Towards a New Method for the Investigation of Tourists' Needs

○Shuang Song[1], Hidenori Kawamura[1], Junichi Uchida[2], Hajime Saito[3] （1. Hokkaido University, 2. Otaru University of Commerce, 3. Hokkaido Information University）

2:00 PM - 2:20 PM

[1B1-OS-11a-04] Route Traffic Flow Estimation by Observing Staying People

○Hitoshi Shimizu[1], Tatsushi Matsubayashi[2], Yusuke Tanaka[2], Tomoharu Iwata[1], Hiroshi Sawada[1,2] （1. NTT Communication Science Laboratories, 2. NTT Service Evolution Laboratories）

2:20 PM - 2:40 PM

[1B1-OS-11a-05] Identifying Individual Chimpanzee with Convolution Neural Networks

○Yuuichiro Ikeda[1], Hiroyuki Iizuka[1], Masahito Yamamoto[1] （1. Graduate School of Information Science and Technology, Hokkaido University）

2:40 PM - 3:00 PM

Oral presentation | Organized Session | [Organized Session] OS-11

[1B2-OS-11b] [Organized Session] OS-11

3:20 PM - 4:40 PM Room B (4F Moon Light)

[1B2-OS-11b-01] Development of Automatic Haiku Generator Using LSTM

○Koki Yoneda[1], Soichiro Yokoyama[2], Tomohisa Yamashita[2], Hidenori Kawamura[2] （1. School of Engineering Hokkaido University, 2. Graduate School of Information Science and Technology, Hokkaido University）

3:20 PM - 3:40 PM

[1B2-OS-11b-02] Verification of Fish Species Estimation Model Based on Echo Sounder Image

○Yudai Hirama[1], Soichiro Yokoyama[1], Tomohisa Yamashita[1], Hidenori Kawamura[1], Keiji Suzuki[2], Masaaki Wada[2] （1. Hokkaido University, 2. Future University Hakodate）

3:40 PM - 4:00 PM

©The Japanese Society for Artificial Intelligence

[1B2-OS-11b-03] Efficiency Evaluation of Smart Access Vehicle Service Using Dispatched Taxi Data in Nagoya City

○Junichi Ochiai[1], Ryo Kanamori[2], Keiji Hirata[3], Itsuki Noda[4] （1. Mirai Share Co., Ltd., 2. Nagoya University, 3. Future University Hakodate, 4. AIST）

4:00 PM - 4:20 PM

[1B2-OS-11b-04] A Development of shery prediction AI platform to optimize distribution

○Hiroaki Taka[1], Taro Osabe[2], Satoru Hanzawa[2], Hiroyuki Shioya[3], Junichi Kishigami[3], Masaaki Wada[1] （1. Future University Hakodate, 2. Hitachi, Ltd., 3. Muroran Institute of Technology）

4:20 PM - 4:40 PM

Room C

Oral presentation | General Session | [General Session] 5. Web Intelligence

[1C1] [General Session] 5. Web Intelligence

座長:黄 宏軒（理化学研究所革新知能統合研究センター）

1:20 PM - 2:40 PM Room C (4F Orchid)

[1C1-01] Assigning BSH Headings to People on the Web

○Masayuki Shimokura[1], Harumi Murakami[1] （1. Osaka City University）

1:20 PM - 1:40 PM

[1C1-02] Developing an Interface for Beginning Application Sharing Smartly in a Group of Cooperative Work

○Satoru Iwata[1], Tadachika Ozono[1], Toramatsu Shintani[1] （1. Department of Computer Science, Graduate School of Engineering, Nagoya Institute of Technology）

1:40 PM - 2:00 PM

[1C1-03] Recommender System using Image Shape Feature for CNN

○Yufeng Duan[1], Ryosuke Saga[1] （1. Osaka Prefecture University）

2:00 PM - 2:20 PM

[1C1-04] Combining semi-supervised learning and singular value decomposition to Cold-Start problem

○Takumi Uchida[1], Kei Nakagawa[1,2], Kenichi Yoshida[1] （1. University of Tukuba, 2. Nomura Asset Management Co., Ltd）

2:20 PM - 2:40 PM

Oral presentation | Organized Session | [Organized Session] OS-8

[1C2-OS-8a] [Organized Session] OS-8

3:20 PM - 4:40 PM Room C (4F Orchid)

[1C2-OS-8a-01] Proposal of Context Search Engine for Integrated Use of Open and Private Data

○Taichi Okahisa[1], Yasufumi Takama[1] （1. Tokyo Metropolitan University）

3:20 PM - 3:40 PM

[1C2-OS-8a-02] Analysis of issues for creating co-creative value through marketing data among companies.

○yutaka oguchi[1], tsuchida naohiro[1] （1. NIPPON RESEARCH CENTER,LTD）

3:40 PM - 4:00 PM

[1C2-OS-8a-03] An Experiment of Causal Knowledge Extraction from Reuter News

○Hiroki Sakaji[1], Jason Bennett[2], Yusuke Miyao[3], Kiyoshi Izumi[1] （1. The University of Tokyo, 2. Sumitomo Mitsui Asset Management Company, Limited, 3. National Institute of Informatics）

4:00 PM - 4:20 PM

[1C2-OS-8a-04] Data Landscape in the Era of Data 3.0

○Teruaki Hayashi[1], Yukio Ohsawa[1] （1. The University of Tokyo）

4:20 PM - 4:40 PM

Oral presentation | Organized Session | [Organized Session] OS-8

[1C3-OS-8b] [Organized Session] OS-8

5:20 PM - 6:20 PM Room C (4F Orchid)

[1C3-OS-8b-01] An Approach of Defining, Generating and Utilizing Metadata for Sensing Data Trading Market

○Toshihiko Oda[1], Hiroshi Imai[1], Takeshi Naito[1], Hajime Takebayashi[1] （1. OMRON Corporation）

5:20 PM - 5:40 PM

[1C3-OS-8b-02] Detecting Team Behaviors of Pedestrians in Redevelopment Areas on Acceleration Similarity

○Yukio Ohsawa[1], Sae Kondo[1], Teruaki Hayashi[1], Atsushi Sugawa[2], Takahisa Yoshida[3] （1. The University of Tokyo, 2. Crosshack, Inc., 3. Arnest one Corp.）

©The Japanese Society for Artificial Intelligence

5:40 PM - 6:00 PM

[1C3-OS-8b-03] Blockchain x Data Jackets accelerates data exchange and utilization

○Eiji Ikeda[1], Hiromichi Sasaki[1] （1. FUJITSU LIMITED）

6:00 PM - 6:20 PM

Room D

Oral presentation | General Session | [General Session] 13. AI Application

[1D1] [General Session] 13. AI Application

座長:肥田 剛典（東京大学）

1:20 PM - 3:00 PM Room D (4F Cattleya)

[1D1-01] Comparison between Tsunami Height Prediction Methods Using Ocean-Bottom Pressure Values

○Kenjiro Kashiwabara[1], Masashi Yoshikawa[1], Yasuhiko Igarashi[1,2], Toshitaka Baba[3], Takane Hori[4], Masato Okada[1] （1. The University of Tokyo, 2. Japan Science and Technology Agency PRESTO, 3. The University of Tokushima, 4. Japan Agency for Marine-Earth Science and Technology）

1:20 PM - 1:40 PM

[1D1-02] Landslide Detection Using CNN with SAR Images before/after the Disaster and DEM

○Daisuke Ueda[1], Shingo Mabu[1], Takashi Kuremoto[1] （1. Yamaguchi University ）

1:40 PM - 2:00 PM

[1D1-03] Applicability of the deep learning flood forecast model against the flood exceeding the training events

○Masayuki HITOKOTO[1], Masaaki SAKURABA[1] （1. NIPPON KOEI CO., LTD）

2:00 PM - 2:20 PM

[1D1-04] A Route Search System Considering Urgency and Efficient Coverage under the Condition of Uncertain Information

Nakamura Yuta[1], ○Masaki Matsubara[1], Nobutaka Suzuki[1], Munenari Inoguchi[2], Atsuyuki Morishima[1] （1. University of Tsukuba, 2. university of Shizuoka）

2:20 PM - 2:40 PM

[1D1-05] Mobile Network Failure Detection and Forecasting with Multiple User Bahavior

○Motoyuki OKI[1], Koh Takeuchi[2], Yukio Uematsu[1], Naonori Ueda[2] （1. NTT Communications Corporation, 2. NTT Communication Science Laboratories）

2:40 PM - 3:00 PM

Oral presentation | Organized Session | [Organized Session] OS-28

[1D2-OS-28a] [Organized Session] OS-28

3:20 PM - 5:00 PM Room D (4F Cattleya)

[1D2-OS-28a-a] OS invited talk

○Naoaki Okazaki[1] （1. Tokyo Institute of Technology）

3:20 PM - 4:00 PM

[1D2-OS-28a-01] A policy decision making with multiple stepwise citizen participation program: A case study of revising the basic environmental plan Sapporo

○Susumu Ohnuma[1], Miki Yokoyama[1] （1. Hokkaido University）

4:00 PM - 4:20 PM

[1D2-OS-28a-02] Verification of consensus building support system on large-scale social experiment

○Tomohiro Nishida[1], Takanori Ito[1], Akihisa Sengoku[1], Takayuki Ito[1] （1. Nagoya Institute of Technology）

4:20 PM - 4:40 PM

[1D2-OS-28a-03] A Consideration of Modeling Understanding of Discussion Context with Content and Process for Developing Autonomous Facilitator Agents

○Shun Shiramatsu[1], Yuto Ikeda[1], Ko Kitagawa[1], Hiroaki Koura[1], Takayuki Ito[1] （1. Nagoya Institute of Technology）

4:40 PM - 5:00 PM

Oral presentation | Organized Session | [Organized Session] OS-28

[1D3-OS-28b] [Organized Session] OS-28

5:20 PM - 7:00 PM Room D (4F Cattleya)

[1D3-OS-28b-01] A Topic Change Judgment Method based on Distributed Representation for Facilitator Support

○Kai Yoshino[1], Takayuki Ito[1] （1. Nagoya Institute of Technology）

5:20 PM - 5:40 PM

[1D3-OS-28b-02] Strategyproof and Fair Matching Mechanism for Union of Symmetric M-convex Constraints

Yuzhe Zhang[1], ○Kentaro Yahiro[1], Nathanael

©The Japanese Society for Artificial Intelligence

Barrot[2], Makoto Yokoo[1] （1. Graduate School of Information Science and Electrical Engineering, Kyushu University, 2. RIKEN, Center for Advanced Intelligence Project AIP）

5:40 PM - 6:00 PM

[1D3-OS-28b-03] Analysis of Equilibria and Reverse Phenomenon in Two-player All-pay Auction with Asymmetric Information

Tooru Akagi[1], ○Taiki Todo[1], Makoto Yokoo[1] （1. Kyushu University）

6:00 PM - 6:20 PM

[1D3-OS-28b-04] Modeling Multiple Tasks by the Response Threshold Model in Evacuation Simulation

○Akira Tsurushima[1] （1. SECOM CO., LTD.）

6:20 PM - 6:40 PM

[1D3-OS-28b-05] A Cloud-based Argumentation Process Repository using LOD for Consensus Building Knowledge Base -- A Preliminary Report

○Naoki Fukuta[1] （1. Shizuoka University）

6:40 PM - 7:00 PM

Room E

Oral presentation | General Session | [General Session] 1. Basis / Theory

[1E1] [General Session] 1. Basis / Theory

座長:新田 克己（産業技術総合研究所）

1:20 PM - 3:00 PM Room E (4F Queen)

[1E1-01] A Cunning Ant System with Multi-Pheromones for Constraint Satisfaction Problems

○Takuya Masukane[1], Kazunori Mizuno[1] （1. Takushoku University）

1:20 PM - 1:40 PM

[1E1-02] Algorithm of Traveling Salesman Problem using Particle Swarm Optimization

○Yamada Yuki[1], Anada hajime[1] （1. Tokyo City Univercity）

1:40 PM - 2:00 PM

[1E1-03] Toward Optimal Parameters for ACO in Data Clustering

○Takayuki Nakayama[1], Kazunori Mizuno[1] （1. Takushoku University）

2:00 PM - 2:20 PM

[1E1-04] Conversion from Logic Programming Language PROLEG to Bipolar Argumentation Framework

○Tatsuki Kawasaki[1], Kazuko Takahashi[1] （1. Kwansei Gakuin University）

2:20 PM - 2:40 PM

[1E1-05] A Proposal of Qualitative Spatial Representation Focused on Change of Shapes

○Momo Tosue[1], Kazuko Takahashi[1] （1. Kwansei Gakuin University ）

2:40 PM - 3:00 PM

Oral presentation | General Session | [General Session] 6. Web Mining

[1E2] [General Session] 6. Web Mining

座長:池田 和史（KDDI綜合研究所）

3:20 PM - 5:00 PM Room E (4F Queen)

[1E2-01] Deep Reinforcement Learning for Recommendation System

○Takashi Kawashima[1], Syunyo Kawamoto[1], Daisuke Tsumita[1], Syo Simoyama[1], Isshu Munemasa[1], Yuta Tomomatsu[1], Kunioki Hayashi[2], Tomohiro Takagi[1] （1. Meiji University, 2. DesignOne Japan, Inc）

3:20 PM - 3:40 PM

[1E2-02] Proposal of Route Recommending Method based on Formulation using Edge Vector

○Hiroki Shibata[1], Yasufumi Takama[1] （1. Tokyo Metropolitan University）

3:40 PM - 4:00 PM

[1E2-03] Churn Prediction using Deep Learning

○Kunihiro Miyazaki[1], Natsuki Murayama[2], Yuki Yamamoto[1], Fumiaki Ushiyama[3], Shohei Ohsawa[1], Yutaka Matsuo[1] （1. School of Engineering, The University of Tokyo, 2. Dept. of Arts and Science, The University of Tokyo, 3. WealthNavi Inc.）

4:00 PM - 4:20 PM

[1E2-04] Targets Recommendation Considering After M\&A Performance by Content based Neural Collaborative Filtering

○Masanao Ochi[1], Yasuko Yamano[1], Kimitaka Asatani[1], Akira Kitauchi[2], Tomoyuki Ota[2] （1. The University of Tokyo, 2. UZABASE Inc.）

4:20 PM - 4:40 PM

[1E2-05] Mathematical model for search action on the Internet

○Akira Ishii[1], Noboru Ashida[1], Yasuko Kawahata[2] （1. Tottori university, 2. Gunma University）

4:40 PM - 5:00 PM

©The Japanese Society for Artificial Intelligence

Oral presentation | General Session | [General Session] 6. Web Mining

[1E3] [General Session] 6. Web Mining

座長:伊藤 雅弘（株式会社東芝）

5:20 PM - 7:00 PM Room E (4F Queen)

[1E3-02] Extraction of Product and Shop Names of Souvenir from Blog Articles

○Ryuya Ikeda[1], Kazuaki Ando[1] （1. Kagawa University）

5:40 PM - 6:00 PM

[1E3-03] What Can Be Seen from the Prefectural Assembly Minutes?

○Yuzu Uchida[1], Keiichi Takamaru[2], Hokuto Ototake[3], Yasutomo Kimura[4] （1. Hokkai-Gakuen University, 2. Utsunomiya Kyowa University, 3. Fukuoka University, 4. Otaru University of Commerce / RIKEN AIP）

6:00 PM - 6:20 PM

[1E3-04] An Interface of the Collection of Know-How Sites and the Topics aggregated by a Topic Model

○Shuto Kawabata[1], Wenbin Niu[1], Takehito Utsuro[1], Yasuhide Kawada[2] （1. University of Tsukuba, 2. Logworks Co., Ltd.）

6:20 PM - 6:40 PM

[1E3-05] Analysis of Political Party Accounts' Followers in Japan Electoin 2017

○Fujio Toriumi[1], Matsuo Yoshida[2] （1. The University of Tokyo, 2. Toyohashi University of Technology）

6:40 PM - 7:00 PM

Room F

Oral presentation | General Session | [General Session] 4. Knowledge Utilization and Sharing

[1F1] [General Session] 4. Knowledge Utilization and Sharing

座長:福田 直樹（静岡大学）

1:20 PM - 3:00 PM Room F (4F Garreria)

[1F1-01] The First Knowledge Graph Completion Challenge 2018

○Takahiro Kawamura[1], Shusaku Egami[2], Shinichi Nagano[3], Ikki Ohmukai[4], Takeshi Morita[5], Yasunori Yamamoto[6], Koji Kozaki[7] （1. Japan Science and Technology Agency, 2. University of Electro-Communications, 3. Toshiba Corp., 4. National Institute of Informatics, 5. Keio University, 6. Database Center for Life Science, 7. Osaka University）

1:20 PM - 1:40 PM

[1F1-02] Faster Ontology Reasoning with Typed Propositionalization

○Maxime CLEMENT[1], Ryutaro ICHISE[1] （1. National Institute of Informatics）

1:40 PM - 2:00 PM

[1F1-03] Asynchronous Chat System for Dialogue Collection on Crowdsourcing

○Kazushi Ikeda[1], Keiichiro Hoashi[1] （1. KDDI Research, Inc.）

2:00 PM - 2:20 PM

[1F1-04] A data editing support tool for large-sized ontology data with context dependency

○Hiroshi Masuya[1], Kouji Kozaki[2], Riichiro Mizoguchi[3] （1. BRC, RIKEN, 2. ISIR, Osaka Univ., 3. Japan Adv. Inst. of Sci. and Tech. (JAIST)）

2:20 PM - 2:40 PM

[1F1-05] Normalize an academic impact indicator for evaluating interdisciplinary

○Kazuya Tanaka[1], Riku Arakawa[1], Yasuaki Kameoka[1], Junichiro Mori[1], Ichiro Sakata[1] （1. The University of Tokyo）

2:40 PM - 3:00 PM

Oral presentation | Organized Session | [Organized Session] OS-5

[1F2-OS-5a] [Organized Session] OS-5

3:20 PM - 5:00 PM Room F (4F Garreria)

[1F2-OS-5a-01] How Do Young People Face the Development of Artificial Intelligence?

○Motoki Ono[1], Hiroshi Nemoto[2], Kazuya Tanaka[2], Kan Suzuki[2] （1. Research Institute at Keio SFC, 2. The University of Tokyo）

3:20 PM - 3:40 PM

[1F2-OS-5a-02] Relationship between mind perception and responsibility in a collaborative task with an artifact

○Tomohito Miyake[1], Yuji Kawai[1], Jihoon Park[1], Jiro Shimaya[2], Hideyuki Takahashi[2], Minoru Asada[1] （1. Graduate School of Engineering, Osaka University, 2. Graduate School of Engineering Science, Osaka Univercity）

3:40 PM - 4:00 PM

[1F2-OS-5a-03] A study on legal personhood of AIs in tort law

○Ryota AKASAKA[1] （1. The National Institute of Advanced Industrial Science and Technology）

©The Japanese Society for Artificial Intelligence

4:00 PM - 4:20 PM

[1F2-OS-5a-04] Driving Self-Driving Cars by Spoken Language Instructions

○Hiroshi Tsukahara[1], Hirotaka Higaki[2], Namabu Oomae[2], Nana Ootawara[3], Akari Inago[3], Ichiro Kobayashi[3] (1. Denso IT Laboratory, Inc., 2. Graduate School of Media and Goverance, Keio University, 3. Ochanomizu University)

4:20 PM - 4:40 PM

[1F2-OS-5a-05] First Trials with Culture-Dependent Moral Commonsense Acquisition

○Rafal Rzepka[1], Da Li[1], Kenji Araki[1] (1. Hokkaido University)

4:40 PM - 5:00 PM

Oral presentation | Organized Session | [Organized Session] OS-5

[1F3-OS-5b] [Organized Session] OS-5

5:20 PM - 7:00 PM Room F (4F Garreria)

[1F3-OS-5b-01] Fundamental consideration on future society with speed tolerances

○Hiroshi Yamakawa[1,2] (1. Dwango Co. ltd., 2. The Whole Brain Architecture Initiative, non-profit organization)

5:20 PM - 5:40 PM

[1F3-OS-5b-02] Viewing Singularity from Various Perspectives

○Masahiko Osawa[1,2], Kazunori Saito[3], Yoichiro Miyake[4], Michita Imai[1] (1. Keio University, 2. Japan Society for the Promotion Science, Research Fellow (DC1), 3. Exponential Japan, 4. SQUARE ENIX CO., LTD.)

5:40 PM - 6:00 PM

[1F3-OS-5b-03] Scenarios and branch points to future machine intelligence

○Koichi Takahashi[1] (1. RIKEN)

6:00 PM - 6:20 PM

[1F3-OS-5b-a] OS invited talk

○Kazuhisa Todayama[1] (1. Nagoya University)

6:20 PM - 7:00 PM

Room G

Oral presentation | General Session | [General Session] 11. Robot / Real World

[1G3] [General Session] 11. Robot / Real World

座長:成田 雅彦（産業技術大学院大学）

5:20 PM - 7:00 PM Room G (5F Ruby Hall Hiten)

[1G3-01] Evaluation of mechanical effect for wire assist suit with force plates inside treadmill

○Hiroumi Murai[1], Nobutaka Tsujiuchi[1], Akihito Ito[1], Keisuke Kitano[1], Kenta Murakami[2], Seigo Okada[2], Tsuyoshi Inoue[2], Yui Endo[3], Yumeko Imamura[3], Jun Ozawa[3] (1. Doshisha University, 2. Panasonic Corporation, 3. National Institute of Advanced Industrial Science and Technology)

5:20 PM - 5:40 PM

[1G3-02] Mechanical effects of wire assist suit on human walking during load-carrying

○Seigo Okada[1], Kenta Murakami[1], Tsuyoshi Inoue[1], Yui Endo[2], Yumeko Imamura[2], Jun Ozawa[2] (1. Panasonic Corporation, 2. National Institute of Advanced Industrial Science and Technology)

5:40 PM - 6:00 PM

[1G3-03] Learning-based Selective Dual-arm Grasping for Warehouse Picking

○Shingo Kitagawa[1], Kentaro Wada[1], Kei Okada[1], Masayuki Inaba[1] (1. the University of Tokyo)

6:00 PM - 6:20 PM

[1G3-04] Integrated Model for Learning of Actions, Language and Planning

○Kazuki Miyazawa[1], Tatsuya Aoki[1], Takato Horii[1], Chie Hieida[1], Tomoaki Nakamura[1], Takayuki Nagai[1] (1. The Department of Mechanical Engineering and Intelligent Systems, University of Electro-Communications)

6:20 PM - 6:40 PM

[1G3-05] Learning Integration Concept of Objects and Motions Based on Segmentation and Classification of Time Series Multimodal Information

○Ryotaro Nunokawa[1], Kazuki Miyazawa[1], Tomoaki Nakamura[1], Takayuki Nagai[1], Masahide Kaneko[1] (1. The University of Electro-Communications)

6:40 PM - 7:00 PM

Oral presentation | NFC Session | [NFC Session] NFC-2 UEPD (Development of fundamental technology for understanding emotions of people with dementia and its applications to communication support)

[1G1-NFC-2a] [NFC Session] NFC-2 UEPD (Development of fundamental technology for understanding emotions of people with dementia

©The Japanese Society for Artificial Intelligence

and its applications to communication support)

座長:竹林 洋一（静岡大学）

1:20 PM - 3:00 PM Room G (5F Ruby Hall Hiten)

[1G1-NFC-2a-a] Aim of the session

Yoichi TAKEBAYASHI[1] （1: Shizuoka University / The Society of Citizen Informatics for Human Cognitive Disorder）

1:20 PM - 1:40 PM

[1G1-NFC-2a-b] (Panel discussion) The results of "Development of fundamental technology for understanding emotions of people with dementia and its applications to communication support"

Shogo Ishikawa[1], Hideki Ueno[2], Shinya Kiriyama[1] （1: Shizuoka University, 2: Chiba University Hospital / The Society of Citizen Informatics for Human Cognitive Disorder）

1:40 PM - 3:00 PM

Oral presentation | NFC Session | [NFC Session] NFC-2 UEPD (Development of fundamental technology for understanding emotions of people with dementia and its applications to communication support)

[1G2-NFC-2b] [NFC Session] NFC-2 UEPD (Development of fundamental technology for understanding emotions of people with dementia and its applications to communication support)

座長:竹林 洋一（静岡大学）

3:20 PM - 5:00 PM Room G (5F Ruby Hall Hiten)

[1G2-NFC-2b-a] (Panel discussion) Toward Development of Citizen Informatics for Human Cognitive Disorder

Koiti HASIDA[1], Ko ISHIYAMA[2], Seiji BITO[3] （1: Tokyo University, 2: ExaWizards Inc., 3: Tokyo Medical Center）

3:20 PM - 3:40 PM

[1G2-NFC-2b-b] Conclusion

Yoichi TAKEBAYASHI[1] （1: Shizuoka University / The Society of Citizen Informatics for Human Cognitive Disorder）

3:40 PM - 5:00 PM

Room H

Oral presentation | Organized Session | [Organized Session] OS-13

[1H1-OS-13a] [Organized Session] OS-13

1:20 PM - 3:00 PM Room H (10F Sky Hall)

[1H1-OS-13a-01] Annotating Expression of Roles and Exercise of Special Abilities to the Werewolf BBS

○Michimasa Inaba[1], Yoshinobu Kano[2], Hirotaka Osawa[3], Takeshi Otsuki[4], Daisuke Katagami[5], Fujio Toriumi[6] （1. Hiroshima City University, 2. Shizuoka University, 3. University of Tsukuba, 4. Yamagata University, 5. Tokyo Polytechnic University, 6. The University of Tokyo）

1:20 PM - 1:40 PM

[1H1-OS-13a-02] Performance Evaluation of AI Wolf Using Neural Network

○Hiroaki Doguro[1], Hitoshi Matsubara[1] （1. Future University Hakodate）

1:40 PM - 2:00 PM

[1H1-OS-13a-03] Improvement of Role Estimation using Machine Learning in werewolf AI

○Yuta Kimura[1], Takeshi Ito[1] （1. University of Electric Communication）

2:00 PM - 2:20 PM

[1H1-OS-13a-04] Development of Werewolf-game Agent Using Differentiable Neural Computer

○Ryo Iehara[1], Atsushi Hirota[1], Kazuaki Tanaka[1], Masahiro Araki[1], Natsuki Oka[1] （1. Kyoto Institute of Technology）

2:20 PM - 2:40 PM

[1H1-OS-13a-05] Analysis of Agents' Information Sharing with Evolutionary Computation

○Bohao Wang[1], Hirotaka Osawa[1], Ken Satoh[2] （1. University of Tsukuba, 2. National Institute of Informatics）

2:40 PM - 3:00 PM

Oral presentation | Organized Session | [Organized Session] OS-13

[1H2-OS-13b] [Organized Session] OS-13

3:20 PM - 5:00 PM Room H (10F Sky Hall)

[1H2-OS-13b-01] Evaluation of topic n-gram model for the utterance of AIWolf agent

○Takashi OTSUKI[1] （1. Yamagata University）

3:20 PM - 3:40 PM

[1H2-OS-13b-02] Role Estimation in Werewolf BBS using Distributed Representation

©The Japanese Society for Artificial Intelligence

Yurie Kimura[1], ○Tomonobu Ozaki[1] (1. Nihon University)

3:40 PM - 4:00 PM

[1H2-OS-13b-03] Natural Language Task in AI Werewolf Contest

○Yoshinobu Kano[1], Michimasa Inaba[2] (1. Shizuoka University, 2. Hiroshima City University)

4:00 PM - 4:20 PM

[1H2-OS-13b-a] Special program

4:20 PM - 5:00 PM

Room J

Oral presentation | General Session | [General Session] 9. NLP / IR

[1J1] [General Session] 9. NLP / IR

座長:平岡 拓也（日本電気株式会社）

1:20 PM - 3:00 PM Room J (2F Royal Garden B)

[1J1-01] A Study on Evaluation Method of Wikipedia's Article Using Network Feature Quantity in Definition Statement Extension for Word Sense Disamibiguation

○Wataru Murata[1], Ei-Ichi Osawa[2] (1. Future University Hakodate Graduate School, 2. Future University Hakodate)

1:20 PM - 1:40 PM

[1J1-02] Generating Descriptions for Videos based on the Interaction between a Human and Objects considering their Positional Relationship

○Rino Urushihara[1], Ichiro Kobayashi[1] (1. Ochanomizu University)

1:40 PM - 2:00 PM

[1J1-03] Automatic generation of questions from product manual sentences

○Sato Sato[1], Itsui Hiroyasu[2], Okumura Manabu[3] (1. School of Engineering, Tokyo Institute of Technology, 2. Mitsubishi Electric Corporation, 3. Institute of Innovative Research, Tokyo Institute of Technology)

2:00 PM - 2:20 PM

[1J1-04] Development of an Access Method to Linked Open Data through Converting Natural Language into SPARQL Queries

○Yuri Murayama[1], Ichiro Kobayashi[1], Takeshi Morita[2], Yukiko Nakano[3], Takahira Yamaguchi[2] (1. Ochanomizu University, 2. Keno University, 3. Seiko University)

2:20 PM - 2:40 PM

[1J1-05] Comparison of Reviews on Picture Books and Developmental Psychology Literature focusing on Infants' Developmental Reactions to Picture Books

○Miho Kasamatsu[1], Hiroshi Uehara[1,2], Takehito Utsuro[1], Yu Saito[3] (1. University of Tsukuba, 2. Akita Pref. Univ., 3. Seitoku Univ.)

2:40 PM - 3:00 PM

Oral presentation | General Session | [General Session] 9. NLP / IR

[1J2] [General Session] 9. NLP / IR

座長:木村 泰知（小樽商科大学）

3:20 PM - 5:00 PM Room J (2F Royal Garden B)

[1J2-01] A Linear-Time Kernelized Co-occurrence Norm for Sparse Linguistic Expressions

○Sho Yokoi[1,2], Sosuke Kobayashi[3], Kenji Fukumizu[4], Kentaro Inui[1,2] (1. Tohoku Univ., 2. Riken AIP, 3. Preferred Networks, 4. ISM)

3:20 PM - 3:40 PM

[1J2-02] Experimental Analysis of Effect of Reducing Search Space for Relevance Feedback Based on SVM

○Yuto Imamura[1], Takahiro Nishigaki[1], Takashi Onoda[1] (1. Aoyama Gakuin University)

3:40 PM - 4:00 PM

[1J2-03] Neural Ranking with Pretraining for Curation of Important Sentences in Business Operations

○Yuta Koreeda[1], Kenzo Kurotsuchi[1], Toshihiko Yanase[1], Kohsuke Yanai[1], Hisao Mase[1], Misa Sato[1] (1. Hitachi, Ltd.)

4:00 PM - 4:20 PM

[1J2-04] The effect of optimization by RIBES in statistical machine translation

○Naotaka Kawata[1], Hideki Isozaki[2], Genichiro Kikui[2] (1. Okayama Prefectural University Graduate School of Computer Science and Systems Engineering , 2. Okayama Prefectural University Faculty of Computer Science and Systems Engineering Department of Systems Engineering)

4:20 PM - 4:40 PM

[1J2-05] An Idea of Patent Document Classifier Support System Using Rough Set Theory

○masaki kurematsu[1] (1. Iwate Prefectural University)

4:40 PM - 5:00 PM

©The Japanese Society for Artificial Intelligence

Oral presentation | General Session | [General Session] 9. NLP / IR

[1J3] [General Session] 9. NLP / IR

座長:平岡 拓也（NEC）

5:20 PM - 7:00 PM Room J (2F Royal Garden B)

[1J3-01] A Study of Frame Importance Detection by Link Relationship among Frames on Comics

〇TAKASHI HIRAOKA[1], RYOSUKE YAMANISHI[2], YOKO NISHIHARA[2]（1. Graduate School, Ritsumeikan University, 2. Ritsumeikan University）

5:20 PM - 5:40 PM

[1J3-02] Classifying Personality of Comic Character Based on Egogram

〇Byeongseon Park[1], Kanae Ibayashi[1], Mitsunori Matsushita[1]（1. Kansai University）

5:40 PM - 6:00 PM

[1J3-03] A Novel Story Analysis Method based on the Distributed Representation of Sentences

〇Kiyohito Fukuda[1], Naoki Mori[1], Keinosuke Matsumoto[1]（1. Osaka Prefecture University）

6:00 PM - 6:20 PM

[1J3-04] Preliminary Analysis of Weibo Emojis for Sentiment Analysis of Chinese Social Media

〇Da Li[1], Rafal Rzepka[1], Kenji Araki[1]（1. Hokkaido University）

6:20 PM - 6:40 PM

[1J3-05] Filtering out improper accounts from Twitter user accounts for discovering individuals interested in certain topic

〇Chao Cai[1], Shun Shiramatsu[1]（1. Department of Computer Science, Graduate School of Engineering, Nagoya Institute of Technology）

6:40 PM - 7:00 PM

Room K

Oral presentation | Organized Session | [Organized Session] OS-2

[1K1-OS-2a] [Organized Session] OS-2

1:20 PM - 3:00 PM Room K (3F Azisai Mokuren)

[1K1-OS-2a-01] Analysis on Elements to Motivate Reading Comics Motivation

〇Kenta Sato[1], Yoshiki Maki[1], Satoshi Nakamura[1]（1. Meiji University）

1:20 PM - 1:40 PM

[1K1-OS-2a-02] Autonomous Generation of 2-panel Comics Based on Human-made Comics

〇Kazushi Mukaiyama[1]（1. Future University Hakodate）

1:40 PM - 2:00 PM

[1K1-OS-2a-03] Toward a Network Analysis of Empathic and Exciting AI Conversation and Scenario

〇Yasuda Yuki[1]（1. Kansai University）

2:00 PM - 2:20 PM

[1K1-OS-2a-04] A Proposal of Machine Translation from Japanese to Chinese Onomatopoeias

〇KAI YANG[1], Tsuyoshi Nakamura[1], Masayoshi Kanoh[2], Koji Yamada[3]（1. Nagoya Institute of Technology, 2. Chukyo University, 3. Institute of Advanced Media Arts and Sciences）

2:20 PM - 2:40 PM

[1K1-OS-2a-05] Recognizing the Order of Four-scene Comics by Three-Path Convolutional Neural Networks

〇Saya Fujino[1], Naoki Mori[1], Keinosuke Matsumoto[1]（1. Osaka Prefecture University）

2:40 PM - 3:00 PM

Oral presentation | Organized Session | [Organized Session] OS-2

[1K2-OS-2b] [Organized Session] OS-2

3:20 PM - 5:00 PM Room K (3F Azisai Mokuren)

[1K2-OS-2b-01] Manga Processing and its Dataset - Manga109- Construction for Academic Use

〇Kiyoharu Aizawa[1]（1. The University of Tokyo）

3:20 PM - 4:00 PM

[1K2-OS-2b-02] Automatic generation of anime-like hair motion of 3D characters

〇Kenji Furukawa[1], Susumu Nakata[1]（1. Ritsumeikan University）

4:00 PM - 4:20 PM

[1K2-OS-2b-03] Trials of Generating Comic Illustrations Using Deep Generative Adversarial Networks

〇Jun Hozumi[1], Yutaka Matsuo[1]（1. the University of Tokyo）

4:20 PM - 4:40 PM

[1K2-OS-2b-04] Character Representation Adaption in Individual Manga

〇Koki Tsubota[1], Toru Ogawa[1], Toshihiko Yamasaki[1], Kiyoharu Aizawa[1]（1. The

©The Japanese Society for Artificial Intelligence

University of Tokyo)
4:40 PM - 5:00 PM

Oral presentation | Organized Session | [Organized Session] OS-10

[1K3-OS-10a] [Organized Session] OS-10

5:20 PM - 7:00 PM Room K (3F Azisai Mokuren)

[1K3-OS-10a-01] Support system of assigning label to acoustic event in pig farm by automatic extraction of acoustic event and showing both acoustic event and movie
○Misaki Mito[1], Takuji Kawagishi[1], Koichi Mizutani[1,2], Keiichi Zempo[1,2], Naoto Wakatsuki[1,2], Nobuhiro Takemae[3], Takehiko Saito[3] (1. Graduate School of Systems and Information Engineering, Univ. Tsukuba, 2. Faculty of Engineering, Information and Systems, Univ. Tsukuba, 3. National Institute of Animal Health, NARO)
5:20 PM - 5:40 PM

[1K3-OS-10a-02] Multi-spectroscopic sensing of lettuce for freshness measurement using machine learning
○Takaharu Kameoka[1], Akane Tsukahara[1], Shinichi Kameoka[1], Ryoei Ito[1], Atsushi Hashimoto[1] (1. Mie University)
5:40 PM - 6:00 PM

[1K3-OS-10a-03] Preliminary study for discriminating oil palm ripeness by using color chart
○Kaiko Minakata[1], Kazuki Kobayashi[1], Kunihisa Tashiro[1], Hiroyuki Wakiwaka[1], Hirokazu Nagata[2], Norhisam Misron[3], Nor Aziana Aliteh[3], Takuma Hasegawa[1], Masaki Futamata[1] (1. Graduate School Science and Technology, Shinshu university, 2. Grobal Education Center, Shinshu University, 3. Faculty of Engineering, Universiti Putra Malaysia)
6:00 PM - 6:20 PM

[1K3-OS-10a-04] A Light-Driven Artificial Neural Network Architecture for Deep Neural Network
○Takuya Otsuka[1], Shiori Konisho[1] (1. Nippon Telegraph and Telephone)
6:20 PM - 6:40 PM

[1K3-OS-10a-05] Evaluation of Data Augmentation to Image-Based Plant Disease Detection
○Kenichi Kobayashi[1], Junpei Tsuji[1], Masato Noto[1] (1. Kanagawa University)
6:40 PM - 7:00 PM

Room L

Oral presentation | General Session | [General Session] 12. HI / Education Aid

[1L1] [General Session] 12. HI / Education Aid

座長:笠井 俊信（岡山大学大学院）
1:20 PM - 3:00 PM Room L (3F Sapphire Hall Asuka)

[1L1-01] Engineering Experiment Environment Combining Knowledge-Constructive Jigsaw Method and IoT
○Takafumi Noguchi[1] (1. National Institute of Technology, Kushiro College)
1:20 PM - 1:40 PM

[1L1-02] Effect of Educational-Support Robot Based on Cognitive Apprenticeship Theory
○Kenya Miyauchi[1], Jimenez Felix[1], Tomohiro Yoshikawa[1], Takeshi Furuhashi[1] (1. Nagoya university)
1:40 PM - 2:00 PM

[1L1-03] Development of a Simulation System for Changing Decision Character during Playing Japanese Poem Card Game
○Chiharu Tokushima[1], Masato Soga[1] (1. Wakayama University)
2:00 PM - 2:20 PM

[1L1-04] Character Strokes Detection and Scoring for Increasing Children's Calligraphy Training time
○Yui Kakino[1], Makoto Kawano[1], Takuro Yonezawa[1], Jin Nakazawa[1] (1. Keio University)
2:20 PM - 2:40 PM

[1L1-05] Analysis of NIE Worksheets and Article Estimation Method for Web News Recommendation to Elementary School Teachers
○Shinya Seki[1], Kazuaki Ando[1] (1. Kagawa University)
2:40 PM - 3:00 PM

Oral presentation | General Session | [General Session] 12. HI / Education Aid

[1L2] [General Session] 12. HI / Education Aid

座長:野口 孝文（釧路高専）
3:20 PM - 5:00 PM Room L (3F Sapphire Hall Asuka)

[1L2-01] Investigation of a Training Environment for Student Teacher using Atmosphere Generation

©The Japanese Society for Artificial Intelligence

Model in a Virtual Classroom

○Masato Fukuda[1], Huang Hsuan Hung[3,4,2], Kazuhiro Kuwabara[2] （1. Graduate School of Information Science and Engineering Ritsumeikan University, 2. College of Information Science and Engineering Ritsumeikan University, 3. Center for Advanced Intelligence Project RIKEN, 4. Department of Intelligence Science and Technology, Graduate School of Informatics, Kyoto University）

3:20 PM - 3:40 PM

[1L2-02] Item Responce Theory for dynamic assesment

○Emiko Tsutsumi[1], Masaki Uto[2], Maomi Ueno[2] （1. Faculty of Informatics and Engineering, The University of Electro-Communications, 2. Graduate school of Informatics and Engineering, The University of Electro-Communications）

3:40 PM - 4:00 PM

[1L2-03] Automatic Classification of Description Problem Answers in Business Education

○Kenta Sasaki[1], Kenichi Suzuki[1], Kentaro Inui[2] （1. The Graduate School of Management, GLOBIS University, 2. Tohoku University）

4:00 PM - 4:20 PM

[1L2-04] Competency-oriented Learning by Teaching is as effective as Mastery Learning provided by Cognitive Tutor

○Noboru Matsuda[1] （1. Texas A&M University）

4:20 PM - 4:40 PM

[1L2-05] A Study on Japanese Listening Training Support System by Using Anime

○Junjie Shan[1], Yoko Nishihara[1], Ryosuke Yamanishi[1] （1. Ritsumeikan University）

4:40 PM - 5:00 PM

Oral presentation | General Session | [General Session] 12. HI / Education Aid

[1L3] [General Session] 12. HI / Education Aid

座長:曽我 真人（和歌山大学）

5:20 PM - 6:40 PM Room L (3F Sapphire Hall Asuka)

[1L3-01] Development of Logical Thinking Training System by Proving Mathematical Problems

○Kayo Kawamoto[1,2], Minatsu Furutani[1], Ayako Miyawaki[1], Tomoyuki Uchida[1], Tsukasa Hirashima[2], Yusuke Hayashi[2] （1. Hiroshima City University, 2. Hiroshima University）

5:20 PM - 5:40 PM

[1L3-02] Student group formation multiobjective optimization with a hybrid of genetic algorithm and particle swarm optimization

○Satoshi V. Suzuki[1] （1. Osaka University of Economics and Law）

5:40 PM - 6:00 PM

[1L3-03] A Study on Oddball Tasks with Feedback for Measuring P300

○Tadashi Koike[1], Tomohiro Yoshikawa[1], Takeshi Furuhashi[1] （1. Nagoya university）

6:00 PM - 6:20 PM

[1L3-04] Constructive and Practical Research Methodology for Computational Understanding of Situated Intelligence

○Koryu Nagata[1], Yasutaka Kuroki[2], Masaya Okada[3] （1. Department of Computer Science, Faculty of Informatics, Shizuoka University, 2. Department of Informatics, Graduate School of Integrated Science and Technology, Shizuoka University, 3. Division of Behavior Informatics, College of Informatics, Academic Institute, Shizuoka University）

6:20 PM - 6:40 PM

Room M

Oral presentation | General Session | [General Session] 13. AI Application

[1M2] [General Session] 13. AI Application

座長:佐々木 耀一（日本電気株式会社）

3:20 PM - 5:00 PM Room M (2F Amethyst Hall Hoo)

[1M2-01] Automatic Planning of Electrical Isolation with Deep Learning in Nuclear Power Plant

○Susumu Naito[1], Kei Takakura[1], Hiroki Shiba[1] （1. TOSHIBA ENERGY SYSTEMS &SOLUTIONS CORPORATION）

3:20 PM - 3:40 PM

[1M2-02] Approach to the transfer of quality control skills at the construction site using eye-gazing data

○Junya Morita[1], Nao Fujimoto[1], Katsumi Yanagita[1] （1. KAJIMA Corporation）

3:40 PM - 4:00 PM

[1M2-03] Toward Supporting Decision Making for Flood Control in a Hydroelectric Dam by Reinforcement Learning and Symbol Grounding

○Yukiko Tanaka[1,2], Takuya Hiraoka[1,2], Takashi Onishi[1,2], Yoshimasa Tsuruoka[2,3], Shohei Takino[4], Yosuke Matsumoto[5] （1. NEC Security Research Laboratories, 2. National Institute of Advanced

©The Japanese Society for Artificial Intelligence

Industrial Science and Technology, Artificial Intelligence Research Center, 3. The University of Tokyo, 4. Tokyo Electric Power Company Holdings, Inc., 5. Tokyo Electric Power Services Co., Ltd.）

4:00 PM - 4:20 PM

[1M2-04] Algorithmic Detection of Quote Spoofing in Stock Exchange Market Using Probability Density Ratio Estimation

○Kenichi Nakahara[1], Fumiya Shimada[1], Kunihiro Miyazaki[1], Masayuki Sekine[1], Shouhei Ohsawa[1], Makoto Ohshima[2], Yutaka Matsuo[1] （1. The University of Tokyo, 2. DSB Co., Ltd.）

4:20 PM - 4:40 PM

[1M2-05] Proposal of a business assisting framework with multiple chatbots

○Keisuke Tsunoda[1], Masahiro Okazaki[1], Ryuto Koyanagi[1], Fujie Nagamori[1], Daisuke Minoura[1] （1. NTT Comware Corporation）

4:40 PM - 5:00 PM

Oral presentation | General Session | [General Session] 13. AI Application

[1M3] [General Session] 13. AI Application

座長:大西 貴士（NEC/産総研）

5:20 PM - 6:40 PM Room M (2F Amethyst Hall Hoo)

[1M3-01] A Lighting Control to Optimize Satisfaction of Illuminance and Color Temperature

○Wataru Bando[1], Mitsunori Miki[2], Hiroaki Nasu[1], Ryoto Tomioka[1], Hiroto Aida[2] （1. Graduate School of Science and Engineering, Doshisha University, 2. Department of Science and Engineering, Doshisha University）

5:20 PM - 5:40 PM

[1M3-02] Development of Machine Learning Models for Gas Identification Based on Transfer Functions

○Gaku Imamura[1], Genki Yoshikawa[1,2], Takashi Washio[3] （1. National Institute for Materials Science, 2. University of Tsukuba, 3. Osaka University）

5:40 PM - 6:00 PM

[1M3-03] Minimum Cost Mapping of Quantum Circuits to Quantum Computers

○Toshinari Itoko[1], Rudy Raymond[1], Takashi Imamichi[1] （1. IBM Research - Tokyo）

6:00 PM - 6:20 PM

[1M3-04] Segment Assignment in Shield Tunneling Method using Constrained Genetic Algorithm

○Koya Ihara[1], Shohei Kato[1,2], Takehiko Nakaya[3], Tomoaki Oki[3] （1. Dept. of Computer Science and Engineering, Graduate School of Engineering, Nagoya Institute of Technology, 2. Frontier Research Institute for Information Science, Nagoya Institute of Technology, 3. Shimizu Corporation）

6:20 PM - 6:40 PM

Room N

Oral presentation | General Session | [General Session] 2. Machine Learning

[1N1] [General Session] 2. Machine Learning

座長:原 聡（大阪大学）

1:20 PM - 3:00 PM Room N (2F Sakurajima)

[1N1-01] Learning of Relative Spatial Concepts from Utterances based on MCMC sampling

○Rikunari Sagara[1], Zhixiang Gu[1], Ryo Taguchi[1], Koosuke Hattori[2], Masahiro Hoguro[2], Taizo Umezaki[1,3] （1. Nagoya Institute of Technology, 2. Chubu University, 3. The University of Tokyo）

1:20 PM - 1:40 PM

[1N1-02] The Method of Machine Learning Considering Tamper of Training Data

Tenshi Yanagimachi[1], ○Yoshiteru Ishida[1] （1. Toyohashi University of Technology）

1:40 PM - 2:00 PM

[1N1-03] Prediction with LSTM and Analysis of Werewolf

○Manami Kondoh[1], Taku Hasegawa[1], Naoki Mori[1], Keinosuke Matsumoto[1] （1. Osaka Prefecture University）

2:00 PM - 2:20 PM

[1N1-04] Analysis of cognitive satisficing value function

○Akihiro Tamatsukuri[1], Tatsuji Takahashi[2] （1. Graduate School of Tokyo Denki Univerity, 2. Tokyo Denki University）

2:20 PM - 2:40 PM

[1N1-05] Social reinforcement learning with shared reference satisficing

○Noriaki Sonota[1], Takumi Kamiya[2], Yu Kono[3], Tatsuji Takahashi[1] （1. School of Science and Engineering, Tokyo Denki University, 2. Graduate School of Tokyo Denki Univerity, 3. DeNA Co., Ltd.）

2:40 PM - 3:00 PM

Oral presentation | General Session | [General Session] 2. Machine Learning

[1N2] [General Session] 2. Machine Learning

座長:岡本 昌之（トヨタ自動車株式会社）

©The Japanese Society for Artificial Intelligence

3:20 PM - 5:00 PM Room N (2F Sakurajima)

[1N2-01] Sequential User Profiling from Newspapers' Access Log

○Wataru Kudo[1], Fujio Toriumi[1] (1. The University of Tokyo)

3:20 PM - 3:40 PM

[1N2-02] A Nonparametric Delayed Feedback Model for Conversion Rate Prediction

○Yuya Yoshikawa[1], Yusaku Imai[2] (1. STAIR Lab, Chiba Institute of Technology, 2. CyberAgent, Inc)

3:40 PM - 4:00 PM

[1N2-03] Learning Style-sensitive Word Vector via Unsupervised-manner

○Reina Akama[1], Kento Watanabe[1], Sho Yokoi[1,2], Sosuke Kobayashi[3], Kentaro Inui[1,2] (1. Tohoku University, 2. RIKEN AIP, 3. Preferred Networks, Inc.)

4:00 PM - 4:20 PM

[1N2-04] Multiplex Network Embedding with Layer Vectors

○Ryuta Matsuno[1], Tsuyoshi Murata[1] (1. Tokyo Institute of Technology)

4:20 PM - 4:40 PM

[1N2-05] Quantification of contribution of features to EEG classification using the efficient estimation of Shapley Value based on a hierarchy of EEG features

○Kazuki Tachikawa[1], Yuji Kawai[1], Jihoon Park[1], Minoru Asada[1] (1. OsakaUniversity)

4:40 PM - 5:00 PM

Oral presentation | General Session | [General Session] 2. Machine Learning

[1N3] [General Session] 2. Machine Learning

座長:松井 藤五郎（中部大学）

5:20 PM - 7:00 PM Room N (2F Sakurajima)

[1N3-01] Excluding the Data with Exploration from Supervised Learning Improves Neural Fictitious Self-Play

○Keigo Kawamura[1], Jun Suzuki[2,3], Yoshimasa Tsuruoka[4] (1. Graduate School of Engineering, The University of Tokyo, 2. NTT Communication Science Laboratories, NTT Corporation, 3. RIKEN Center for Advanced Intelligence Project, 4. Graduate School of Information Science and Technology, The University of Tokyo)

5:20 PM - 5:40 PM

[1N3-02] Estimation of a non-linear reward function using score-based inverse reinforcement learning

○Natsumi Watanabe[1], Gakuto Masuyama[2], Kazunori Umeda[1] (1. Chuo University, 2. Meijo University)

5:40 PM - 6:00 PM

[1N3-03] Toward satisficing in general reinforcement learning

○Kuniaki Satori[1], Yutaka Yoshida[1], Kenta Yamagishi[1], Yuya Ushida[2], Takumi Kamiya[2], Tatsuji Takahashi[1] (1. Tokyo Denki University, 2. Graduate School of Tokyo Denki Univerity)

6:00 PM - 6:20 PM

[1N3-04] Hybird Learning Using Profit Sharing and Genetic Algorithm -Task Division Performance in MDP Environments-

○Kohei Suzuki[1], Shohei Kato[1,2] (1. Nagoya Institute of Technology, 2. Frontier Research Institute for Information Science, Nagoya Institute of Technology)

6:20 PM - 6:40 PM

[1N3-05] Inverse Reinforcement Learning with BDI Agents for Pedestrian Behavior Simulation

○Nahum Alvarez[1], Itsuki Noda[1] (1. The National Institute of Advanced Industrial Science and Technology (AIST))

6:40 PM - 7:00 PM

Room O

Oral presentation | General Session | [General Session] 10. Vision / Speech

[1O1] [General Session] 10. Vision / Speech

座長:石寺 永記（NECソリューションイノベータ）

1:20 PM - 3:00 PM Room O (2F Kaimon)

[1O1-01] Banner Click Through Rate Classification Using Deep Convolutional Neural Network

Nicolas Michel[2,3], ○Hayato Sakata[1], Keita Kurita[3], Toshihiko Yamasaki[3] (1. So-net Media Networks Corp., 2. Institut Mines-Télécom Atlantique, 3. The University of Tokyo)

1:20 PM - 1:40 PM

[1O1-02] Turn Signal Recognition by Convolutional Recurrent Neural Network

○Ryota Hagi[1], Keisuke Yoneda[1], Naoki Suganuma[1] (1. Kanazawa University)

1:40 PM - 2:00 PM

[1O1-03] Bidirectional recognition between motion context on long-term observation and human

©The Japanese Society for Artificial Intelligence

motion

○Tadashi Ogura[1], Tetsunari Inamura[1,2] (1. SOKENDAI(The Graduate University for Advanced Studies), 2. National Institute of Informatics)

2:00 PM - 2:20 PM

[1O1-04] On Simultaneous Recognition of Multiple Paper Sticky Notes with Position Detection and High-resolution

○Eishun Ito[1], Tadachika Ozono[1], Toramatsu Shintani[1] (1. Nagoya Institute of Technology)

2:20 PM - 2:40 PM

[1O1-05] ATM Anomaly Behavior Detection with Machine Learning: A Study

○TRONG HUY PHAN[1], Reiko Kishi[1], Kazuma Yamamoto[1], Makoto Masuda[1] (1. Corporate Research and Development Center, Oki Electric Industry Co., Ltd.)

2:40 PM - 3:00 PM

Oral presentation | Organized Session | [Organized Session] OS-15

[1O2-OS-15a] [Organized Session] OS-15

3:20 PM - 5:00 PM Room O (2F Kaimon)

[1O2-OS-15a-01] Artificial Intelligence: Challenge to the Real World Problems

○Hideyuki Nakashima[1] (1. University of Tokyo)

3:20 PM - 3:40 PM

[1O2-OS-15a-02] Future Artificial Intelligence Technology: Real World Problems in Implementation

○Yoichi Motomura[1] (1. The National Institute of Advanced Industrial Science and Technology)

3:40 PM - 4:00 PM

[1O2-OS-15a-03] Utilization of Artificial Intelligence and its Human Resource Development in Kansai Area

○Joe Suzuki[1] (1. Osaka University)

4:00 PM - 4:20 PM

[1O2-OS-15a-04] How to Improve Manufactual Industrial Business with Design Thinking

○Nami Harada[1], Yoichi Motomura[1] (1. ADVANCED INDUSTRIAL SCIENCE AND TECHNOLOGY)

4:20 PM - 4:40 PM

[1O2-OS-15a-05] Optimization of Food supply chain by AI technology

○Tatsuhiro Matsuoka[1], Yoichi Motomura[2] (1. Sigmaxyz inc., 2. National Institute of Advanced Industrial Science and Technology)

4:40 PM - 5:00 PM

Oral presentation | Organized Session | [Organized Session] OS-15

[1O3-OS-15b] [Organized Session] OS-15

5:20 PM - 7:00 PM Room O (2F Kaimon)

[1O3-OS-15b-01] Development of service platform and eco system for sustainable data collection of AI

○Kota Takaoka[1], Yoichi Motomura[1] (1. Artificial Intelligence Research Center(AIST))

5:20 PM - 5:40 PM

[1O3-OS-15b-02] User model about kansei using probabilistic methods and implementation trials of user model

○Eiichi Sakurai[1], Youichi Motomura[1] (1. National Institute of Advanced Industrial Science and Technology (AIST))

5:40 PM - 6:00 PM

[1O3-OS-15b-03] Preliminary Investigation Toward Development System of Childcare Study Support Using AI

○Tetsuzi Yamada[1], Ryoma Hida[2], Masahiro Miyata[2], Takashi Omori[3] (1. Tamagawa University Brain Science Institute, 2. Tamagawa University Graduate School of Engineering, 3. Tamagawa University Faculty of Engineering)

6:00 PM - 6:20 PM

[1O3-OS-15b-04] Visitors' Migration Behavior Analysis at Large-scale Events

○Nao Kondo[1], Nami Harada[1], Kazuya Yamashita[1], Tomotaka Omae[1,2], Yoichi Motomura[1,2] (1. National Institute of Advanced Industrial Science and Technology, 2. Tokyo Institute of Technology)

6:20 PM - 6:40 PM

[1O3-OS-15b-05] Generation of learning data for everyday life behaviors in elderly care home using 3DCG

©The Japanese Society for Artificial Intelligence

Koji Kitamura[1], Yoichi Motomura[1], Yoshifumi Nishida[1], ○Tomoya Iwasawa[2], Masanobu Eshima[2], Hideshi Hirose[3] (1. National Institute of Advanced Industrial Science and Technology, 2. IMAGICA Imageworks, Inc., 3. IMAGICA Corp.)

6:40 PM - 7:00 PM

Room P

Oral presentation | General Session | [General Session] 3. Data Mining

[1P1] [General Session] 3. Data Mining

座長:成松 宏美（NTT）

1:20 PM - 3:00 PM Room P (4F Emerald Lobby)

[1P1-01] A Sampling Method based on Generalized Relative Square Error to Emphasize Low Probability Events

Hiroshi Hasegawa[1], ○Tomomi Nakamura[1], Takashi Washio[2] (1. Dept. Math and Sciences, Ibaraki University, 2. ISIR, University of Osaka)

1:20 PM - 1:40 PM

[1P1-02] Adaptive questionnaire system based on Bayesian network

○Shu Tamura[1], Eiichi Sakurai[1], Youichi Motomura[1] (1. National Institute of Advanced Industrial Science and Technology (AIST))

1:40 PM - 2:00 PM

[1P1-03] Applying Ordinal logit model to Self-Attentive-LSTM

○Hiroyuki Mitsugi[1], Michiharu Kitano[1], Hiroaki Watabe[1] (1. Daiwa Institute of Research Ltd.)

2:00 PM - 2:20 PM

[1P1-04] Creation of Causal Relation Network using Semantic Similarity

○kohei nishimura[1], Hiroki Sakaji[2], Kiyoshi Izumi[2] (1. Department of Systems Innovation, Faculty of Engineering, The University of Tokyo, 2. Graduate School of Engineering, The University of Tokyo)

2:20 PM - 2:40 PM

[1P1-05] Analysis of the relation between leaders and revitalization of community activities

○Kosuke Hamajima[1], Atsuko Mutoh[1], Koichi Moriyama[1], Nobuhiro Inuzuka[1] (1. Nagoya Institute of Technology)

2:40 PM - 3:00 PM

Oral presentation | General Session | [General Session] 3. Data Mining

[1P2] [General Session] 3. Data Mining

座長:原 聡（大阪大学）

3:20 PM - 5:00 PM Room P (4F Emerald Lobby)

[1P2-01] Design and evaluation of visual analytics interface for time series data based on direct manipulation of trajectory

○Rei Takami[1], Yasufumi Takama[1] (1. Tokyo Metropolitan University)

3:20 PM - 3:40 PM

[1P2-02] Anomaly Detection on Sound Data Using Dynamic Mode Decomposition

○Kota Dohi[1], Naoya Takeishi[1], Takehisa Yairi[1], Koichi Hori[1] (1. Department of Aeronautics and Astronautics, The University of Tokyo)

3:40 PM - 4:00 PM

[1P2-03] Analysis of Television Viewing Pattern Transitions with Clustering Large-Scale Log Data

○Yoshiaki Mizuoka[1], Kouta Nakata[1], Ryohei Orihara[1] (1. Analytics AI Laboratory, Corporate Research and Development Center, Research &Development Division, Toshiba Corporation)

4:00 PM - 4:20 PM

[1P2-04] Verification of Factors Forming Quality Brand Image in Customers' Perception

○Takumi Kato[1], Kazuhiko Tsuda[2] (1. Honda Motor Co.,Ltd., 2. University of Tsukuba)

4:20 PM - 4:40 PM

[1P2-05] Detection of Social Bots: Quantification of Language Independent Features and Bot Clusters

○Masaki Sugimori[1], Kazutoshi Sasahara[1,2], Kei Tokita[1] (1. Graduate School of Informatics, Nagoya University, 2. JST, PRESTO)

4:40 PM - 5:00 PM

Oral presentation | General Session | [General Session] 3. Data Mining

[1P3] [General Session] 3. Data Mining

座長:岡田 将吾（北陸先端科学技術大学院大学）

5:20 PM - 7:00 PM Room P (4F Emerald Lobby)

[1P3-01] Twitter Actuates the Cryptocurrency Market

○Koichiro Tamura[1], Shohei Ohsawa[1], Yutaka Matsuo[1] (1. The University of Tokyo)

5:20 PM - 5:40 PM

[1P3-02] Finding Representatives via Nearest Neighbor Based Binarization and Frequent Pattern Mining

○Yuka Yoneda[1], Mahito Sugiyama[2], Takashi Washio[1]

©The Japanese Society for Artificial Intelligence

（1. The Institute of Scientific and Industrial Research , 2. National Institute of Informatics）

5:40 PM - 6:00 PM

[1P3-03] Inference of Local Feature Correlations by Hints

HongJie ZHAI[1], ○Makoto HARAGUCHI[1], Hideyuki IMAI[1] （1. Hokkaido University）

6:00 PM - 6:20 PM

[1P3-04] Studies on Normal Boiling Point of Chemical Substances and Eigen Values of Their Molecular Matrices

○Kiryu Yamashita[1], Yoshimasa Takahashi[1], Tetsuo Katsuragi[1] （1. Graduate School of Engineering , Toyohashi University of Technology）

6:20 PM - 6:40 PM

[1P3-05] Extraction of the operational skills by analysis of CAD operation log

○KEISUKE NIIMI[1], Akio Sotoike[1], Tatsuya Arisato[1] （1. Toyota Motor Corporation）

6:40 PM - 7:00 PM

Room Z

Oral presentation | General Session | [General Session] 2. Machine Learning

[1Z1] [General Session] 2. Machine Learning

座長:大塚 琢馬（NTT）

1:20 PM - 3:00 PM Room Z (3F Matsu Take)

[1Z1-01] Concept-drift-aware Stochastic Gradient Descent

○Kohei Miyaguchi[1], Hiroshi Kajino[2] （1. Graduate School of Information Science and Technology, The University of Tokyo, 2. IBM Research - Tokyo）

1:20 PM - 1:40 PM

[1Z1-02] Statistical Evaluation for Mode Selection in Sparsity-promoting Dynamic Mode Decomposition

○Masashi Hiraoka[1], Yoshinobu Kawahara[1,2], Takashi Washio[1] （1. The Institute of Science and Industrial Research, Osaka University, 2. Center for Advanced Intelligence Project, RIKEN）

1:40 PM - 2:00 PM

[1Z1-03] Expert-based reward function training: the novel method to train sequence generators

○Joji Toyama[1], Yusuke Iwasawa[1], Yutaka Matsuo[1] （1. The University of Tokyo）

2:00 PM - 2:20 PM

[1Z1-04] Dynamic mode decomposition using supervised principal component analysis

○Takehito Bito[1], Yoshinobu Kawahara[1,2], Takashi Washio[1] （1. Osaka university, 2. RIKEN）

2:20 PM - 2:40 PM

[1Z1-05] Bayesian Estimation and Model Averaging of CNN by Hypernet

○Kenya Ukai[1], Takashi Matsubara[1], Kuniaki Uehara[1] （1. Graduate School of System Infomatics, Kobe University）

2:40 PM - 3:00 PM

Oral presentation | General Session | [General Session] 2. Machine Learning

[1Z2] [General Session] 2. Machine Learning

座長:竹内 孝（NTT）

3:20 PM - 5:00 PM Room Z (3F Matsu Take)

[1Z2-01] Robustness verification of CMA-ES optimization for neural networks

○Hiroki Shimizu[1], Junpei Komiyama[2], Masashi Toyoda[2] （1. The University of Tokyo, 2. Institute of Industrial Science, the University of Tokyo）

3:20 PM - 3:40 PM

[1Z2-02] Learning to Bipedal Walking on Simulation with SUNA

○Yuta Inoue[1], Danilo Vasconcellos Vargas[1] （1. Kyushu University）

3:40 PM - 4:00 PM

[1Z2-03] The Study on Stochastic Variational Inference for Topic Modeling with Word Embeddings

○Kana Ozaki[1], Ichiro Kobayashi[1] （1. Ochanomizu University）

4:00 PM - 4:20 PM

[1Z2-04] Kernel median embedding as a functional parameter of the data distribution

○Matthew J Holland[1] （1. Osaka University）

4:20 PM - 4:40 PM

[1Z2-05] On Incomplete Noisy Sorting

○Junpei Komiyama[1] （1. The University of Tokyo）

4:40 PM - 5:00 PM

Oral presentation | General Session | [General Session] 2. Machine Learning

[1Z3] [General Session] 2. Machine Learning

座長:石畠 正和（NTT）

5:20 PM - 7:00 PM Room Z (3F Matsu Take)

[1Z3-01] A Proposal of a loss function of GAN to generate various images

©The Japanese Society for Artificial Intelligence

○Ryoji Kodama[1], Tsuyoshi Nakamura[1], Masayoshi Kanoh[2], Koji Yamada[3] （1. Nagoya Institute of Technology, 2. Chukyo University, 3. Institute of Advanced Media Arts and Sciences）

5:20 PM - 5:40 PM

[1Z3-02] Approximation of Value Function with Feature Representation Learning to Deal with Extendable Action Space

○Yu Kono[1], Ikki Tanaka[1], Jun Ernesto Okumura[1] （1. DeNA Co., Ltd.）

5:40 PM - 6:00 PM

[1Z3-03] Disentangled Representation Learning From Sequential Data

○Masanori Yamada[1], Heecheol Kim [3], Kosuke Miyoshi[3], Hroshi Yamakawa[2,3] （1. NTT Secure Platform Laboratories, 2. The Whole Brain Architecture Initiative, 3. Dwango Artificial Intelligence Laboratory）

6:00 PM - 6:20 PM

[1Z3-04] Autonomous optimal exploration through satisficing

Yu Kono[2], ○Tatsuji Takahashi[1] （1. Tokyo Denki University, 2. DeNA Co., Ltd.）

6:20 PM - 6:40 PM

[1Z3-05] Comparison of extraction of diffuse lung disease areas using CNN, FCN and U-Net

○Kanako Murakami[1], Noriaki Hashimoto[1], Shoji Kido[1], Yasushi Hirano[1], Shingo Mabu[1], Kenji Kondo[2,3], Jun Ozawa[2] （1. Graduate school of Sciences and Technology for Innovation, Yamaguchi University, 2. Advanced Industrial Science and Technology, 3. Panasonic Corporation）

6:40 PM - 7:00 PM

©The Japanese Society for Artificial Intelligence

[1B3] [General Session] 5. Web Intelligence

座長:大塚 淳史（NTT）

Tue. Jun 5, 2018 5:20 PM - 6:40 PM Room B (4F Moon Light)

[1B3-01] Burst Phenomenon Analysis in Social Tagging System using Hawkes Process

○Shota Ejima[1], Taichi Kosugi[1], Mizuki Oka[1], Masanori Miyake[2], Takashi Ikegami[2] （1. Graduate School of Systems and Information Engineering, University of Tsukuba, 2. Graduate School of Arts and Science, The University of Tokyo）

5:20 PM - 5:40 PM

[1B3-02] Analyzing the influence of human personality on SNS community formation

○Gaia Suzuki[1], Masanao Ochi[1], Takeshi Sakaki[1], Ichiro Sakata[1] （1. School of Engineering, The University of Tokyo）

5:40 PM - 6:00 PM

[1B3-03] An Evaluation System for Credibility of Fake News using Dynamic Relational Networks

Sanae Kuraya[1], ○Yoshiteru Ishida[1] （1. Toyohashi University of Technology）

6:00 PM - 6:20 PM

[1B3-04] A Consideration of Social Relationships and Social Support in a Virtual Society

○Masanori Takano[1], Kan Mizuno[1] （1. CyberAgent, Inc.）

6:20 PM - 6:40 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

Hawkes Process を用いた Social Tagging System におけるバースト現象解析

Burst Phenomenon Analysis in Social Tagging System using Hawkes Process

江島昇太 *1 Shota Ejima　小杉太一 *1 Taichi Kosugi　岡瑞起 *1 Mizuki Oka　三宅雅矩 *2 Masanori Miyake　池上高志 *2 Takashi Ikegami

*1筑波大学大学院システム情報工学研究科
Graduate School of Systems and Information Engineering, University of Tsukuba

*2東京大学大学院総合文化研究科
Graduate School of Arts and Science, The University of Tokyo

In the activities of people on WEB such as SNS, the burst phenomenon is observed. Recently, Hawkes Process is used as a method to analyze the burst phenomenon. It is known that when the branching ratio, which is an index representing the internal dynamics of Hawkes Process, exceeds a certain threshold, the event time series transits from steady state to nonstationary state where the burst phenomena is likely to occur. In this paper, we focus on social tagging system among data obtained from SNS, and analyze how branching ratio changes timewise with service growth.

1. はじめに

Social Networking Service (SNS) など, WEB 上の人々の活動においては, ある特定の話題に対する言及が急激に増えるような**バースト現象**が見られる. バースト現象は, あるイベントの発生が別のイベントの発生を引き起こすといった自己励起性という性質によって特徴づけることができる. 近年, このような WEB 上におけるバースト現象を, 自己励起型の確率的点過程の一つである Hawkes Process によってモデル化するといった試みが行われている [Oka 15].

Hawkes Process における内部のダイナミクスを表す指標である branching ratio がある一定の値を超えると, イベント時系列が静的な定常状態から, バースト現象が起こりやすい非定常状態へと相転移することが理論的及びシミュレーションによって明らかになっている [Onaga 14]. また, SNS から得られた実データに対してもこの相転移が見られることが分かっている [三宅 17][三宅 18].

SNS における特徴的なシステムとして, **Social Tagging System** が挙げられる. Social Tagging System では, ユーザがコンテンツに対して「タグ」を付与することによってコンテンツの管理や検索を容易にすることが目的とされている. 一方で, このタグはユーザが自由に付与することが出来る場合が多く, 新たなタグの発明や流行といった現象が見られる. こうした流行現象は, 強い自己励起性によってもたらされる可能性があり, ある種のバースト現象であると捉えることができる.

本研究では, SNS から得られる実データの中でも特に, Social Tagging System におけるユーザのタグ付け行為に着目した. サービスが成長するにつれて多くのタグが生み出され使用されていくが, その使用履歴にはバースト現象を呈するものが存在する. タグが付与されたコンテンツの投稿をイベント時系列とみなし, サービス初期から直近のデータを一定間隔ごとに区切った後, Hawkes Process によってモデル化することで, サービスの成長に伴って branching ratio がどのような時間的変化をしているのか, またサービスの期間内で, 非定常状態と定常状態を示す挙動がどのような比率で存在しているかを確認した.

連絡先: 江島昇太, eji@websci.cs.tsukuba.ac.jp
小杉太一, tai_kos@websci.cs.tsukuba.ac.jp

2. 解析手法

2.1 Hawkes Process

Hawkes Process は, 自己励起型の確率的点過程の一つである [Hawkes 71]. 指数関数カーネルを用いて, 強度関数 (イベントの発生率) $\lambda(t)$ が, 以下の式で表される.

$$\lambda(t) = \mu + \alpha \sum_{t_k<t} e^{-\beta(t-t_k)} \tag{1}$$

ここで, 強度とは単位時間あたりのイベントの平均発生回数を表す. α はイベント発生時の強度関数の励起率 (ジャンプ幅) を表し, β はイベント発生語の強度関数の減衰率を表す. また, μ は常に最低限保たれるベースラインとなる強度を表す.

Hawkes Process の大きな特徴は, 強度関数が過去に発生したイベントとの時間的関係によって表されており, あるイベントが起こるとさらにそれが起こりやすくなる, というような**正のフィードバック効果**が考慮されているという点である.

従来, Hawkes Process は地震の発生間隔といった自然現象の解析に対して用いられてきたほか, 神経細胞の活動や金融取引パターンの解析, 予測など, 様々な分野に応用されてきた. 近年では, SNS のおけるユーザの活動のダイナミクスを捉えるために, Hawkes Process を用いてモデル化するといった研究もなされている.

また, Hawkes Process における内部のダイナミクスを表す指標である **branching ratio** は以下のように表される.

$$n = \int_{-\infty}^{\infty} \alpha e^{-\beta t} dt = \frac{\alpha}{\beta} \tag{2}$$

branching ratio が以下に示すある一定の値を超えると, イベント時系列が静的な定常状態から, バーストが頻繁に発生する非定常状態へと相転移する比率が以下で与えられる [Onaga 14].

$$\begin{aligned} n &> 1 - 1/\sqrt{2} \\ &\approx 0.2929... \end{aligned} \tag{3}$$

すなわち, branching ratio はバースト現象を定量化する際のティッピング・ポイントとなる指標である.

2.2 最適区間幅推定

イベント時系列のバースト現象を定義する手法として, 生理学などでよく用いられる Peristimulus Time Histogram (PSTH) 作成における最適区間幅推定を用いる. 時間幅の決定に関しては, 平均二乗誤差 (MISE) 最小化の観点から, 以下の手順で求めることができる [Shimazaki 07].

1. n 回の試行による時系列の観測期間 T を幅 Δ, N 個の bin に分割し, i 番目の bin に入るイベントの個数を k_i とする.
2. bin ごとのイベント数の平均 $\overline{k}$ と分散 v

$$\overline{k} = \frac{1}{N}\sum_{i=1}^{n} k_i, \quad v = \frac{1}{N}\sum_{i=1}^{n}(k_i - \overline{k})^2 \tag{4}$$

をそれぞれ計算する.

3. コスト関数

$$C_n(\Delta) = \frac{2\overline{k} - v}{(n\Delta)^2} \tag{5}$$

を計算する.

4. 異なる時間幅 Δ に対して 1 から 3 を繰り返し,

$$\Delta^* \equiv \arg\min_{\Delta} C_n(\Delta) \tag{6}$$

となる Δ^* を求める.

イベント時系列が静的な定常状態である場合, この手順により求まる最適区間は無限大 (= 時系列の長さそのもの) になる. 一方, バースト現象を起こしやすい非定常状態である場合, バースト現象が発生した時点とそうでない時点とで異なるイベント発生率を示すようなヒストグラムとなるため, 有限の値となる. これを利用して, イベント時系列が定常状態か非定常状態かを判別することが出来る.

2.3 最尤法

イベント時系列に対して Hawkes Process のフィッティングを行うことで, α, β, μ を推定することができる. このパラメータ推定には, Ogata らが提唱した最尤法 [Ogata 78] がよく用いられる. 強度関数 $\lambda(t)$ から解析的に求められる対数尤度を最大化 (= 負の対数尤度を最小化) するようなパラメータ $\boldsymbol{\theta} = (\alpha, \beta, \mu)$ を求めることで, イベント時系列に対するパラメータ推定を行う.

3. 解析

3.1 実験データ

本研究では, Tunnel 株式会社によって運営されている RoomClip[*1] という部屋の写真を投稿する SNS のデータを用いる. データの取得期間は, サービス開始の 2012 年 4 月から 2016 年 6 月の約 4 年間である. 2016 年 6 月時点での RoomClip の基本データとしては, 写真数が 410,391, タグの種類数が 405,484, タグが付与された回数が 8,805,112 である.

RoomClip においても, 投稿する写真への Social Tagging System が採用されている. タグには任意の文字列を指定することができ, 一つの投稿に対して複数のタグを付与することが可能である.

*1 http://roomclip.jp/

3.2 データの選択と前処理

Hawkes Process におけるフィッティングを正しく行うためにはある程度のデータ数が必要となる. 本研究では RoomClip の全タグの中でも 4,000 回以上使用された計 171 個のタグを解析対象とした. これらのタグについて, サービスにおける何番目の投稿で対象のタグが使用されたかを, 各タグの使用を表すイベント時系列データとした. また, パラメータの時間的変化を見る方法として, 全投稿を 30,000 投稿ずつのウィンドウに分け (図 1 参照.), 各タグのウィンドウごとに Hawkes Process のフィッティングを行ない, 2.2 の 1-4 の方法を用いて, 最適な Δ^* を決定した. ただし, ウィンドウ内で 70 回以上使用されなかったデータに関してはフィッティングを行わなかった. また, 区切られたウィンドウの個数は 49 であった.

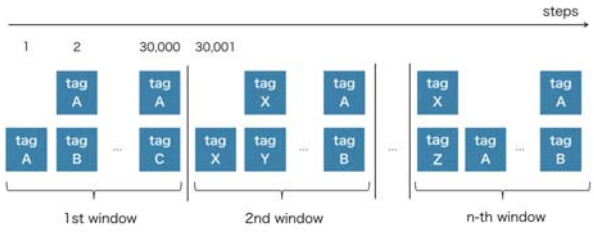


図 1: タグの投稿時系列をウィンドウに区切るイメージ図. 「そのタグが最初の投稿から何番目の投稿か」によってインデックスを振り, 30,000 投稿毎にウィンドウに区切る. 一つの投稿に対して複数のタグが付与されることもあり, その場合はそれぞれのタグに同じインデックスを振る.

3.3 結果と評価

Hawkes Process のフィッティングの評価には, QQ-plot が頻繁に用いられる. Hawkes Process によるフィッティングがうまくいっていれば QQ-plot のプロットは直線 $y = x$ 上に並ぶ. 詳細は省略するが, 本研究においては QQ-plot のプロットが大きく逸脱したものはなく, フィッティングは概ね良好であった. しかし, フィッティングがかなりうまくいっているものもあれば多少ずれているものもあり, タグごとにゆらぎが存在した.

図 2 は, 「リメイクシート」というタグに対して, 投稿数の推移 (上側) と, ウィンドウ毎に分けた投稿時系列の branching ratio の推移 (下側) を示したものである. 左側図中の赤い破線は (3) 式で示したティッピング・ポイントの値である. この「リメイクシート」というタグは, ある時点で爆発的に使用回数が増えていることが確認できる. 一方, branching ratio の値も, その爆発に合わせてティッピング・ポイントを超えた高い値を取っていることがわかり, バースト現象による相転移をうまく捉えていることがわかる.

図 3 は, 各ウィンドウごとの全タグの branching ratio の平均値をプロットした結果である. ここで, タグごとに最適な Δ^* は異なる. SNS では, サービス内のユーザ数, 投稿数が増えるに連れてユーザ間のインタラクションや他ユーザの投稿を目にする機会は増加していくため, サービスが成長するにつれてバースト現象が起こりやすくなる, すなわち branching ratio の値も上昇していくのではないかと予想したが, 平均としての結果は 0.15 程度に収まることが分かった. これに対して, 各写真への ‘ Like ’ を時系列とした branching ratio の計算では, サービスの成長とともに branching ratio が臨界的に漸近するという結果になった [Oka 17][Ikegami 17]. これは, サー

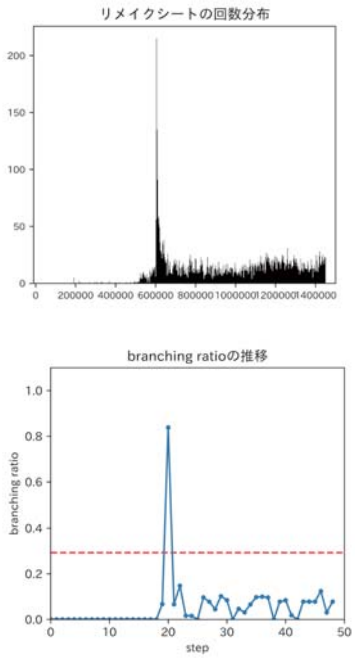


図 2: タグ「リメイクシート」の投稿数の推移 (上側) と, branching ratio のウィンドウ毎の推移. 赤い破線は (3) 式の値を示す.

ビスの成長と共にユーザ数が増え, 投稿はしないが Like は行うユーザ行動が反映されていると考えられる.

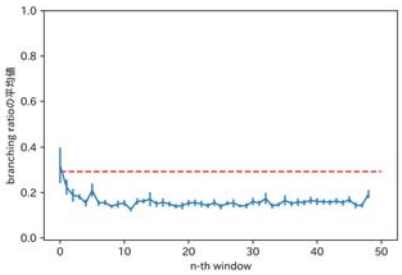


図 3: 各ウィンドウごとの全タグの branching ratio の平均値の変化. 青い線が branching ratio の平均値を示しておりエラーバーは分散を示している. 赤い破線は (3) 式のティッピング・ポイントの値である. 各ウィンドウ間でオーバーラップはさせず, 49 のウィンドウそれぞれに含まれるタグに対して計算を行っている.

図 4 は, 対象となる全タグについて, 横軸に 10 ウィンドウごとの branching ratio, 縦軸に最適区間幅 Δ^* の逆数をプロットした結果である. 時系列が定常状態であれば, 最適区間幅は無限大になるため, 逆数の値は 0 に近づく. 逆に, バースト現象が起こりやすい非定常状態では, 最適区間幅は有限の値にあんるため, 逆数の値は 0 から離れていく. 図中の赤の破線は, (3) 式で表したティッピング・ポイントの値を示しており, この破線の右側ではプロットが 0 から離れた場所にあることが分かる. これより, 実データに対しても $n > 0.2929\cdots$ となる時系列においては, 非定常状態になっており, 逆に, 破線の左側では, プロットは 0 付近に密集していることが分かり, 定常状態から非定常状態への相転移を確認することができた. 一方で, 時系列をウィンドウごとに区切ることによってサービスの開始初期から時間が経った後で branching ratio と最適区間幅の逆数との関係について大きな変化は見られなかった. つまり, サービスの成長にともなってユーザ数や投稿数が増えても, branching ratio がティッピング・ポイントを超える割合に大きな変化はなく, バースト現象の発生にはサービスの成長度合いはあまり関係ない可能性が示唆される.

表 1 に, 各タグについて branching ratio を計算することができたウィンドウに対して, (3) 式のティッピング・ポイントを超えた回数の割合を計算した結果を示す. 「クリスマス」「ハロウィン」など, 季節性のあるタグは, branching ratio の値がティッピング・ポイントの値を超える割合が非常に高いことが分かる. また, その他にも「男前」「RC 愛知」「子供と暮らす。」など, RoomClip のユーザ独自のタグも割合が比較的高い. 一方, 「 ベランダ」「収納」など, 部屋に関連する基本的なタグは割合が低いことがわかる.

表 1: branching ratio がティッピング・ポイントを超えた割合.

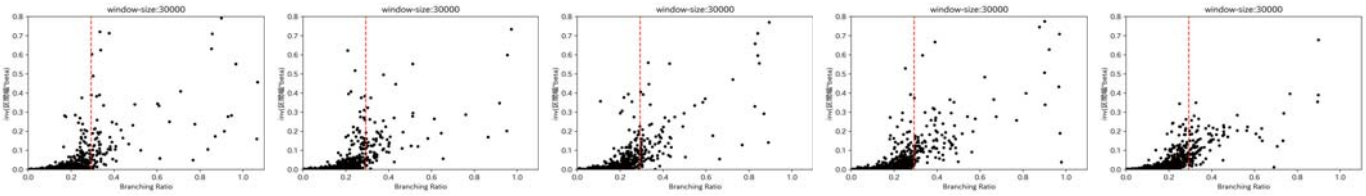
割合	タグの種類数	タグの例
10% 以下	124	ベランダ, 収納
11 - 20%	27	多肉植物, 西海岸
21 - 30%	9	男前, RC 愛知
31 - 50%	6	こどもと暮らす。
51 % 以上	5	クリスマス, ハロウィン

4. おわりに

4.1 まとめと考察

本研究では, SNS における Social Tagging System に着目し, そこから得られる実データに対して Hawkes Process によるフィッティングを行い, branching ratio の時間的変化を追うためにイベント時系列をウィンドウに区切った解析を行った. サービスの成長に伴い, バースト現象の増加, すなわち branching ratio も増加していくものと予想していたが, 結果として大きな相関は見られず, サービスの期間を通してほぼ一定であることが分かった. 一方で, 季節性のあるタグや, RoomClip 独自のタグなどは, branching ratio がティッピング・ポイントを超える割合が高いことが分かった. これは, 「部屋の写真を投稿する」という RoomClip の特性上, クリスマスなどのイベント事にはそのテーマに沿った家具やインテリアが配置された写真が多くのユーザによって局所的に投稿されるためであると推測できる.

また, 三宅らの研究 [三宅 18] においても, SNS 上の実データに対して Hawkes Process を用いて定常状態から非定常状態への相転移を捉えている. 本研究では, [三宅 18] の結果よりもばらつきが大きい結果となった. これは全てのタグに対して同じウィンドウ幅 (= 30,000 投稿) を設定したが, 実際はタグ毎に適切なウィンドウ幅が異なるためであると考えられる. ウィンドウ幅を固定すると, ウィンドウ内で有効となるサンプル数が様々であったり, また一つのバースト現象を同じウィンドウ内で囲みきれなかった場合 (バースト現象が 2 つのウィンドウにまたがってしまった場合) などが原因となり, パラメータ推定がうまく行われなかった可能性が考えられ, 今後はこのウィンドウ幅を QQ-plot による誤差が最小となるようなもの



[1] 1 - 10 ウィンドウ. [2] 11 - 20 ウィンドウ. [3] 21 - 30 ウィンドウ. [4] 31 - 40 ウィンドウ. [4] 41 - 49 ウィンドウ.

図 4: 各ウィンドウにおける branching ratio と最適区間幅の逆数の関係. それぞれのウィンドウに含まれる全タグに関してまとめて表示してある.

に設定していくなどして最適化していくことが必要であると考えている.

4.2 今後の展望

複数のイベント時系列間のダイナミクスを考慮した多次元 Hawkes Process においても, 対象としているイベント時系列のうち少なくとも一つのイベント時系列が定常状態から非定常状態へと相転移する条件の閾値は, 以下の様に表されることが知られている [Onaga 14].

$$\max_i(\boldsymbol{C}\boldsymbol{\Lambda}\boldsymbol{C}^T\boldsymbol{\Lambda}^{-1})_{ii} > 2 \tag{7}$$

この閾値は, fluctuation condition と呼ばれる.

これに対して三宅らの計算 [三宅 18] では, ユーザ同士のフォロー・フォロワーネットワークを考え, 投稿に対する Like のやり取りに着目している. ネットワーク中の各ユーザの Like のイベント時系列に対する branchign ratio の最大成分の値は, fluctuation condition < 2 の場合は 0.29 未満であるのに対して, fluctuation condition > 2 の場合は 0.30 を超えている. 両者の fluctuation condition の差はこの値の違いによる部分が大きいと考えられる. 一方で, ネットワーク内の各ユーザに対する branching ratio の行列の各成分を見てみると, 高い非定常性示したネットワークでは非対角成分でも比較的高い値を持つものが確認できるが, 高い定常性を示したネットワークでは対角成分以外では全て低い値を取っている. この非対角成分に関する差が, Hawkes Process によって求められる fluctuation condition と最適区間幅推定によって得られる非定常性との不整合の原因となっているのではないかと考え, 特にこの不整合性の大きいいくつかのネットワークについての非対角成分の分布を比較しているが, 全体として特に差は見られていない.

本研究では今後, タグをノード, タグ同士の共起関係をエッジとするようなネットワークを考えることによって, 複数のタグ同士の関係性, 影響度を考慮したバースト現象分析を行うことができると考えている. また, ネットワーク中のエッジの有無を操作することによって, バースト現象を引き起こしたり, あるいは抑制したりすることができることがシミュレーションにより明らかになっている. 今後の実験では, タグの共起関係ネットワークにおいてこのようなエッジの操作を行うことによってバースト現象に関するシミュレーションも行いたいと考えている.

謝辞

解析に用いた貴重なデータを提供頂いた, Tunnel 株式会社の皆様に感謝致します. 本研究は JSPS 科研費 15K00420 の助成を受けたものです.

参考文献

[Oka 15] Oka, M., Hashimoto, Y. and Ikegami, T.: Open-ended evolution in a web system. In Late breaking papers at the European Con- ference on Artificial Life, pp. 17. (2015)

[Hawkes 71] Hawkes, A. G.: Point spectra of some mutually exciting point processes. Journal of the Royal Statistical Society. Series B (Method- ological), pp. 438-443. (1971)

[Onaga 14] Onaga, T. and Shinomoto, S.: Bursting transition in a linear self-exciting point process. Physical Review E, 89(3), 042817. (2014)

[Shimazaki 07] Shimazaki, H., and Shinomoto, S.: In A Method for Selecting the Bin Size of a Time Histogram, Neural computation, 19(6), pp. 1503-1527. (2007)

[Ogata 78] Ogata, Y.: The asymptotic behaviour of maximum likelihood estimators for station- ary point processes. Annals of the Institute of Statistical Mathematics, 30(1), pp. 243-261. (1978)

[Oka 17] Oka Mizuki, Hashimoto Yasuhiro, Ikegami Takashi: Understanding evolutionary dynamics in online social networks. In Proc. of IEEE ALIFE 2017, DOI 10.1109/SSCI.2017.8280796, pp. 1-5. (2017)

[Ikegami 17] Takashi Ikegami, Mizuki Oka, Yasuhiro Hashimoto, Yoichi Mototake: Life as an Emergent Phenomenon, Studies From Large-Scale Boid Simulation and Web Data, Philosophical Transactions A of the Royal Society, 375.20160351. (2017)

[三宅 17] 三雅雅矩, 池上高志, 岡瑞起, 橋本康弘: Hawkes Process と最適区間幅推定を用いた Web Data の解析. 人工知能学会全国大会 (2017)

[三宅 18] 三宅雅矩: Hawkes 過程を用いた Web データにおける相転移現象の解析. 東京大学大学院総合文化研究科広域科学専攻, 平成 29 年度修士論文 (2018)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

ソーシャルメディア上のコミュニティ形成に対して個人の性格が与える影響

Analyzing the influence of human personality on SNS community formation

鈴木 凱亜 *1 Gaia Suzuki　大知 正直 *1 Masanao Ochi　榊 剛史 *1 Takeshi Sakaki　坂田 一郎 *1 Ichiro Sakata

*1東京大学 工学系研究科
School of Engineering, The University of Tokyo

With its huge spread in daily life, social media is now a big platform to make new human relationships. While recent research identified the relationship between users' personality traits and how individual users behave on social media, knowledge about how personality traits affect users' mutual interactions is limited. This research proposes a method to relate human personality to community formation on social media. By applying this method to Twitter data, it was inferred that personality factors such as gregariousness, conscientiousness, cheerfulness shows a "homophilous" tendency. This means that similarity in these personality traits breeds user connection. Furthermore, we investigated the relationship between community's composition of personality and community dynamics(size, activeness). Analysis by the proposed method may contribute to creating a social matching system with better user satisfaction.

1. はじめに

ソーシャルメディア上の人々の関わり合いは，今後ますます発展し多様化すると見込まれる．そのような環境下において，ソーシャルメディア上のコミュニティ形成のメカニズムを把握することは，人々の関わり合いを通してユーザが得られる効用や，チームワークが生み出すパフォーマンスを最大化するために必要不可欠である．本研究では，ユーザの特徴がその所属するコミュニティの挙動とどのように関係するかを分析する．SNS ユーザは，投稿の文面に表出される互いの性格を見て交流の取捨選択を行う、という仮定のもと、「ユーザの性格」がコミュニティ形成にどのような影響を与えるか考える．

そもそもソーシャルメディア上の人々のつながりに影響を与える要因は「ユーザの性格」以外にも,「ユーザの属性」、そして「ユーザの思想・感情」があると考える．McPherson らはネットワークにおいて「共通の属性を持つ人同士が繋がりやすい」，Homophily と呼ばれる傾向に着目した．そして，様々な社会ネットワークで民族や人種，宗教といった「ユーザの属性」が Homophily な傾向を示す，すなわち似た者同士でコミュニティを形成しやすいことを確認した [McPherson 01]．他方で「ユーザの思想・感情」によるコミュニティ形成の例として，ソーシャルメディア上で偏った意見を持つ人々が集まり，そのグループの中でその声が反芻されることで意見が過激化・極端化する，Echo Chamber と呼ばれる現象も知られている．「ユーザの性格」によるコミュニティ形成については，他の 2 つの要因と比較して小さなスケールでのネットワークダイナミクスであること，そして定量化された性格データの取得が困難であったことから，研究例が少ない．

本論文の目的は，SNS の会話ネットワークにおいて，どのような性格同士のユーザが活発に会話を行うグループを形成するか，コミュニティの形成や挙動と構成員の性格との関係を分析することである．これにより得られる知見は，SNS 上のチームビルディングの最適化や，より相性の良い人とつながる SNS プラットフォームの設計などの応用が期待される．

連絡先: 鈴木 凱亜，東京大学大学院工学系研究科，東京都文京区本郷 7-3-1 工学部 3 号館， gaiaapr23@gmail.com

2. 関連研究

心理学の分野では，人間の性格と行動との相関を分析した研究が広くなされている．そういった研究において性格を捉える枠組みとしてスタンダードになっているのが，ビッグファイブと呼ばれる性格因子である．これは，性格を「Openness（知的好奇心）」,「Conscientiousness（誠実性）」,「Extraversion（外向性）」,「Agreeableness（協調性）」,「Emotional range（感情起伏）」の 5 つの性格特性のスコアの組み合わせにより座標的に表現する枠組みであり，これは文化圏などによらないユニバーサルなものである [McCrae 97]．性格特性のスコアは，被験者への心理テストによって得られる．

性格の異なるユーザの SNS 上の行動の違いを捉える研究手法として，分析対象を定量的な指標で表し，上記の性格特性のスコアとの相関係数を計算するというものがある．Ryan らは Openness（知的好奇心）のスコアが高い人ほど SNS への積極的なコミットが見られることを示し [Ryan 11]，Skues らもそのような人ほど友人を多くもつ傾向にあるとした [Skues 12]．また，Seidman らは Agreeableness（協調性）のスコアが高い人ほど返信など他人に向けた積極的なアプローチを行う傾向にあることを示した．

複数人の性格の組み合わせを捉えるとき，性格スコアの単純な平均値に加え，分散や最大値・最小値などもグループの性格の分布を見るための重要なパラメータとなる．Barrick らは，チームによる仕事のパフォーマンスとメンバーの性格の関係を分析するために，チームごとの性格スコアの平均や分散，最大値・最小値と，チームパフォーマンスの相関係数を計算し，0.23 以上の高い相関を示す関係を有意なものとして抽出した．その結果，Conscientiousness（誠実性）が平均的に高いチームほど仕事が優秀な傾向が見られるが，チーム内で Consceintiousness（誠実性）のばらつきが大きいとパフォーマンスは低下してしまうことを発見した [Barrick 98]．

3. 提案手法

提案手法の概略

SNS 上のネットワークダイナミクスに対する性格の影響を見る際に考慮しなければならないのが,「ユーザの性格」以外の要因によるつながりの存在である．純粋に性格が与える影響を捉えるためには，上述した「ユーザの属性」,「ユーザの感情・思想」による影響を区別し取り除いたネットワークを考える必要がある．

そこで本論文では，同じトピックに属するユーザを投稿のクエリ検索によって抽出し，興味分野やトピックに対する見解が共通したユーザによる会話ネットワーク（以下，トピックネットワークと呼ぶ）を構築する．適切なクエリの選択により，「ユーザの属性」と「ユーザの思想・感情」をできる限り統制したトピックネットワークの構築が可能であると考える．そして，このトピックネットワークの中で，ユーザの性格推定，クラスタリング，分析指標との相関分析などを行うことを提案する（図 1）．

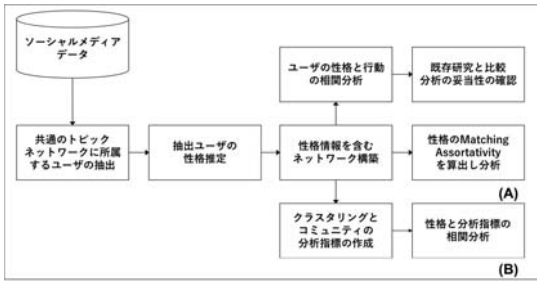


図 1: 分析のフレームワーク

3.1 ユーザの性格推定

近年，ビッグファイブを心理テストでなく SNS の投稿データのテキスト分析により推定する研究が進んでいる．たとえば IBM Watson は，ユーザの SNS 投稿データからビッグファイブと、それぞれの小分類（ファセット）にあたる計 35 種類の性格特性のスコアを推定するモデルを API として公開している．それぞれの性格特性について，具体的な説明は脚注の URL を参照されたい [*1]．この Personality Insights API は日本語の投稿にも対応しており，伝統的な心理テストにより計算された実スコアと 0.2 程度の比較的高い相関を示すことから，本論文の実験でもこのサービスを用いる．取得可能なデータから性格が計算できるようになると，被験者を集め心理テストを実施する必要がなくなり，より多様なユーザデータを用いた分析が可能になる．

3.2 クラスタリングによるコミュニティ抽出

構築したユーザ間会話ネットワークから，活発に会話を行うグループを抽出するために，Louvain 法 [Blondel 08] を用いたモジュラリティ最大化によるネットワークのクラスタリングを行う．この手法により，分割数を指定することなく重み付きネットワークをつながりの密なグループに分割することができる．本研究では，得られたクラスタのうち 10 人以上のものを分析対象のコミュニティとした．

*1 https://console.bluemix.net/docs/services/personality-insights/models.html

3.3 Homophily な性格特性の確認

スコアの近いもの同士がつながりやすいような，Homophily な性格特性が存在するかを確認するため，ネットワーク上でリンクを結ぶノード同士の属性値がどのくらい似ているかを捉える指標である Matching Assortativity[Newman 03] を計算する．これは 0 から 1 の値を取り，大きくなるほどノードの属性の近いもの同士がつながったネットワークであることを示す．

3.4 分析指標とユーザの性格の相関分析

本研究で用いる分析指標を表 1 に示す．ユーザ行動の分析指標はユーザの 35 種類の性格特性との相関係数を，コミュニティの分析指標は所属するユーザの性格特性の平均値，標準偏差との間の相関係数を計算する．前述した Barrick らの研究で 0.23 以上の相関があるものを取り上げていたことや，Personality Insights API の推定結果と実スコアの間の相関が 0.2 程度であることをふまえると，本研究においてもあまり大きな相関係数は期待されない．そこで，他の性格指標と比較し相対的に大きな相関を示し，作成したどのトピックネットワークにおいても一貫してその相関が見られるような関係を取り上げる．

表 1: 本研究で使用する分析指標

分析指標の種類	指標	説明
ユーザ行動の評価	投稿の頻度	1 日あたりの投稿数
	リプライ率	投稿内の返信の割合
コミュニティの評価	ユーザ数	コミュニティの人数
	活性度	コミュニティ内の会話の増加率

4. 実験

4.1 トピックネットワークの抽出

本実験では，トピックネットワークの抽出に Twitter のハッシュタグ検索機能を用いた．ハッシュタグの種類を適切に選択することで，同一の話題に関して，お互いに積極的に話しかける密なトピックネットワークの抽出が可能となる．そこで，表 2 に示す 4 種類のトピックに関するハッシュタグ検索により取得されたツイートから，それぞれのトピックネットワークを構成するユーザを抽出した．表 2 にあるようなハッシュタグのユーザは，共通してトピックに対する興味を持ち，共通して「同じ趣味を持つ人間と繋がりたい」というモチベーションを持つため，繋がりを形成する最終的な決め手が性格的な相性になりやすいと考える．

表 2: 作成したトピックネットワーク

トピックネットワーク	検索ハッシュタグの例
ファッション	#おしゃれさんと繋がりたい
映画	#映画好きと繋がりたい
イラスト	#絵師さんと繋がりたい
他者依存	#メンヘラさんと繋がりたい

4.2 ネットワークの構築とクラスタリング

ハッシュタグにより抽出したユーザの全ツイート（最大で 2000 ツイート）を取得し，その投稿データをもとに Personality Insights API によって 35 種類の性格特性のスコアを計算した．また，取得したツイートからネットワーク内のメンション関係を抽出し，性格特性のスコアを属性として持つノードと，会話

の回数を重みとして持つリンクによるトピックネットワークを構築した．

構築したネットワークから提案手法のクラスタリングを用い分析対象のコミュニティを抽出した．各ネットワークの基本情報，抽出されたコミュニティの数は表 3 の通り．

表 3: 構築したネットワーク

トピック	ノード	リンク	コミュニティ数
ファッション	923	742	12
映画	490	623	8
イラスト	947	662	16
他者依存	916	1575	19

4.3 分析の妥当性の検証

そもそも日本語のツイートから，外部モデルにより性格を推定し，それを前提に議論を行うことに妥当性はあるか，実際の分析を行う前に検証した．関連研究で述べたように，SNS への積極性的なコミットには Openness（知的好奇心）の高さが，他人に向けた投稿をする傾向には Agreeableness（協調性）の高さが関わると思われる．

そこで，それぞれを表す指標として，「1 日あたりの投稿数（投稿の頻度）」と「全投稿に対するメンション投稿の割合（リプライ率）」をユーザごとに計算し，Openness（知的好奇心），Agreeableness（協調性）との相関を計算した．結果は表 4 の通りである．

相関の値は高くないが，4 つのネットワーク共に一貫して 0.1 付近の相関係数を示し，また他の性格特性と比較すると相対的に高い相関を示した．大きな相関は確認されなかったが，既存研究と矛盾しないため，本分析を行うことは有意義であると考える．

表 4: 性格特性とユーザ行動の相関関係

性格の種類	Openness	Agreeableness
ユーザ行動の分析指標	投稿の頻度	リプライ率
相関係数の平均	0.12	0.13
35 性格中のスコアの順位	1 位	7 位

4.4 分析指標の作成とコミュニティ形成の分析

本研究では二種類の分析を行う．

(A) コミュニティの形成過程と性格の関係の分析

会話ネットワークの Matching Assortativity を各性格特性について計算することで，コミュニティの形成過程において，「ユーザの属性」や「ユーザの思想・感情」で見られる Homophily な傾向が，性格特性についても見られるか分析した．

(B) 形成されたコミュニティの挙動と性格の関係の分析

コミュニティのふるまいを測る指標として「コミュニティの規模（ユーザ数）」と，「コミュニティの活性度（一人当たりの会話の増加率）」を計算し，コミュニティ内の性格特性の平均値，標準偏差との相関を算出した．

5. 結果および考察

(A) コミュニティの形成過程と性格の関係の分析

それぞれの性格特性の各トピックネットワークにおける Matching Assortativity の平均値を計算した．Matching Assortativity が相対的に大きい 3 つの性格特性を表 5 に示す．

分析結果から，Gregariousness（社交性）や，Conscientiousness（誠実性），Cheerfulness（明朗性）にはスコアの高い人は高い人同士で，低い人は低い人同士で繋がりやすい Homophily な傾向があると思われる．これらの性格特性は，自らと反対の傾向を持つ人との交流がストレスを生むのではないかと思われる．人々がそういったストレスを回避しようとした結果，コミュニティ形成において Homophily な傾向が見られていると推測される．

この研究結果は，関連研究で述べたチーム内の Conscientiousness（誠実性）のばらつきがパフォーマンスの低下を招くことと整合する．誠実性の差は，互いの仕事への姿勢や自制力の差に対する不満やストレスにつながり，人々の結束を低下させると考える．

表 5: Matching Assortativity の大きな性格特性

性格特性の種類	Matching Assortativity
Gregariousness（社交性）	0.260
Conscientiousness（誠実性）	0.225
Cheerfulness（明朗性）	0.195

(B) 形成されたコミュニティの挙動と性格の関係の分析

「コミュニティの規模」，「コミュニティの活性度」のそれぞれのコミュニティの挙動について，相関関係が 0.2 以上であり，各トピックネットワークについて一貫しているような性格特性の平均値や標準偏差を表 6，7 に示す．

「コミュニティの規模」については，Prone to Worry（心配性），Melancholy（悲観的）のような性格特性が正の相関を示すことが分かった．これらの性格特性のスコアが高い人は，他人との関わりによって心の安定を図るため，できる限り多くの相手と関わりを作ろうとし，その結果コミュニティの規模が大きくなると推測される．

「コミュニティの活性度」について，Emotional Range（感情起伏）や Uncompromising（強硬さ）の標準偏差が小さく，Dutifulness（忠実さ），Self-efficacy（自己効力感），Melancholy（悲観的）の標準偏差が大きいほど，コミュニティ内で活発な会話がなされることが分かった．

この結果から，他人への接し方に関わる性格特性は画一的で，自分のあり方に関わる性格特性は多様性に富んでいるコミュニティであることが，活発な会話につながっていると示唆された．

表 6: コミュニティのふるまいと正の相関を示す性格特性

コミュニティの規模	コミュニティの活性度
Prone to Worry（平均値）	Dutifulness（標準偏差）
Melancholy（平均値）	Self-efficacy（標準偏差）
	Melancholy（標準偏差）

表 7: コミュニティのふるまいと負の相関を示す性格特性

コミュニティの規模	コミュニティの活性度
該当なし	Emotional Range（標準偏差）
	Uncompromising（標準偏差）

6. おわりに

本研究では，日本語の SNS 投稿データとテキスト性格推定モデルを用い，SNS 上のコミュニティ形成に性格がどう関わるか分析した．興味を統一したユーザの抽出という提案手法により，既存研究と矛盾しない分析ができることが確認され，また Homophily な作用が見受けられる性格の存在を確認した．提案した分析のフレームワークを用い，コミュニティ形成のメカニズムに関し新たな知見が得られる可能性を提示した．

今後の展望としては，ユーザの抽出方法の改善と，性格推定モデルの精度の向上が挙げられる．

ユーザの抽出方法について，本研究で抽出した twitter ネットワークは条件を満たすハッシュタグの選択が難しかったため，twitter コミュニティ全体の中で非常に限定的なものであった．そこで，より多くのトピックネットワークを構築できるユーザ抽出方法の考案，もしくはユーザの「属性」や「思想・感情」も特徴量に含めた包括的なコミュニティ形成モデルの議論が望まれる．

性格推定モデルについては，ユーザの投稿テキストのみでなく，プロフィールデータや投稿画像データなども特徴量とすることで，より高い精度の性格推定が可能であることが英語の SNS データでは明らかになっている [Azucar 18]．本研究で行った相関分析では，0.2 以上の相関を示す関係は非常に少なく，より説得力のある議論を行うためには，日本語のデータにおいても性格推定の精度を高める必要があると思われる．

参考文献

[McPherson 01] McPherson, M., Smith-Lovin, L., and Cook, J. M.: Birds of a feather: Homophily in social networks, *Annual review of sociology*, Vol. 27, No. 1, pp. 415-444 (2001)

[McCrae 97] McCrae, R. R., and Costa Jr, P. T.: Personality trait structure as a human universal, *American psychologist*, Vol. 52, No. 5, pp. 509 (1997)

[Ryan 11] Ryan, T., and Xenos, S.: Who uses Facebook? An investigation into the relationship between the Big Five, shyness, narcissism, loneliness, and Facebook usage, *Computers in human behavior*, Vol. 27, No. 5, pp. 1658-1664 (2011)

[Skues 12] Skues, J. L., Williams, B., and Wise, L.: The effects of personality traits, self-esteem, loneliness, and narcissism on Facebook use among university students, *Computers in Human Behavior*, Vol. 28, No. 6, pp. 2414-2419 (2012)

[Seidman 13] Seidman, G.: Self-presentation and belonging on Facebook: How personality influences social media use and motivations, *Personality and Individual Differences*, Vol. 54, No. 3, pp. 402-407 (2013)

[Barrick 98] Barrick, M. R., Stewart, G. L., Neubert, M. J., and Mount, M. K.: Relating member ability and personality to work-team processes and team effectiveness, *Journal of applied psychology*, Vol. 83, No. 3, pp. 377 (1998)

[Blondel 08] Blondel, V. D., Guillaume, J. L., Lambiotte, R., and Lefebvre, E.: Fast unfolding of communities in large networks, *Journal of statistical mechanics: theory and experiment*, Vol. 2008, No. 10 (2008)

[Newman 03] Newman, M. E.: Mixing patterns in networks, *Physical Review E*, Vol. 67, No. 2 (2003)

[Azucar 18] Azucar, D., Marengo, D., and Settanni, M.: Predicting the Big 5 personality traits from digital footprints on social media: A meta-analysis, *Personality and Individual Differences*, Vol. 124, pp. 150-159 (2018)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

動的関係ネットワークを用いた
フェイクニュース判定システムの為の評価モデル
An Evaluation System for Credibility of Fake News using Dynamic Relational Networks

藏屋 沙那恵[*1]
Sanae Kuraya

石田好輝[*1]
Second Author's Name

[*1] 豊橋技術科学大学　情報・知能工学科
Toyohashi University of Technology
Department of Computer Science and Engineering

This study aims to construct a system to support evaluating credibility of fake news. We proposed a credibility evaluating model using dynamic relationship network which dynamically determines credibility by relative consistency. This credibility evaluation model consists of a *conclusion node* representing the truth and false of the article and a *fact node* having information of 5W1H. For evaluation of the crudities model, we evaluated the network using non-fake news and fake news. As a result, it is possible to identify unreliable information from the fact node, and the conclusion node. It was also known found that the trend of the article can be inferred.

1. はじめに

近年，ニュースを得る手段として Web の利用が増加している[総務省]. Web 上の情報には，匿名での情報発信が可能であるという特性上，信用度の低い情報が含まれる. それに対して，ページのランク付けや第 3 者によるチェックが行われている. しかし，チェックされた内容が反映される前に情報を閲覧することがあるため，個人で情報の信用性を判断することが必要である.

本研究では，フェイクニュースの判定を補助するシステムの構築を目指し，信用度を相対的整合性により動的に決める動的関係ネットワーク(Dynamic Relational Network)を用いた信用度評価モデルを提案する.

2. 動的関係ネットワーク

動的関係ネットワークネットワークは Web 上のリンク構造や人間関係のように，時間経過によって構造が動的に変化するネットワークである. 動的関係ネットワークは有向グラフに基づき，ネットワーク上のノードが互いの持つ値を信用可能であるか評価する[Ishida] . 評価はノード間に配置されるアークによって行う. アークには二つのノード i, j が有する値の関係によって正または負の値を設定し，正の場合は整合，負の場合は矛盾を意味する. 一方，動的関係ネットワークのノード i は実数の信用度 $R_i(t) \in [0, 1]$を持つ. 信用度はノードの有する値がどの程度信用可能かを示す値で，1 に近いほど信用でき，ネットワーク上ではノードが活性化する.

3. 提案モデル

ヒトがニュース記事の真偽を判断する際，他の記事や知識と比較し，食い違いの有無を確認することで判断しているのではないかと仮定する. 事実関係を相対的に判断し整合性を求めることが可能な動的関係ネットワークを用いる. 動的関係ネットワークは有向グラフに基づき，ノードが他のノードの持つ値を信用できるか相互に評価するモデルである.

提案手法では，1 つの結論ノードと最大 6 個の事実ノードの集合で構成される記事ユニットを用いてネットワークを構成する. 結論ノードは，事実情報の評価値によって最終的に信用度を評価するノードである. また，事実ノードは，5W1H の情報をラベルとして持つ. まず，評価したい記事の信用度を算出するための結論ノードを配置する. 次に，評価したい記事の事実（5W1H に関する内容）をラベルとした，事実ノードを配置する. その後，結論ノードと事実ノードの間にアークを生成する. 続いて、その記事のタイトルに含まれる単語を用いて検索エンジンで検索を行い，関連記事として記事ユニットを設置する. 同じ種類のラベルを持つ事実ノードの間にアークを生成し，時間経過で信用度を求める. 最終的に時間経過によって収束した各ノードの信用度を結果とする.

3.1 結論ノード

結論ノードは，事実情報の評価値によって最終的に信用度を評価するノードである. このノードは，事実ノードと正の双方向アークによって繋がれる.

配置したノードの信用度について初期値を設定する必要がある. 本研究では，設置する段階でのニュース記事はすべて正しいと仮定して，初期信用度は最大値である 1 を与える. また，ラベルとして「『記事名』で述べられている内容は真実である」を持つ.

3.2 事実ノード

事実ノードはニュースの中で事実だと報じられている内容(5W1H)をラベルとして持ち，そのラベルの信用度を評価するノードである. 事実ノードは，同じ種類のラベルを持つノードの間に双方向のアークが置かれる. このとき，ラベルの内容が同じ場合は正のアーク，内容が異なる場合は負のアークが設置される. 同じ配置したノードの信用度について初期値を設定する必要がある. 本研究では，設置する段階でのニュース記事はすべて正しいと仮定して，初期信用度は最大値である 1 を与える.

連絡先：kuraya@sys.cs.tut.ac.jp

3.3 記事ユニット

記事ユニットは，動的関係ネットワークのノードより図 3.1 のような構造を持つ最大 6 個のノードで構成される．6 個のノードのうち 1 つは結論ノード，他の 5 つは事実ノードである．

4. 実験方法

提案モデルを用いてネットワークを作成し，信用度を得られるかニュースの内容と比較して評価を行う．ニュースは，通常のニュースと数種類のフェイクニュース[2]を用いる．評価方法は，まず，評価したいニュース記事のタイトルを用いて検索エンジンより記事を 10 件取得する．このとき，動画やリンク集など 5W1H が文章から抽出できないページは除外する．取得した記事より，ネットワークを生成し， 時間経過によるシミュレーションを行う．評価したい記事を A1 とし，他のノードと比較することで評価する．

4.1 使用するフェイクニュースの種類

Rubin らはフェイクニュースを文章解析によって抽出するために意図的に作られたフェイクニュースの種類を分類している[Victoria]．意図的に作られたフェイクニュースは 3 項目に分けられると述べている．また，研究団体 First Draft News に所属する Claire Wardle は誤情報や，不正確な情報もフェイクニュースに含まれるとしている[Claire]．

本研究では，立場によって事実が異なる政治的なニュースや思想操作が関与してくるフェイクニュースを用いない．そのため，今回は以下に示す 3 種類のフェイクニュースを用いて検証を行う．

- 大規模なデマ：意図的に作成された，もしくは事実のミスリーディングや根拠のない情報を付け足された情報，広く拡散されることが目的
- ユーモラスなフェイク：風刺や存在しないジョークニュース，悪意はない
- 誤りを含むニュース：誤情報や不正確な情報が含まれるニュース

5. 評価実験

5.1 通常のニュースに対するシミュレーション

通常のニュースに対するシミュレーションのニュース記事は例として「給食の牛乳に“異臭”新宿区で児童ら 1300 人訴える」を用いた．各ノードの値を表 1, 2 に示す

実験結果は，評価を行いたい A1 の各ノード値を見ると，R2, R3 は高い信用度を得られた．また，R4 と R5 は，R1 から R3 と比較すると低めの値であることを確認できた．

結果より，事件が起きた場所や時間は基本的に共通するため信用度が高く，記事毎に対象としている範囲が異なる Who や What は差異がでやすいことがわかった．これらより，事実ノードの信用度から，信用できない情報の特定が可能だと考える．

問題点として，現段階では結論ノードの値が高くても A1 の記事が正しいと断定できないことがあげられる．理由として，フェイク記事が正しい記事として多く集まった場合信用度が高くなるからである．また，評価したい記事と内容の大きくことなる記事も信用度が低くなるためである．

表1. 通常の記事での各ノードの信用度 A1～A5

	A1	A2	A3	A4	A5
R1：結論	0.88	0.88	0.5	0.5	0.882
R2：When	1	1	0	0	1
R3：Where	1	1	0	0	1
R4：Who	0.659	0.74	0.583	0.588	0.74
R5：What	0.716	0.719	0.005	0.084	0.719

表2. 通常の記事での各ノードの信用度 A6～A10

	A6	A7	A8	A9	A10
R1：結論	0.882	0.88	0.88	0.88	0.88
R2：When	1	1	1	1	1
R3：Where	0.999	0.999	0.999	0.999	1
R4：Who	0.74	×	0.726	0.73	0.659
R5：What	0.722	0.711	0.724	0.732	0.704

5.2 フェイクニュースに対するシミュレーション

実際にフェイクニュースが入力されたとき，どのような値になるか検証するため，意図的にフェイクニュースを用いて評価を行う．

拡散を目的とした大規模なデマに分類される記事のシミュレーション結果を表 3 に示す．記事は「クーポンを出したら最初に出さないと料理の量を減らせないと言われた」を用いた．誤情報を含むニュースに分類される記事のシミュレーション結果を表 4 に示す．記事は「Dropbox はどうやって著作権侵害ファイルを特定しているの？」を用いた．ジョークニュースに分類される記事のシミュレーション結果を表 5, 6 に示す．記事は「琵琶湖で 1 メートル超の人魚釣れる人魚拓も展示」を用いた．

大規模なデマに分類されるニュースのシミュレーション結果は，事実ノード，結論ノードどちらも極端に低い値が得られた．また，他の記事と信用度が同値であった．

誤情報を含むニュースに分類されるシミュレーション結果は，結論ノード，事実ノードの値が一番高くなった．

風刺やジョークに対するシミュレーション結果は，結論ノード，事実ノードの値が低めで，他の記事と信用度が近い値が得られた．

表3. 大規模なデマに分類される記事の各ノード値

	A1	A2	A3
R1：結論	0	0	0
R2：When	0	0	0
R3：Who	0	0	0
R4：What	0	0	0

表4. 誤情報に分類される記事の各ノード値

	A1	A2	A3	A4
R1：結論	0.941	0.874	0.941	0.729
R2：Who	0.98	0.97	0.98	0.97
R3：What	0.944	0.94	0.944	0
R4：How	0.847	0.013	0.847	0.012

表5ジョークニュースでの各ノードの信用度 A1～A5

	A1	A2	A3	A4	A5
R1：結論	0.5	0.5	0.5	0.5	0.5
R2：When	0.705	0.72	0.72	0.72	0.72
R3：Where	0.705	0.72	0.72	0.72	0.72
R4：Who	0.705	0.72	0.72	0.72	0.72
R5：What	0.705	0.72	0.72	0.72	0.72

表6ジョークニュースでの各ノードの信用度 A6～A10

	A6	A7	A8	A9	A10
R1：結論	0.5	0.5	0.5	0.5	0.5
R2：When	0.703	0.495	0.72	×	×
R3：Where	0.703	0.495	0.72	×	×
R4：Who	0.703	0.495	0.72	0.69	0.69
R5：What	0.703	0.495	0.72	0.69	0.69

これより，収集した関連記事の中でも多数派が優位になる，情報がすべてことなる場合信用度が等しく低くなることから，フェイクニュースであるかどうかの断定は難しいことがわかった．

しかし，多数の記事を比較した場合に以下の 2 種類の傾向に分けることができると考えられる．

・大規模なデマやジョークニュースは，結論ノードの値が全体的に低い
・誤情報を持つ記事は部分的に事実ノードの値が低い

6. 考察

結果より，評価したい記事を他の記事と比較した場合，事実ノードの信用度により，信用できない情報の特定が可能であることがわかった．また，基準の記事と同じ内容が多数存在する場合信用度が高くなる．このことから，現段階ではフェイクニュースかどうか断定することは難しいと考える．理由として，フェイクかどうか断定するための情報が不足していることが考えられる．そのため，ライターの情報や天気予報のような観測データなど，5W1H 以外の情報を用いることを検討する必要がある．

フェイクニュースを用いたシミュレーションを比較した結果，以下の傾向が見られた．

・大規模なデマやジョークニュースは，事実ノードの信用度が低い
・誤りのある記事は一部事実ノードの信用度が低い

傾向を，シミュレーションの際に結論ノードへ反映することで，フェイクの判定に寄与できるのではないかと考える．

7. まとめ

本研究では、フェイクニュースの判定を補助するシステムの構築を目指し，信用度を相対的整合性により動的に決める動的関係ネットワークを用いた信用度評価モデルを提案した．

信用度評価モデルの評価のために，提案モデルを用いてネットワークを構築し，評価した．その結果，事実ノードより，信用できない情報の特定が可能，結論ノードより，記事の傾向が推察可能であることがわかった．

これより，提案モデルを用いたシステムでフェイクニュースの種類の特定が行える可能性があると考える．しかし，情報源が非常に少ない記事で共通する事実がない場合に，信用度での評価が行えないことから，5W1H 以外の事実ノードの追加や推論による人的評価といった検討の余地がある．

参考文献

[総務省 16] 総務省: 平成 28 年情報通信メディアの利用時間と情報行動に関する調査報告書, 2016.

[Ishida 98] 石田好輝, 平山博史, 藤田博之, 石黒章夫, 森一之: 免疫型システムとその応用-免疫系に学んだ知能システム, コロナ社, 1998.

[Victoria 15] Victoria L. Rubin, Yimin Chen and Niall J. Conroy: Deception Detection for News : Three Types of Fakes , Proceedings of the Association for Information Science and Technology , 2015.

[Claire 18] Claire Wardle: 6 types of misinformation circulated this election season, Columbia Journalism Review, https://www.cjr.org/tow_center/6_types_election_fake_news.php(2018/01/15 参照).

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

仮想社会における社会関係とソーシャルサポートに関する一考察

A Considaration of Social Relationships and Social Support in a Virtual Society

高野雅典 *1　水野寛 *1
Masanori Takano　Kan Mizuno

*1株式会社サイバーエージェント
CyberAgent, Inc.

Anonymous online communications more easy to self-disclosure than offline communications. However, Japanese young people's online social relationships tend to include offline social relationships. Therefore, it is important to complement offline social relationships by communication tools which have few offline relationships. For this complementing, we discuss online social support in an avatar chat service "Pigg Party." We marshal user-interview results of application developers of this service from a viewpoint of online social support.

1. はじめに

Web を介したオンラインコミュニケーションはいまや我々の日常生活の一部であり，そこでは様々な相手と様々な相互作用が行われている [総務省 17]．オンラインでの共感・愛着・尊敬や問題解決のための情報・方策を提供することをオンラインソーシャルサポートという [Choudhury 14]．オンライン・オフラインに関わらずソーシャルサポートは人の Well-being・精神的健康に非常に重要である [Turner 14]．

ソーシャルサポートの提供を促すには，受け手が自身の状況や感情を開示（自己開示）する必要がある．Choudhury ら [Choudhury 14] はインターネット掲示板 Reddit の自殺やメンタルヘルスに関連する複数のコミュニティを分析し，ユーザが自己開示をするほど，他者からのオンラインソーシャルサポートの提供を促すことを示した．

自己開示はオンラインコミュニケーションの特徴である匿名性と深く関連する．匿名性の高いコミュニケーションでは，普段話しづらい話題についても話しやすく，ネガティブで個人的な経験や感情も分かち合う事ができるからである [Choudhury 14, Kang 16]．例えば，性的虐待の悩みについての相談 [Andalibi 16] などである．またカウンセラーよるオンラインカウンセリングにおいても匿名性の高さが自己開示を促す [岡本 08]．日本で幅広く普及している Facebook，Twitter，LINE での社会関係は，若い世代においてはオフラインの人間関係の延長線上にあることが多い [総務省 17]．したがって，オフラインの人間関係とは切り離された社会関係のあるオンラインコミュニケーションツールは，それらの社会関係を補完することが期待できる [高野 18]．

アバターチャットサービス「ピグパーティ」では，自身のいじめ被害について告白し，それに対する相談という形でオンラインソーシャルサポート提供が観測されている [高野 18]．本研究では現実世界やその延長にあるオンラインコミュニケーションツールのピグパーティによる補完可能性を知ることを目的とする．そのためにソーシャルサポートとソーシャルサポートに深く関わる要因「現実と仮想社会の社会関係の重なり合い，自己開示，情動表出の表現力」の 4 つの観点から，ユーザインタビュー結果を整理する．この観点からの知見は他のオンラインコミュニケーションツールにおけるソーシャルサポートを検討する際にも有効であろう．

連絡先: 高野雅典，株式会社サイバーエージェント 秋葉原ラボ，takano_masanori@cyberagent.co.jp



図 1: ピグパーティでのコミュニケーションのイメージ．ユーザは自分で作ったアバターを使って他のユーザと対話することができる．

本稿ではアバターチャットサービス「ピグパーティ」において，サービス運営者がユーザの利用実態の把握・製品改善のために行ったインタビュー結果資料を社会関係やソーシャルサポートの観点で整理した．具体的な観点は以下の 4 つである．

- RQ1: ユーザの仮想社会と現実社会の社会関係はどの程度，重なり合っているのか？
- RQ2: テキストのみのチャットではなくビデオ通話でもないアバターチャットを用いたコミュニケーションについてどのように感じているか？
- RQ3: 仮想のキャラクター（匿名）として振る舞うことが可能な世界でユーザは自己開示についてどう捉えているか？
- RQ4: 仮想社会での関係においてソーシャルサポートを提供されるのか？

2. インタビュー

「ピグパーティ」とはインターネット上の仮想社会を提供するオンラインコミュニケーションサービスで，iOS と Android のアプリケーションとして提供されている．ユーザは好みのアバターを作成し，ピグパーティが用意した空間（ルーム）でチャットによるコミュニケーションをする（図 1）．利用者は

10 代が多く，学校や趣味など様々な話題の対話がなされている（2017 年 8 月時点で 6 割以上が 10 代）．

サービス運営者によるインタビューは半構造化インタビューで，ピグパーティ利用ユーザ 8 名に対して行ったものである．本研究に関する質問項目は以下のとおりであった．

- ピグパーティをどのように楽しんでいるか？
- 他のユーザに対してどのように考えているか？
- 自分のアバターに対してどのように考えているか？

この他には使いやすさやデザインなどについて質問がされた．

3. 結果

3.1 RQ1: ユーザの仮想社会と現実社会の社会関係はどの程度，重なり合っているのか？

8 名全員のピグパーティでの社会関係は現実のものとほぼ重なっていなかった．それは現実とピグパーティの社会関係は切り離しておきたいと考えていたためである．

1 名を除きインタビューイが仲が良いと述べた社会関係の数は 1〜6 程度であった [*1]．この人数は現実の社会関係と同程度である [Zhou 05]．また他のオンラインの社会関係（Twitter [Arnaboldi 13], Facebook [Dunbar 12]）においても類似の傾向が見られる．

1 名は現実の友人と話せないときにピグパーティの友人と話す事が多いと述べた．これはピグパーティを現実の社会関係補完の可能性を示している．

3.2 RQ2: テキストのみのチャットではなくビデオ通話でもないアバターチャットを用いたコミュニケーションについてどのように感じているか？

5 名がアバターのジェスチャーや表情がコミュニケーションを円滑にすると感じていた．特に 2 名は現実で会話しているような感覚でコミュニケーションが取れると述べた．1 名は現実での会話に比べると言葉や表情のニュアンスが伝わりづらいと感じていたが，そのニュアンスを伝えるためにジェスチャーを多用していた．

3.3 RQ3: 仮想のキャラクター（匿名）として振る舞うことが可能な世界でユーザは自己開示についてどう捉えているか？

6 名が現実の生活で起きたことをピグパーティの会話では話していなかった．それは 1) 自身の身元が知られてしまうリスク回避，2) 現実とピグパーティの社会関係は切り離しておきたいという 2 つの理由である．後者はインタビューイが現実の社会関係の補完的役割をピグパーティの社会関係に期待していることを示唆する．

自分の悩みについて打ち明けるなど自己開示行動について言及したインタビューイはいなかった．これはソーシャルサポートを期待した使い方が主な利用方法ではないことを示す．

3.4 RQ4: 仮想社会での関係においてソーシャルサポートを提供されるのか？

3 名がピグパーティ上で他者からの自己開示を受け，それに対して相談をしていた（ソーシャルサポートを提供していた）．それは学校や職場の悩み・愚痴を聞くというものであった．相談者は自身の悩みや状況について自己開示を行っており，インタビューイはそれに応じて相談をしていた．

*1 残りの 1 名は数十名のユーザと大きな偏りなく仲が良いと述べた．

4. 議論

ユーザがピグパーティの社会関係に現実の社会関係と相補的な役割を期待していることを示唆された．それは，ピグパーティの社会関係は現実の社会関係とほぼ切り離されており，現実の延長線上に有る主要オンラインコミュニケーションツール [総務省 17] とは大きく異なり，それはユーザが意図的に切り離していたからである（RQ1）．

そのピグパーティでの親密な社会関係は，ソーシャルサポートの観点において現実の社会関係を補完できる能力があると考えられる．それはユーザの自己開示とそれに対するソーシャルサポート提供がされていたからである（RQ4）．これはユーザの行動分析の結果からも支持される [高野 18]．また，その親密な社会関係の構造が，現実 [Zhou 05] や他のオンラインコミュニケーションツール [Dunbar 12] といったソーシャルサポートが有効に働いている社会関係の構造と類似していたこと（RQ1）も，補完能力を支持する．

オンラインソーシャルサポートを含むオンラインコミュニケーションにおいてアバターの表情やジェスチャーの重要であることがわかった（RQ2）．対面やテレビ電話など相手の顔が見えることは見えないこと（電話やテキストコミュニケーション）に比べて，コミュニケーションの満足度を高くする [Vlahovic 13]．デフォルメされたアバター（図 1）の表情やジェスチャーであっても，対面やテレビ電話のような効果があるかもしれない．したがってアバターコミュニケーションは，テキストを中心とする一般的なオンラインコミュニケーションツールによるコミュニケーションに対して相補的な役割を果たしうる．またオンラインカウンセリングの課題として非言語メッセージが使えないことが挙げられる [岡本 08]．アバターコミュニケーションはそれを緩和できる可能性がある．

以上のように，ピグパーティにおける自己開示とそれに対するソーシャルサポートは，現実や主要オンラインコミュニケーションツールに対して相補的な役割を果たしうることが示された．例えば，学校におけるいじめ被害に対する支援として電話相談窓口やスクールカウンセラーの設置があるが，被害者が利用をためらうことによってサポートを受けていない場合があり，補完が必要である [The Japan Times 17]．ピグパーティのような性質をもったオンラインコミュニケーションツールが，そのような場合の補完として期待できる．

参考文献

[Andalibi 16] Andalibi, N., Haimson, O. L., De Choudhury, M., and Forte, A.: Understanding Social Media Disclosures of Sexual Abuse Through the Lenses of Support Seeking and Anonymity, *CHI*, pp. 3906–3918 (2016)

[Arnaboldi 13] Arnaboldi, V., Conti, M., Passarella, A., and Pezzoni, F.: Ego networks in Twitter: An experimental analysis, *INFOCOM*, pp. 3459–3464 (2013)

[Choudhury 14] Choudhury, De, M. and De, S.: Mental Health Discourse on reddit: Self-Disclosure, Social Support, and Anonymity, *ICWSM* (2014)

[Dunbar 12] Dunbar, R. I. M.: Social cognition on the Internet: testing constraints on social network size, *Proceedings of the Royal Society B: Biological Sciences*, Vol. 367, No. 1599, pp. 2192–2201 (2012)

[Kang 16] Kang, R., Dabbish, L. A., and Sutton, K.: Strangers on Your Phone: Why People Use Anonymous Communication Applications, *CSCW*, pp. 358–369, (2016).

[The Japan Times 17] The Japan Times: Nagano counselors trial online consultations for troubled teens via Line messaging app (Oct. 10, 2017) Retrieved Jan. 11 2017.

[Turner 14] Turner, R. J., Turner, J. B., and Hale, W. B.: Social Relationships and Social Support, in *Sociology of Mental Health*, pp. 1–20, Springer (2014)

[Vlahovic 13] Vlahovic, T., Roberts, S., and Dunbar, R. I.: "Media Naturalness Theory" and Human Social Bonding., *Human Behavior and Evolution Society Conference* (2013)

[Zhou 05] Zhou, W.-X., Sornette, D., Hill, R. A., and Dunbar, R. I.: Discrete hierarchical organization of social group sizes, *Proceedings of the Royal Society B: Biological Sciences*, Vol. 272, No. 1561, pp. 439–444 (2005)

[岡本 08] 岡本悠, 松田英子: ビデオチャットカウンセリングの有用性に関する検討—対面カウンセリング及び E メールカウンセリングとの比較—, メディア教育研究, Vol. 4, No. 2, pp. 91–98 (2008)

[高野 18] 高野雅典, 角田孝昭: オンラインコミュニケーションにおける「いじめ経験の告白」, 人工知能学会全国大会 (2018)

[総務省 17] 総務省: スマートフォン経済の現在と将来, 2017 年版 情報通信白書, 第 1 章 (2017)

Oral presentation | Organized Session | [Organized Session] OS-11

[1B1-OS-11a] [Organized Session] OS-11

Tue. Jun 5, 2018 1:20 PM - 3:00 PM Room B (4F Moon Light)

[1B1-OS-11a-01] Proposal on incentive design for activation of shopping street using city walk application

○Yuya Ieiri[1], Yuu Nakajima[2], Reiko Hishiyama[1] （1. Waseda University, 2. Toho University）

1:20 PM - 1:40 PM

[1B1-OS-11a-02] Large Scale Terrain Modeling and Automatic Aerial Shooting with Multi-drone System

○Keiji Suzuki[1], Sho Yamauchi[2], Kouki Ogata[1], Toshio Kawashima[1] （1. Future University Hakodate, 2. KITAMI Institute of Technology）

1:40 PM - 2:00 PM

[1B1-OS-11a-03] Towards a New Method for the Investigation of Tourists' Needs

○Shuang Song[1], Hidenori Kawamura[1], Junichi Uchida[2], Hajime Saito[3] （1. Hokkaido University, 2. Otaru University of Commerce, 3. Hokkaido Information University）

2:00 PM - 2:20 PM

[1B1-OS-11a-04] Route Traffic Flow Estimation by Observing Staying People

○Hitoshi Shimizu[1], Tatsushi Matsubayashi[2], Yusuke Tanaka[2], Tomoharu Iwata[1], Hiroshi Sawada[1,2] （1. NTT Communication Science Laboratories, 2. NTT Service Evolution Laboratories）

2:20 PM - 2:40 PM

[1B1-OS-11a-05] Identifying Individual Chimpanzee with Convolution Neural Networks

○Yuuichiro Ikeda[1], Hiroyuki Iizuka[1], Masahito Yamamoto[1] （1. Graduate School of Information Science and Technology, Hokkaido University）

2:40 PM - 3:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

街歩きアプリを用いた商店街活性化のための インセンティブ設計の提案

Proposal on incentive design for activation of shopping street using city walk application

家入　祐也 *1　　中島　悠 *2　　菱山 玲子 *1
Yuya Ieiri　　Yuu Nakajima　　Reiko Hishiyama

*1早稲田大学大学院創造理工学研究科経営システム工学専攻
Graduate School of Creative Science and Engineering, Waseda University

*2東邦大学理学部情報科学科
Infomation Science, Toho University

In order to revitalize the shopping street, it is necessary to urge customers to visit each store in the shopping street and to know the attractiveness of each store. However, regarding the current situation, there is a problem that the visits of most customers tend to concentrate in certain stores such as big chain stores. Therefore, in our study, we actually implemented an event using city walk application that we developed. Also, in the event, in order to prevent customers from visiting such stores, we created an incentive design to determine the point allocation of each store, with the aim of stabilizing the unique index of the research called “store appeal value”. And then, by analyzing the log data of the event, we were able to confirm the visit to each store in the shopping street and show the effectiveness of the proposed method.

1.　はじめに

商店街は古くから形成されており，各地域の中心地として重要な役割を果たしてきた．現在でも，全国で 10,000 を超える数の商店街が存在しているが，大型チェーン店の出店等によって厳しい経営状況に困惑する商店街は非常に多い．そのため，商店街活性化のための方法は様々考えれており，ひょうご産業活性化センター [1] では，商店街活性化のためには，商店街を形成する各店舗が魅力を有することが必要と考えられている．

各店舗の魅力が適切に評価されるためには，顧客が店舗を訪れ，その店舗について知ることが条件であると考えれるが，現状としては，多くの顧客が大型チェーン店等での購買に集中しており，個々の商店が新規顧客の獲得に力を入れる必要があると述べられている [2]．そこで本研究では，街歩きアプリを用いたイベントの実施によって，ユーザに対して商店街の各店舗への来店を促し，各店舗の魅力を伝えることを試みた．また本研究では，一部の店舗にユーザの訪問が偏ることを防ぐために，ポイント制度やランキング制度などといった非金銭的インセンティブや，ある一定ポイントと金券が交換出来るという金銭的インセンティブを付与した．そして，この両インセンティブにとって重要な要素となる「ポイント」を店舗ごとに適切に配分する手法を提案する．

本研究では，特に早稲田大学付近の 2 つの商店街を対象として，街歩きアプリを用いたイベントを実施し，対象ユーザである大学関係者（大学生・大学職員）に対して，一部の店舗に偏りが生まれないように，商店街の各店舗への来店を促し，各店舗の魅力を伝えることを試みた．この試みのため，本研究では以下の 3 点を行った．

- 商店街を散策する街歩きアプリの開発とイベントの実施
- フィージビリティスタディによる店舗魅力値均一化のためのインセンティブ設計の提案
- イベントログデータの分析による本提案手法の評価

連絡先: 家入祐也，早稲田大学創造理工学研究科経営システム工学専攻，〒 169–8555 東京都新宿区大久保 3–4–1　51 号館 15 階 02 号室，080-6537-9947，ieyuharu@ruri.waseda.jp

以上 3 点の実施によって，商店街の各店舗へユーザを誘導し，魅力を伝えるための提案手法の有効性を明らかにする．

2.　関連研究

ICT 技術を利用して商店街への誘導を行うことで，商店街の認知向上を試みている研究は様々存在している．長島ら [3] は，商店郡への誘導と認知を促すために，ポイントシステム，クーポンシステムを実装したスマートフォンアプリケーションの開発を行っている．また美原ら [4] は，商店街への誘導を促すために，ユーザの回遊履歴から適していると思われる商店街の情報を提示するシステムの開発を行っている．そして実験によって，商店街への誘導率の向上のみならず，商店街の滞在時間も向上したことを示している．

これらの研究は本研究同様，ICT 技術を利用して商店街への誘導を試みているが，いずれの研究も商店街という大きな空間への誘導にとどまっている．本研究はよりミクロな視点で，各個店への誘導を街歩きアプリとインセンティブ設計によって試みているという点で，以上の研究とは異なっている．

3.　提案

本研究では，早稲田大学付近の 2 つの商店街を対象として，街歩きアプリを用いたイベントを実施し，対象ユーザである大学関係者（大学生・大学教職員）が，一部の店舗に偏りが生まれないように各店舗へ来店し，各店舗の魅力に気が付かせることを試みている．本章ではその試みのために開発した街歩きアプリの説明を行い，その後，ユーザの訪問が一部の店舗に偏ることを防ぐために行った，フィージビリティスタディによる店舗魅力値均一化のためのポイント配分方法についての説明を行い，最後に本研究で実施したイベントについての説明を行う．

3.1　街歩きアプリ：まちナビ

本研究では，商店街の各店舗への誘導を促進するための街歩きアプリとして Ieiri ら [5] によって開発された「まちナビ」を用いた．まちナビでは，次の 5 つの手順を繰り返してユーザを各店舗へ誘導し訪問（チェックイン）させる．

1. 一覧画面から目的地を選択

2. ナビ（方向と残り距離）を用いて移動
3. 店舗で何か購入する，またはサービスを受ける
4. ショップカードを受け取り，記入されているキーワードを入力する（チェックイン）
5. クイズに回答する

本アプリのコンテンツとして組み込まれている店舗は，後に説明するイベント「Myshop 発見ツアー」に参加をした 26 店舗であり，著者らによる各店舗への複数回にわたる現地調査に基づいて作成した．なお，本アプリではチェックインをすると店舗ごとに異なるポイントが獲得でき，さらにクイズに正解すると追加で 1 ポイント獲得できる仕様になっている．また，ランキング画面が存在し，他ユーザと総合獲得ポイント数を競い合うことが可能になっている．

3.2 店舗魅力値の均一化

本研究では「店舗魅力値」を以下のように定義する．

$$\text{店舗魅力値} = \text{入店願望値} - \text{入店阻害値} \tag{1}$$

入店願望値とは，ある店舗に対してどの程度その店舗に入りたいと思うかを数値化したものであり，入店阻害値とは，ある店舗に対してどの程度その店舗に入りにくいと感じるかを数値化したものとする．本研究では，全店舗の店舗魅力値が一定であれば，本アプリケーションのユーザを全ての店舗に偏りなく誘導することが出来るという仮説を立て，この仮説のもと，店舗魅力値を一定にするために，各店舗で獲得することのできるポイント数を変化させた．

ここからは，具体的に店舗魅力値をどのように算出したか，店舗魅力値を一定にするためにどのようにポイントを配分したかについて説明する．本研究では店舗魅力値の算出，店舗魅力値の均一化，のために以下の 4 ステップを行った．

STEP1
店舗魅力値決定要素の設定

STEP2
アンケート調査による各要素の重み付け

STEP3
フィージビリティスタディによる店舗ごとの各要素の評価値の決定

STEP4
店舗魅力値の算出と各店舗のポイントの決定

まず，STEP1 について説明する．店舗への評価に関する研究は様々行われており，小崎ら [6] は，気楽に訪れることのできる店舗，なじみのある店舗が店舗の高評価につながることを述べ，またその店舗がどのような立地条件にあるかは，店舗の評価に大きな影響を与えることを明らかにしている．また，山本ら [7] によって，店舗の商品の価格帯をはじめとして，店舗内の様子が外から見てどの程度分かるか，予測される入店後の居心地はどうか，などの要素が，店舗の入りにくさに影響していることが明らかにされている．以上より本研究では，「入店願望値」と「入店阻害値」，すなわち店舗魅力値を決定するための要素として以下のものを選択した．

P1 なじみ具合・気楽さ

表 1: 各要素の重み付け

Factors	P1	P2	P3	P4	N1	N2	N3
Weight	w1	w2	w3	w4	w5	w6	w7

P2 立地条件

P3 店舗のジャンル

P4 キャッシュバック（ポイント）

N1 価格帯

N2 店舗内の様子の分かり具合

N3 予測される入店後の居心地

P1，P2，P3，P4 に関しては，入店願望値の決定要素（Positive Factor）を示しており，N1，N2，N3 に関しては，入店阻害値の決定要素（Negative Factor）を示している．また，P3 と P4 に関しては，本実験における実験対象者の中心である大学生にとっては，入店の可否を決定する重要な要素であると考え，本研究では入店願望値の決定要素として追加している．

次に STEP2 について説明する．先に示した各要素は，すべてが同じ影響力を持つとは考えにくい．そのため，表 1 のように重み付けを行う．ここで本研究では，入店願望値と入店阻害値は，店舗魅力値を決定する上で同等であると考え，以下の数式が成立するものとした．

$$\begin{aligned} w1 + w2 + w3 + w4 &= 1 \\ w5 + w6 + w7 &= 1 \end{aligned} \tag{2}$$

そして，本研究の実験対象者の中心である大学生に対してアンケート調査を行い，各重みの具体的な値を決定する．

次に STEP3 について説明する．本研究では，店舗魅力値決定要素の重みづけを終えた後に，実際の各店舗の店舗魅力値を算出するためにフィールド調査によるフィージビリティスタディを行う．このフィールド調査では，本研究の実験対象者の中心である大学生を実際に各店舗へ訪問させ，次の 6 項目に関して 1 から 5 の 5 段階評価を行った．

(1) なじみ具合・気楽さ
なじみやすい，気楽に行けると感じた店ほど，大きな値で評価

(2) 立地条件
訪問しやすい立地であるほど，大きな値で評価

(3) 店舗のジャンル
入店しやすいジャンルの店ほど，大きな値で評価

(4) 価格帯
価格が高いと感じた店ほど，大きな値で評価

(5) 店舗内の様子の分かり具合
店舗内の様子が分かりにくい店ほど，大きな値で評価

(6) 予測される入店後の居心地
入店後の居心地が良くないと予測される店ほど，大きな値で評価

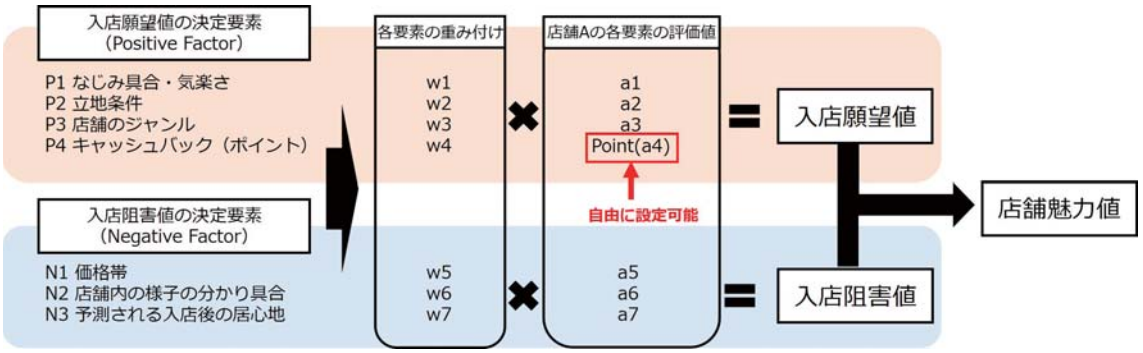


図 1: 店舗 A における店舗魅力値算出の流れ

次に STEP4 について説明する．今回設定した店舗魅力値決定要素の中で，自由に値を変更できるのは P4 要素であるポイントである．そのため，このポイントを調整することによって，店舗魅力値の一定化を試みる．図 1 はある店舗 A における店舗魅力値算出の流れを示したものである．ここで，図 1 のように，STEP3 で調査した店舗 A における各要素の評価値を a1,a2,a3,Point(a4),a5,a6,a7 とすると，入店願望値と入店阻害値は以下のように示され，これらを式 (1) に代入することで，店舗 A の店舗魅力値が算出できる．

$$\begin{aligned} \text{入店願望値} &= w1 \cdot a1 + w2 \cdot a2 \\ &\quad + w3 \cdot a3 + w4 \cdot \text{Point(a4)} \\ \text{入店阻害値} &= w5 \cdot a5 + w6 \cdot a6 + w7 \cdot a7 \end{aligned} \tag{3}$$

このように本研究では，入店願望値を形成する「Point」を自由に設定することによって，各店舗の店舗魅力値を一定にすることが可能になった．

3.3 Myshop 発見ツアー

「Myshop 発見ツアー」とは，2017 年 12 月 8 日～12 月 22 日に行われたイベントであり，この期間内に本イベントに参加した 26 店舗でキーワードの記されているショップカードが顧客に配布された．また，この期間内には広報活動として，大学内でポスターやチラシの配布を行った．この，広報物には QR コードが記されており，この QR コードを読み込めば，「まちナビ」が起動される仕組みになっている．また，イベントの最後の 5 日間のみ金券交換所を開き，本イベント参加店で利用できる 500 円商品券を，「まちナビ」にユーザ登録をした人に 1 枚，総獲得ポイントが 50 ポイントに達した人に 5 枚，100 ポイントに達した人に 10 枚を配布した．

なお，本イベントの実施に先立ち，先に説明した店舗魅力値の均一化のための 4 ステップを行い，ポイント配分を行った．店舗魅力値決定要素の重みづけのためのアンケート調査は大学生 45 人を対象に実施し，これと同時に，各店舗の店舗魅力値を算出するためのフィールド調査を大学生 17 人の協力のもと行った．本提案手法によって算出された配分された各店舗の店舗魅力値（ポイント調整前）とポイントを表 2 に示す．また，ユーザのポイント計算を容易にするために，各店舗で獲得できるポイント数は最小を 5 として，5 の倍数とした．

4. 実験結果と考察

本章では，イベント「Myshop 発見ツアー」によって得られたユーザのログデータの分析を行う．

表 2: 各店舗のポイントについて

店舗名	店舗魅力値（ポイント調整前）	ポイント
大型チェーン店 1	2.1505	5pt
大型チェーン店 2	2.1972	5pt
大型チェーン店 3	−0.2514	30pt
大型チェーン店 4	−1.8428	5pt
大型チェーン店 5	0.9175	20pt
大型チェーン店 6	2.5584	5pt
飲食店 1	0.7626	20pt
飲食店 2	0.8149	20pt
飲食店 3	1.6646	10pt
飲食店 4	−0.6150	35pt
飲食店 5	−1.2153	40pt
飲食店 6	0.0498	25pt
飲食店 7	−0.0579	30pt
飲食店 8	−0.0634	30pt
飲食店 9	0.3110	25pt
飲食店 10	1.4627	10pt
サービス店 1	−0.7313	35pt
サービス店 2	−0.7668	35pt
サービス店 3	−0.6055	35pt
サービス店 4	−0.8914	35pt
サービス店 5	−1.6123	45pt
最寄品小売店 1	−0.5411	35pt
最寄品小売店 2	−0.6663	35pt
衣料品・身の回り品店 1	−1.1713	40pt
その他店 1	−2.3195	50pt
その他店 2	−0.3516	30pt

第 3.3 節で説明したように，本研究ではユーザに対して金券を配布した．配布された金券を利用する際には，ポイントという制約がなくなるため，利用者が行きたい店舗，すなわちポイント調整前の店舗魅力値が高い店舗で利用されることが予測される．そこで，本金券の利用者は「まちナビ」の利用者であることから，「まちナビ」によって訪問された店舗と金券が利用された店舗に差があった場合，「まちナビ」を提案手法に基づいてインセンティブ設計して利用することにより，ユーザに対して普段訪れないような店舗へと誘導することが可能であったと言える．更に，ポイント調整前の店舗魅力値が低かった店舗での金券の利用，すなわちユーザの再訪問が見受けられたならば，ユーザにその店舗の魅力が伝わったことが予測できる．本研究では，主にそのような観点からイベントログデータの分析を行い，本提案手法の有効性を評価する．

本イベントにおいて，総ログイン者数は 121 人，そのうちポイントを実際に獲得したユーザは 21 人であり，また，チェックインされた店舗の数は 26 店舗中 11 店舗であった．チェックインされた店舗の一覧を表 3 に示す．

表 3: 各店舗の被チェックイン回数

店舗名	被チェックイン回数（回）
飲食店 7	14
大型チェーン店 5	12
最寄品小売店 2	9
大型チェーン店 6	8
飲食店 3	8
飲食店 4	4
飲食店 2	3
最寄品小売店 1	3
飲食店 6	2
衣料品・身の回り品店 1	1
飲食店 10	1

表 4: 各店舗で使用された金券の枚数

店舗名	金券枚数（枚）
大型チェーン店 6	97
飲食店 10	65
大型チェーン店 1	32
飲食店 8	27
大型チェーン店 2	18
飲食店 3	18
飲食店 2	15
大型チェーン店 5	9
飲食店 4	9
飲食店 9	7
飲食店 7	4
その他店 2	4
飲食店 1	3
最寄品小売店 2	2
サービス店 3	2

表 3 より，ポイント調整前の店舗魅力値が低いにもかかわらず，チェックインされている，すなわちユーザが何かを購入したり，サービスを受けたりした店舗が複数存在していることが分かる．このことから，店舗魅力値を一定にすることを試みることで，一部の，ポイント調整前の店舗魅力値が低かった店舗にも誘導出来たことが分かる．

次に，金券を利用された店舗について分析を行う．金券は全部で 312 枚利用され，金券の利用された店舗の数は 15 店舗であった．その内訳は次の表 4 のようである．

本章のはじめにも説明したように，金券が利用された店舗というのは，金券保持者がポイント等を考えずに，ただ行きたい，入店したい，と感じた店舗，すなわちポイント調整前の店舗魅力値が高い店舗で利用されると予測される．そこで，金券の利用された 15 店舗を見てみると，そのうち 9 店舗の店舗魅力値（ポイント調整前）が正の値になっていることが分かる．これは，今回のイベント参加店舗の内，10 店舗のみが店舗魅力値（ポイント調整前）は正の値を示しており，そのうちの 9 店舗で金券が利用されたことを考えると，たしかに先の予測は正しかったことが分かる．更に，金券保持者が行きたい，入店したい，と感じた店舗は，ポイント調整前の店舗魅力値が高い店舗が多かったということから，今回の店舗魅力値の算出方法は妥当であると言える．

また，店舗魅力値が負の値であったにも関わらず，金券の利用が確認された店舗に関しては，イベント開催期間にもチェックインの実績がある店舗であるケースがみられ，再訪問が推定される結果となった．このことから，本提案手法によって，各店舗に来店することによって，店舗の魅力に気が付かせることが出来たと言える．

5. まとめと今後の課題

本研究では，街歩きアプリ「まちナビ」を用いたイベント「Myshop 発見ツアー」の実施によって，ユーザに対して商店街の各店舗への初来店を促し，各店舗の魅力を伝えることを試みた．また，店舗魅力値という本研究独自の指標を定義し，その算出方法を合理的に作成するとともに，店舗魅力値を一定にするために，各店舗のポイント配分を決定するというインセンティブ設計を行うことによって，対象ユーザに対して，商店街の各店舗への初来店を促し，各店舗の魅力を伝え，再来店を促すことに成功した．

今後の課題としては，本実験で実施したイベント「Myshop 発見ツアー」に参加した店舗には，本提案手法でもユーザを誘導することのできなかった，魅力を伝えることが出来なかった店舗が，複数存在していた．そのため，店舗魅力値の算出方法の改善が必要があると考えられる．

謝辞 本研究は，科学技術融合振興財団（FOST）の平成 29 年度助成金による成果である．本研究では，早稲田大学特定課題の支援を受けた．また，本実験は，新宿区による平成 29 年度商店街補助事業の一環として実施した．

参考文献

[1] これならできる！商店街に客を呼び込む仕掛けづくり：公益財団法人　ひょうご産業活性化センター，*https://web.hyogo-iic.ne.jp/files/kouri/syotengaisikake_report.pdf*（最終アクセス日 2018-2-13）．

[2] マンスリーリサーチ商店街に関するマーケティングデータ：朝日大学 マーケティング研究所，*http://marketing.asahi-u.ac.jp/wordpress/wp-content/uploads/0401.pdf*（最終アクセス日 2018-3-3）．

[3] 長島弘志，湯瀬裕昭，渡邉貴之：地域商店群を対象とした O2O アプリケーションの開発，第 14 回情報科学技術フォーラム（FIT2015），O-040, pp.523-524 (2015).

[4] 美原義行，市川裕之，武藤伸洋，岡本学，内田典佳，井前吾郎，舘裕之：プライバシを考慮したスマートフォン向け回遊場所推薦システム，情報処理学会論文誌コンシューマ・デバイス＆システム（CDS），Vol.7, No.2, pp.87-96 (2017).

[5] Yuya, I., Takuya, M., Yuu N., Ryota, A. and Reiko, H.: Effect of First Impressions in Tourism by Using Walk Rally Application , *Proc. International Conference on Culture and Computing (Culture and Computing)* , pp.1-6 (2017).

[6] 小崎美希：商業店舗の外観評価と外観構成要素に関する研究，日本建築学会環境系論文集，Vol.82, pp.695-704 (2017).

[7] 山本杏子，伊丹弘美，小島隆矢：想起法による店舗等の入りづらさに関する調査分析，日本建築学会環境系論文集，Vol.81, pp.19-27 (2016).

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

マルチドローンによる大規模地形モデリングと自動飛行撮影

Large Scale Terrain Modeling and Automatic Aerial Shooting with Multi-drone System

鈴木　恵二 *1　山内　翔 *2　尾形　晃基 *1　川嶋　稔夫 *1
Keiji Suzuki　Sho Yamauchi　Kouki Ogata　Toshio Kawashima

*1公立はこだて未来大学　*2北見工業大学
Future University HAKODATE　KITAMI Institute of Technology

In natural scenes such as mountains, to realize precise aerial shootings, large scale terrain modeling with multi-drone is proceeded. The SfM (Structure from Motion) is applied for this modeling based on the pictures produced by the automatic flying multi-drone. Using the terrain modeling, the procedure of precise automatic aerial shootings is proposed.

1.　はじめに

ドローンによる広域自然景観を撮影する場合に，手ブレなしで長時間安定した映像取得を行うために，自動飛行による撮影は一つの有効な手段となる．自動飛行を実行するためには，あらかじめ飛行経路とカメラアングルのプランニングが必要となる．特にドローンでは撮影対象への接近や地表面に対して低空で飛ばすなどの撮影が行われる．このような撮影を行うためには，地形に関する情報に基づいてプラニングを行う必要がある．このプラニングに必要な地形情報をドローンを用い，SfM（Structure from Motion）から地形モデリングを生成する．この際，規模の大きな地形をモデリングするために，時間短縮のために複数のドローンを同時に活用して，モデリング用の撮影を行った．この地形モデリングに基づき，自動撮影飛行プラニングを作成する．以上，大規模地形モデリングを含めた自動飛行撮影の手順とその成果について示す．

2.　提案手法

2.1　撮影フロー

撮影フローを (**図 1**) に示す．まず始めに, 予定撮影経路を含めた撮影エリア一帯での地形モデリングを行う．次に発着点を決定する. 発着点から経路までの往復距離と経路の飛行距離を合わせた総飛行距離が, 機体の飛行可能距離以下であるように経路の設定を行う．総飛行距離が飛行可能距離を超えている場合は, 飛行可能距離内に撮影経路を収めるよう, 経路の分割を行う．次に飛行プランニングの作成を行う．地形モデリングで作成した撮影エリアの 3D モデルを使用し, 自動飛行に必要な way point，カメラアングルの設定を行う．作成した経路・飛行プランは使用機体の飛行可能距離・時間内である必要があり, 作成後確認を行う．最後に作成した経路をもとに自動飛行撮影を行う．

2.2　地形モデリング

撮影エリアの地形モデルをドローンを活用した地形測位で使われている [1][2]SfM(structurefrom motion) で生成する．ただし、GCP(ground control point) は用いない．撮影エリアが広大で，かつ立ち入りの難しい自然地形が多く，設置が困難であるためである．モデリングには AgisoftPhotoscan Professional edition を使用した．撮影エリアのモデリングのための写真撮影では, 地形測位の多くで使用されているグリッド軌道 [3][4][5] ではなく円形軌道により撮影を行っている．これは撮影エリアが自然地形であり，起伏に飛んでいるため，オクルージョンを回避できる円形軌道を使用している．また, モデリングエリアが広域であるため, 複数の円を設定して対象領域をカバーしている．

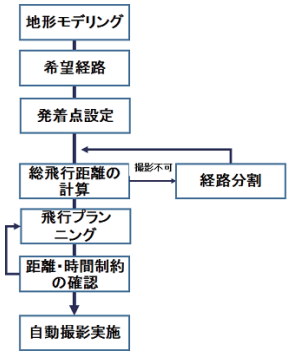


図 1: 撮影フロー概要

2.3　飛行プランニング

飛行プランニングでは飛行経路の作成を行う. 飛行経路は way point の列として XML ファイルに記述する．各 way point には緯度，経度，高度が記述されるとともに撮影用方向転換，カメラの向き，写真・動画撮影の実行を指定することができる．作成した地形モデルから緯度経度, 高度情報を取得することができ、モデル上で確認しながら飛行経路に必要な way point の設定を行う．

2.4　自動飛行撮影

広域の対象を撮影することを目的とするため，対象を分割して撮影する複数台のドローンを同時に運用できるシステムとして．自動飛行管理システムを作成した．このシステムは飛行計画を区分的に進められ，かつ複数台の飛行管理が可能である．飛行経路を記述した XML ファイルを各ドローン機体にアップロードし，自動撮影を実行させる．各ドローン機体の状態は PC で一括したモニタリングが可能であり，リアルタイムに飛行の中断や再開などの命令を送信できる．

連絡先: 鈴木恵二: kjsuzuki@fun.ac.jp

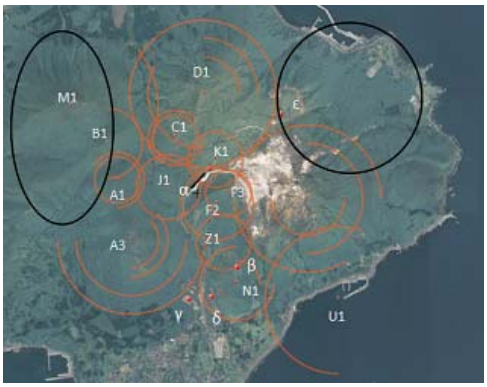


図 2: モデリング用経路図 (恵山道立自然公園)

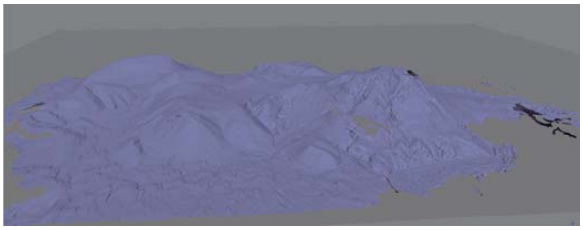


図 3: 作成したモデル (恵山道立自然公園)

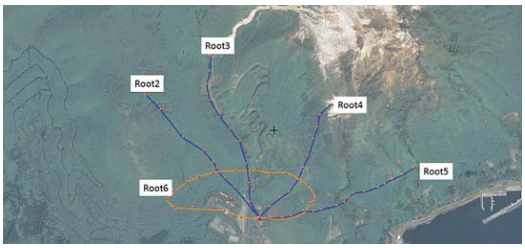


図 4: 映像撮影用経路 (恵山道立自然公園)

3. 恵山道立自然公園を対象とした撮影実験

恵山道立自然公園にて地形モデリングと自動飛行撮影実験を行った. 恵山道立自然公園は，北海道道南地区の活火山恵山を中心とする道立自然公園でありその中でも，主に観光客・登山客が訪れるエリア周辺を対象に恵山の山肌，渓谷に接近した映像の撮影を行った.

モデリングの対象となるエリアは 5.9(km) x 4.3(km) に及び，離発着場所から撮影場所までの最大距離は 1.5(km) である. モデリングに使用した総写真枚数は 1645 枚（手動撮影数は 423 枚）で，モデリングには 103 時間ほどの計算時間を要した. モデリング結果を (**図 3**) に示す.

作成したモデルを使用し、飛行プランニング、経路作成を行った (**図 4**). 作成した経路を自動操縦による撮影を行った. 撮影した動画の一部を (**図 5**),(**図 6**) に示す.

4. まとめ

本研究では，山，海岸，湖沼など自然地形を対象とした大規模地形モデリングに基づく自動飛行撮影に向けた手法の提案と



図 5: Route3 撮影動画抜粋 1(恵山道立自然公園)



図 6: Route3 撮影動画抜粋 2(恵山道立自然公園)

函館恵山地区における飛行実験の結果を示した. 今後，飛行プラニングにおける Way point の設定など，手動で行っている部分を自動生成できるようにしていく予定である.

謝辞

本研究は公益財団法人南北海道学術振興財団の平成２９年度学術研究支援事業として採択された「マルチドローンの自動飛行多角的利用プラットフォーム」への助成を受けたものである.

参考文献

[1] 内山庄一郎, 井上公, 鈴木比奈子: SfM を用いた三次元モデルの生成と災害調査への活用可能性に関する研究, 防災科学技術研究所研究報告 第 81 号 2014. 情報メディア学会誌, Vol.65, No.4, pp.479-472, 2011.

[2] 小花和宏之, 早川裕弌, ゴメス クリストファー: UAV 空撮と SfM を用いたアクセス困難地の 3D モデリング Transaction, Japanese Geomorphological Union 35-3, p.283-294,2014

[3] 国土交通省国土地理院 UAV を用いた公共測量マニュアル (案)　平成 28 年 3 月

[4] 早坂 寿人, 大野 裕幸, 大塚 力, 関谷 洋史, 瀧 繁幸: UAV による撮影画像を用いた三次元モデリングソフトウェアの精度検証, 国土地理院時報, p.107-116, 2015.

[5] 近津 博文, 小高 明彦, 柳 秀治, 横山 大: UAV 写真測量における三次元モデリングソフトウェアの性能評価, 写真測量とリモートセンシング, 55(2), p.117-127, 2016.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

Towards a New Method for the Investigation of Tourists' Needs

Shuang Song[*1] Hidenori Kawamura[*1] Junichi Uchida[*2] Hajime Saito[*3]

[*1] Hokkaido University [*2] Otaru University of Commerce
[*3] Hokkaido Information University

Many travel surveys have been carried out in many tourist destinations to investigate tourist's needs. However, traditional survey methods can be time and money consuming. Meanwhile, the analysis of the massive and up-to-date travel reviews may be able to provide a low-cost and real-time substitute. There are many tasks before we can develop a method to perform the investigation automatically. This paper will explain the progresses we have made through manual analysis and show the remaining tasks for developing an automated method.

1. Introduction

The inbound tourism has been growing in recent years and it can bring huge economic contributions to the destinations. To attract more international tourists, many travel survey have been carried out by national or local government to investigate tourists' needs (e.g. travel intention, facts and satisfaction). The most common methods used in those investigations are interview, mail or Internet survey. Despite of their advantages, it usually takes a lot of time (e.g. seasonly to yearly) and money (e.g. personnel expense, distribution expense and incentives) to acquire a large amount of samples. Nevertheless, these samples will be probabilistically limited if the arrivals of the tourists from a certain region is few.

Meanwhile, millions of users are posting blogs, pictures and videos to the Internet nowadays. For example, TripAdvisor (see: tripadvisor.jp), the world's largest travel website, has over 465 million travel-related reviews posted by worldwide tourists about hotels, restaurants and attractions located in 232 countries. According to our previous manual content analysis of 1,300 travel reviews from TripAdvisor, we have found that over 49% travel reviews contain tourist satisfaction, over 34% reviews contain the travel facts and 2.5% reviews contain the travel intention [Song et al. 18a].

These massive and up-to-date data is providing an opportunity for the development of a low-cost method for real-time investigation of the needs of tourists who come from different countries. This paper will introduce the progresses we have made through manual analysis [Song et al. 18b] and the remaining tasks for developing an automated method.

2. Questions in field surveys

Even on the same topic, different surveys have different question settings, depending on the scale of the survey and the local specialties. Also, the method of measurement differs. Taken tourist satisfaction as an example, in the Consumption Trend Survey for Foreigners Visiting Japan by the Japan Tourism Agency, 20 aspects are taken in concern(e.g. *Eat Japanese food*, *Drink Japaneses alcoholic beverages*...) [JNTO 17]. And these questions are answered with 2 options, *satisfied* and *not satisfied*. Meanwhile, in the the Survey Concerning Customer Satisfaction by the Hokkaido Government, the participants needed to answer how satisfied they were towards 11 questions, such as *meals at each tourist destination*, *souvenirs*, *accommodations* and etc. with 7 options from (1) *very satisfied*, (2) *satisfied*, (3) *fairly satisfied*, (4) *it was ok*, ..., to (6) *not satisfied* and (7) *did not use*. And the proportions of the participants who answered (1)(2)(3) are summed up as the satisfaction rates of each region [Hokkaido Government 16]. Based on these facts, we need a method that can be applied to different surveys.

Contact: Shuang Song, Hokkaido University, 060-0814, Nishi 9, Kita-ku, Sapporo, Japan, sousou@complex.ist.hokudai.ac.jp

3. Answering survey questions with travel reviews

Unlike field surveys, where targeted information can be acquired using pre-defined questions, travel reviews are mainly user generated. It leads to the doubt whether travel review is a suitable data source. So we will focus on the following 4 questions here, using the Hokkaido Survey as an example.

(1) How to find potential equivalent reviews?
(2) How to find the answers from these reviews?
(3) What are the answering rates in reviews?
(4) Are the results similar to those in field surveys?

Firstly, we need to find reviews posted by tourist who went to the survey area during the survey period. Also, results are usually aggregated by nationality in surveys, so we need to identify the nationality of the reviewer. TripAdvisor records posting date of the reviews, and gives visiting date and location information if the tourist provided them. In our research, we collected reviews based on their posting date, but notice that, there are over 1.5 months delay on average between posting date and visiting date. And the region of a tourist will be the region in the location information only if the language used in the review is (one of) the native language(s) in his/her location, to rule out those

who move to another country in middle/long term stay for job, education or etc.

Secondly, to find answers, we need (1) explanations of the captions of the questions, (2) a set of sentiments and their explanations and (3) rules to transform the emotions in reviews into the defined sentiments. We can adopt explanations from published dictionaries if they are not mentioned in the survey. But it is important to rescale the explanation to the survey area. For example, *meals* should be *food, or eating food in Hokkaido* in our case. The most efficient rules we have for now are: for each questions, first find out the related text from the review, and then judge the emotion by selecting one sentiment from positive, neutral, negative and ambiguous. It takes about half the time of the rules which ask participants to point out the related text and judge the emotion, and gives 88.5% to 91.7% consistency of the results given by every two participants.

Thirdly, in a sampling analysis of 1,158 reviews written in English and Chinese by tourists from America, Singapore, Australia, Mainland China, Taiwan, Hong Kong and Britain, we found the averagely answering rate for meals is 59.3%, transportation is 37.1%, customer service is 33.9%, scenery is 29.2%, accommodation is 28.3% and tourist attractions is 27.1%. But it is more difficult to find information about multilingualization(<6.3%), wifi(2%) or comments on the entire trip(0.4%).

Fourthly, we found (strong) correlations between the proportions of positive reviews and the satisfaction rates from the Hokkaido survey, or the proportions of positive and neutral reviews and the satisfaction rates from the Hokkaido survey in 6 out of 7 regions except for Australia.

4. From manual analysis to automated analysis

To perform the automated analysis, the following three steps are needed: (1) identification of the aspect-sentiment pairs, (2) sentiment classification and (3) aggregation.

But before that, tourists from different regions may have different language backgrounds. There are several methods for cross-language analysis, such as using data in one commonly used language or use different tools for each language. In our research, we will use Google Translation (see: translate.google.co.jp) to translate reviews into English. We found a over 97% consistency by comparing the results between original and translated reviews (150 randomly selected Chinese reviews from 1,158 samples).

Next, beginning with the identification, since machines cannot understand the captions the way human do, we need a method for machines to related text in the reviews with the questions from the surveys. There are two often discussed approaches [Schouten & Frasincar 16]: (1) dictionary-based approach, where a set of keywords, or a set of syntax (patterns of keywords) are assigned to each aspect, simplifying the task to the identification of the keyword-sentiment pairs. Usually, we can use thesaurus such as WordNet [Miller 95], or use keywords derived from the data themselves. We compared words in 1,158 samples with the words in WordNet2.1. It is found that 1935 / 7432 = 26% kinds of words do not exist in WordNet. And most of these words are proper nouns or Romaji such onsen or ramen. (2) machine learning approach, where a large amount of labeled data is usually required. However, different field surveys have different questions settings, so a set of labeled data for one survey may not be reusable for another survey, and it is difficult for human to label data on phrase or sentence level with their limited context.

Once we have identified the related text from the reviews, sentiment classification will be a much simpler task because the sentiments are independent from field surveys. And machine learning approaches such as the use of SVM should be applicable to our case.

5. Conclusions and future works

This paper explained our progresses of the development of a low-cost method for real-time needs investigation using travel reviews. Considering the answering rates and high correlations, travel reviews should be a potential data source for needs investigation. Still, we need to solve the remaining tasks for the automation of the analysis by means of automatic extraction and classification of regional words or unsupervised machine learning.

References

[Hokkaido Government 16] Hokkaido Government: Survey Concerning Customer Satisfaction. http:// www.pref.hokkaido.lg.jp/kz/kkd/H28doutai_home.htm (2016)(in Japanese)[access: 8/4/2017]

[JNTO 17] Japan National Tourist Organization (JNTO): Survey on consumption trend of foreigners visiting Japan. http://www.mlit.go.jp/kankocho/siryou/toukei/syouhityousa.html (2017) (in Japanese)[access: 8/4/2017]

[Miller 95] Miller, G. A.: WordNet: A Lexical Database for English, *Communications of the ACM*, Vol. 38, No. 11, pp.39-41 (1995)

[Schouten & Frasincar 16] Schouten, K., Frasincar, F.: Survey on aspect-level sentiment analysis, *IEEE Transactions on Knowledge and Data Engineering*, Vol.28, No.3, pp.813-830 (2016)

[Song et al. 18a] Song, S., Saito, H. and Kawamura, H.: Content analysis of travel reviews: exploring the needs of tourists from different countries, *Information and Communication Technologies in Tourism 2018*, Springer, Cham, pp.93-105. (2018)

[Song et al. 18b] Song, S., Kawamura, H., Uchida, J. and Saito, H.: Towards a New Investigation Method for Tourists' Needs: from Travel Survey to the Analysis of Travel Reviews, *Proceedings of The First International Conference on Digital Practice for Science, Technology, Education, and Management*, Hokkaido, Japan, pp.11-16.(2018)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

滞在人数を考慮した経路別人数の推定

Route Traffic Flow Estimation by Observing Staying People

清水 仁 *1 Hitoshi Shimizu　松林 達史 *2 Tatsushi Matsubayashi　田中 悠介 *2 Yusuke Tanaka　岩田 具治 *1 Tomoharu Iwata　澤田 宏 *1*2 Hiroshi Sawada

*1日本電信電話株式会社 コミュニケーション科学基礎研究所
NTT Communication Science Laboratory

*2日本電信電話株式会社 サービスエボリューション研究所
NTT Service Evolution Laboratories

Estimating the number of people traveling by route is an important task in transportation research. We propose a new method that utilizes the number of people staying and passing to estimate the number of people traveling by route with high accuracy. By using artificial data, we demonstrate that the error rate of the proposed method is smaller than the conventional method. In addition, the analysis of read-world data are shown.

1. はじめに

交通分野において，経路を移動する人数を推定することは重要な課題である．推定された経路別人数は，道路や鉄道の設備計画などに利用される．また，経路別人数を人流シミュレータの入力として用いることで，雑踏警備や誘導計画を検討することができる [山下 16]．さらに，経路別人数には起点（Origin）と終点 (Destination) に加えて途中の経由点の情報も含まれているため，経路選択モデルの検証に用いることができる [安藤 11]．

既存研究においては四段階推定法 [大蔵 93] に基づいて，道路の通過人数を用いて OD 交通量（起点から終点までの交通量）を推定してから経路選択率で経路別の交通量を配分することが多かった [朝倉 94]．しかし既存手法では，経路選択率の推定が困難という課題と，観測できるエッジが少ない場合に精度が悪いという問題があった．

本研究では，通過人数に加えて滞在人数を用いて経路別人数を推定する手法を提案する．提案手法では，移動経路に依存して起点と終点で滞在人数が増減するという関係を利用し，観測された通過人数と滞在人数の両方に整合するような経路別人数を推定する．OD 交通量の推定のプロセスが不要であり，また，解の制約条件が追加されるため，推定精度が向上することが期待できる．通過人数は目視やカメラ [大西 15] やレーザーで観測されるが，建物の出入口や道路以外の空間では境界を判別しづらいため観測が困難となる．一方，滞在人数の観測にカメラを用いる場合には境界を判別しやすいため，通過人数よりも容易に取得できる場合もある．

すでに近年，滞在人数のデータを交通量推定に用いる手法が開発されている [金森 15]．しかし，金森らは交通手段別 OD 交通量を推定することを目的としているのに対して，本研究では歩行者の経路別人数を推定することを目的としている．

2. 問題設定

各記号の定義を表 1 に示す．

表 1: 各記号の定義

記号	説明
G	道路網を表現する有向グラフ $G(V,E)$
L	道路網 G のエッジの数．$\ell \in \{1,\cdots,L\}$
M	道路網 G のノードの数．$m \in \{1,\cdots,M\}$
r_i	i 番目の経路
K_i	r_i に含まれるノードの数
I	経路の数．$i \in \{1,\cdots,I\}$
T	観測時刻の数．$t \in \{0,\cdots,T\}$
$Y_{t,i}$	時刻 $t-1$ から t に経路 r_i を移動した人数．経路別人数．
$X_{t,\ell}$	時刻 $t-1$ から t にエッジ e_ℓ を通過した人数．通過人数．
$S_{t,m}$	時刻 t にノード v_m に滞在している人数．滞在人数．
$D_{t,m}$	$S_{t,m} - S_{t-1,m}$．滞在人数増減．

2.1 道路網と経路

道路網を，交差点をノード集合 V，道路 *1 をエッジ集合 E とする有向グラフ $G(V,E)$ で表現する．m 番目のノードを $v_m \in V$，ℓ 番目のエッジを $e_\ell \in E$ と表記する．時刻 $t-1$ から t までの時間帯にエッジ e_ℓ を通過した人数を通過人数 $X_{t,\ell}$ とし，時刻 t にノード v_m に滞在している人数を滞在人数 $S_{t,m}$ とする．歩行者はノードからノードまで移動するものとし，全ノード間の経路候補を列挙したときの i 番目の経路を r_i とする．r_i の k 番目の要素 $r_i(k)$ はノードである（$r_i(k) \in V$．ただし $k \in \{1,\cdots,K_i\}$ とする）．時刻 $t-1$ から t に経路 r_i を移動する歩行者の人数を経路別人数 $Y_{t,i}$ とする *2．本研究ではこの経路別人数 $Y_{t,i}$ の推定を目的とする．

2.2 通過人数と滞在人数の関係

通過人数は，特定の「時間帯」について観測されるが，滞在人数は，特定の「時刻」で観測されるので，対応づけるために，滞在人数増減 $D_{t,m} = S_{t,m} - S_{t-1,m}$ を用いる．ノード v_m に接続する全てのエッジの通過人数を観測できる場合には，滞在人数増減は「ノードに流入する通過人数の和」と「ノードから流出する人数の和」の差と一致する．そのため，滞在人数の観

連絡先: 清水仁，ＮＴＴコミュニケーション科学基礎研究所，京都府相楽郡精華町光台 2-4，0774-93-5112，shimizu.hitoshi@lab.ntt.co.jp

*1 有向グラフで表現するため同一の道路でも方向別に異なるエッジとする．

*2 歩行には移動時間がかかるため，時刻 t −1 から t までの時間帯に所望の移動を完了できるとは限らない．そのため，1 人の歩行者の軌跡が複数の時間帯に分断された複数の移動となる場合がある．

測によって追加される情報がないので推定精度は向上しない．そこで，通過人数の観測が不完全な場合に，滞在人数を利用して精度向上させることを検討する．

3. 手法

3.1 既存手法

通信分野においては，通信リンクの通信量から地点間の通信量を推定するために，交流トラヒック推定技術が開発されている [Zhang 03][植松 15]．我々はこの技術を交通分野に適用した手法を提案した [清水 17]．以下では [清水 17] に沿って既存手法を説明する．

各時間帯の中では，各エッジの通過人数はそのエッジを通過する経路別人数の和となる．すなわち，エッジ e_ℓ を通過する経路 $r_i (i : e_\ell \in r_i)$ を用いて，

$$X_{t,\ell} \simeq \sum_{i:e_\ell \in r_i} Y_{t,i} \tag{1}$$

が成り立つ．ここで，X と Y の関係を整数行列 $A \in \mathbb{Z}^{L\times I}$ を用いて，

$$A_{\ell,i} = \begin{cases} 1 & \text{エッジ } e_\ell \text{ が経路 } r_i \text{ に含まれるとき} \\ 0 & \text{otherwise} \end{cases} \tag{2}$$

と表すと，

$$X \simeq AY \tag{3}$$

が成り立つ．この A をルーティング行列と呼ぶ [Zhang 03]．

各時間帯において通過人数 X が与えられたとき，式 (3) をなるべく満たすように以下の目的関数 (4) を最小化することで，経路別人数 Y を推定する．

$$\sum_{\ell=1}^{L} \left| \sum_{i=1}^{I} A_{\ell,i} Y_{t,i} - X_{t,\ell} \right|^2 + \lambda_1 \sum_{i=1}^{I} |Y_{t,i}|^2 \tag{4}$$

第 2 項は，登場する歩行者の人数を小さくする目的で，追加している [松村 14]．短距離の移動をする人よりは長距離の移動をする人のほうが出現しやすいという経験則に基づいており，この項を追加することで安定した解を得ることができる．

3.2 提案手法

本研究では滞在人数の観測を利用できるように，上記の既存手法を拡張する．各ノードの滞在人数は，そのノードに到着する人数とそのノードから出発する人数との差だけ増減する [*3] ため，ノード v_m を先頭または末尾に含む経路 $r_i (i : v_m \in r_i)$ を用いて，

$$D_{t,m} \simeq \sum_{i:v_m = r_i(K_i)} Y_{t,i} - \sum_{i:v_m = r_i(1)} Y_{t,i} \tag{5}$$

が成り立つ．ここで，D と Y の関係を整数行列 $B \in \mathbb{Z}^{M\times I}$ を用いて，

$$B_{m,i} = \begin{cases} 1 & \text{経路 } r_i \text{ の末尾が } v_m \text{ のとき} \\ -1 & \text{経路 } r_i \text{ の先頭が } v_m \text{ のとき} \\ 0 & \text{otherwise} \end{cases} \tag{6}$$

[*3] 経路の先頭と末尾以外にそのノードが含まれる場合は，そのノードに流入し，かつ，流出するので，滞在人数の増減には影響しない．

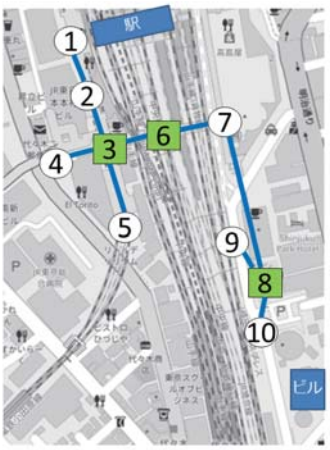


図 1: 歩行者道路網の構成．数字はノード ID を表す．四角（緑）のノードは滞在人数を観測した箇所を示す．地図 [OSM] に重ねて位置関係を示している．「駅」は JR 新宿駅，「ビル」は NTT ドコモ代々木ビルを示す．

と表すと，

$$D \simeq BY \tag{7}$$

が成り立つ．この B を滞在行列と呼ぶことにする．

各時間帯において通過人数 X と滞在人数増減 D が与えられたとき，式 (3) と式 (7) の両方をなるべく満たすような解を求めたい．そこで式 (4) の代わりに，以下の目的関数 (8) を最小化することで，経路別人数 Y を推定する．

$$\begin{aligned} &\sum_{\ell=1}^{L} \left| \sum_{i=1}^{I} A_{\ell,i} Y_{t,i} - X_{t,\ell} \right|^2 + \lambda_1 \sum_{i=1}^{I} |Y_{t,i}|^2 \\ &+ \quad \lambda_2 \sum_{m=1}^{M} \left| \sum_{i=1}^{I} B_{m,i} Y_{t,i} - D_{t,m} \right|^2 \end{aligned} \tag{8}$$

ハイパーパラメータ λ_1, λ_2 は，予備実験で観測との誤差が最小になるように調整した値を用いる．

4. データセット

4.1 道路網

東京オリンピック・パラリンピック 1000 日前「YOYOGI CANDLE 2020」のイベントで，新宿駅南口周辺に歩行者が集まった際に周辺の道路網の通過人数と滞在人数を測定した．道路網は，観測箇所を含む最低限の構造になるように，ノード 10 個，有向エッジ 18 個の有向グラフとした（図 1）．経路 r_i は，同一地点が最大 1 回しか現れない経路に限定して列挙した．今回の道路網では起点と終点によって経路が一意に決まるため，$Y_{t,i}$ は OD 交通量に対応する．

4.2 人工データ

今回の観測では経路別人数を観測しなかった．そこで，以下の手順で経路別人数が得られる人工データを生成した．時間帯の数 T は 42 個とし，各時間帯に計 500 人が移動開始する．起点の選択確率と終点の選択確率はそれぞれ多項分布に従い，どちらの多項分布も $\alpha = 0.8$ のディリクレ分布に従って生成する．生成する歩行者の起点と終点は選択確率に従って決めるが，起点と終点とが同一ノードとなった場合は，起点と終点の

表 2: 実データの推定の誤差

手法	NAE_X	NAE_D	$\mathrm{NAE}_X + \mathrm{NAE}_D$
既存手法	0.013	0.550	0.563
提案手法	0.066	0.000	0.066

選択をやり直した．上記の手順で経路別人数 Y を生成してから，式 (3) と式 (7) を用いて通過人数 X と滞在人数増減 D を求めた．乱数のシードを変えて 100 個のデータセットを作成した．

4.3 実データ

道路網上では全ての有向エッジにおいて 1 分間隔で通過人数を観測した．また，3 個のノード（イベントを観覧できるエリアに相当する）において約 5 分間隔で滞在人数を観測した．通過人数と滞在人数は，2017 年 11 月 29 日の 18 時から 21 時 30 分まで観測した．通過人数と滞在人数の観測間隔を揃えるため，通過人数を合計して 5 分間隔の時系列データを作成した．

5. 実験結果

5.1 人工データ

人工データを用いて経路別人数推定精度の評価を行った．評価尺度として，以下の標準化絶対値誤差（normalized absolute error, NAE）を用いた．

$$\mathrm{NAE}_Y = \frac{\sum_t \sum_i |\hat{Y}_{t,i} - Y_{t,i}|}{\sum_t \sum_i |Y_{t,i}|} \tag{9}$$

ただし，$\hat{Y}_{t,i}$ は $Y_{t,i}$ に対する推定値である．

通過人数の観測エッジ数は 1 本から 18 本まで変化させた．通過人数の観測対象外のエッジは，ランダムに選択した．また滞在人数の観測箇所は，実データと同一の 3 個のノードとした．図 2 にそのときの NAE_Y を示す．18 本の場合は，滞在人数の観測の有無によって誤差は変わらない．一方，通過人数の観測エッジが 1 本以上欠損している場合は，滞在人数の観測を利用した提案手法ほうが誤差が小さくなった．すなわち，通過人数の観測が不完全な場合には，滞在人数の観測値と整合するように解を求めることで，経路別人数の推定精度が向上すると言える．

しかし通過人数の観測が完全な場合でも誤差は 0.5 程度であり，十分小さいとは言えない．これは問題設定が不良設定問題であり，未知の変数の数に対して制約条件の数が少ないため避けられない誤差が残っていると考えられる．もし各ノードでの出発人数や到着人数などを観測して制約条件を追加できれば，さらに誤差を小さくことができるだろう．

5.2 実データ

実データに対して提案手法を適用して求めた経路別人数 $\hat{Y}$ から，通過人数 $\hat{X} = A\hat{Y}$ と滞在人数増減 $\hat{D} = B\hat{Y}$，滞在人数 $\hat{S}_{t,m} = S_{0,m} + \sum_{t'=1}^{t} \hat{D}_{t',m}$ を求めて，推定結果が観測とほぼ整合していることを確認した（図 3，4）．一方既存手法では，通過人数の観測には一致するが，滞在人数増減の観測には一致しない推定結果となった．観測との誤差の評価尺度として，式 (9) と同様に NAE_X と NAE_D を定義して，$\mathrm{NAE}_X + \mathrm{NAE}_D$ を用いると，提案手法は既存手法よりも大幅に推定精度が向上していることがわかる（表 2）．

提案手法で推定した経路別人数を，起点と終点で集計した結果を図 5 に示す．起点，終点，ともにノード ID が 1 または 7 のノードである歩行者が多かった．これらは新宿駅に近

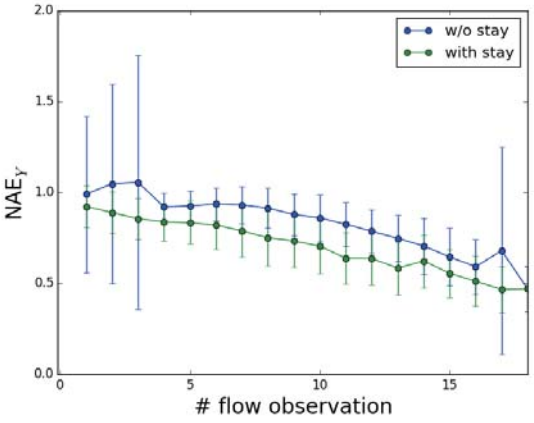


図 2: 滞在人数の有無と推定誤差の関係．横軸は通過人数を観測するエッジの数．縦軸は誤差 NAE_Y．青と緑はそれぞれ，提案手法と既存手法を示す．データセット 100 個について，平均値をプロットした．エラーバーは標準偏差を示す．

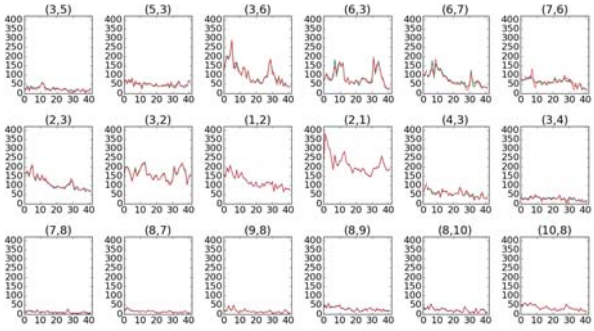


図 3: 通過人数の観測との誤差．青線が観測値 X，緑線が滞在人数を考慮しない推定値 $\hat{X}$，赤線が滞在人数を考慮した推定値 $\hat{X}$ を示す．ただし青線と緑線は重なっているため 1 本に見える．

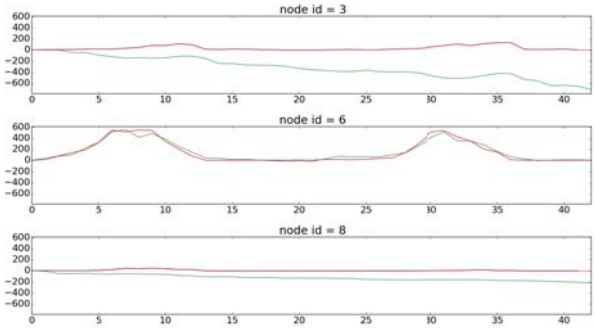


図 4: 滞在人数の観測との誤差．青線が観測値 S，緑線が滞在人数を考慮しない推定値 $\hat{S}$，赤線が滞在人数を考慮した推定値 $\hat{S}$ を示す．ただし青線と赤線は重なっているため 1 本に見える．

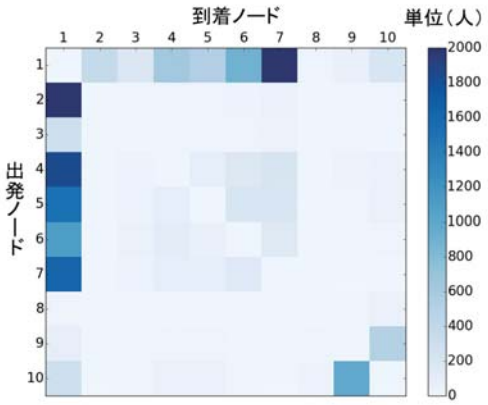


図 5: 歩行者の起点と終点の推定結果．210 分間の推定結果を経路別に合計した値をヒートマップで表示した．

いノードであり，駅の利用者が多数観測されていると考えられるため，直感と整合した妥当な結果が得られたと言える．

6. まとめ

本研究では，観測データから経路別人数を推定する問題に取り組んだ．滞在行列を用いて滞在人数の観測を推定に利用することで，推定精度を向上させられることが人工データの実験によってわかった．また，実データにおいて経路別人数の推定をすることで，イベントを開催した時間帯の人流を分析した．今後は，観測値にノイズが含まれる場合の推定精度に与える影響の調査や，得られた経路別人数をもとに将来の交通量を予測できるモデルの開発に取り組んでいきたい．

謝辞

「YOYOGI CANDLE 2020」のイベントにおける通過人数，滞在人数の測定には，株式会社 NTT ドコモの小田哲様，岡田佳之様にご協力いただき実現することが出来ました．ここに深謝します．

参考文献

[OSM] OSM, : OpenStreetMap: `https://openstreetmap.jp/`

[Zhang 03] Zhang, Y., Roughan, M., Duffield, N., and Greenberg, A.: Fast accurate computation of large-scale IP traffic matrices from link loads, in *ACM SIGMETRICS Performance Evaluation Review*, Vol. 31, pp. 206–217ACM (2003)

[安藤 11] 安藤 正幸, 高山 純一, 中山 晶一朗：交通流観測結果による Logit 型経路選択モデルの検証，土木学会論文集 D3 (土木計画学), Vol. 67, No. 5, pp. 67_I_435–67_I_453 (2011)

[金森 15] 金森 亮, 水野 敬太, 野田 五十樹, 中島秀之：滞留人口データを利用した交通手段別 OD 交通量推計手法の提案, 研究報告知能システム (ICS), Vol. 2015, No. 8, pp. 1–6 (2015)

[山下 16] 山下 倫央, 松島 裕康, 野田 五十樹：屋外大規模イベントの流動制御に向けた動的群集誘導モデルの構築, 人工知能学会全国大会オーガナイズドセッション「OS-5 交通・移動・物流とＡＩ (2)」 (2016), 1H5-OS-05b-2

[松村 14] 松村 龍太郎, 土屋 利明, 高橋 玲：2 次計画法による交流トラヒック推定法 (B-14. 情報通信マネジメント, 一般セッション), 電子情報通信学会ソサイエティ大会講演論文集, Vol. 2014, No. 2, p. 344 (2014), B-14-9

[植松 15] 植松 芳彦, 鎌村 星平, 杉山 隆太, 武田 知典, 宮村 崇, 笹山 浩二：交流トラヒック推定技術の大規模サービス統合 IP 網への適用性, 電子情報通信学会論文誌 B, Vol. 98, No. 3, pp. 255–265 (2015)

[清水 17] 清水 仁, 大塚 琢馬, 岩田 具治, 澤田 宏, 上田 修功：人流シミュレーションにおけるエージェントパラメータの推定, 第 20 回情報論的学習理論ワークショップ (IBIS2017) (2017), D2-50

[大西 15] 大西 正輝, 山下 倫央, 星川 哲也, 佐藤 和人：人の流れの計測とシミュレーションによる避難誘導の伝承支援—新国立劇場における避難体験オペラコンサートを例に—, 人工知能学会合同研究会知識・技術・技能の伝承支援研究会 (2015), SIG-KST-026-06

[大蔵 93] 大蔵 泉：交通工学., 土木系大学講義シリーズ, 初版, コロナ社 (1993)

[朝倉 94] 朝倉 康夫, 柏谷 増男, 西山 晶造：観測リンク交通量を用いた道路網交通流の日変動推定とその信頼性分析への応用, 土木学会論文集, No. 482, pp. 17–25 (1994)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

畳み込みニューラルネットワークによるチンパンジーの個体識別

Identifying Individual Chimpanzee with Convolution Neural Networks

池田 宥一郎 *1　飯塚 博幸 *1　山本 雅人 *1
Yuuichiro Ikeda　Hiroyuki Iizuka　Masahito Yamamoto

*1北海道大学 大学院情報科学研究科
Graduate School of Information Science and Technology, Hokkaido University

The development of information science in recent years has greatly contributed to studies of animal behavior. We are collaborating with Maruyama Zoo in Sapporo to reduce the load on zookeepers taking care of animals using artificial intelligence. One of our targets is to automatically create chimpanzee's Ethogram for health management and maintenance of breeding environments. Ethogram is an inventory of all behavior patterns of specific individuals and species. In order to create an Ethogram, it is necessary to identify individuals. Therefore, in this research, we examined whether each individual chimpanzee can be recognized using Convolutional Neural Networks ,which has high accuracy in image recognition field. Experimental results showed that it is possible for our system to identify individual chimpanzees.

1. はじめに

近年の情報科学分野の発展は動物行動学分野の研究に大きく寄与しており，動物の行動に関するデータを情報科学の技術を持って自動的に計測，分析を行っていく”Computational Ethology”[Anderson and Perona 14] とよばれる新領域の発展を促進している [福永と岩崎 15]．Computational Ethology においては画像や動画データにおける動物の個体識別および行動分類が課題として挙げられている．この分野の発展は情報科学分野の発展と連動しており，近年めざましい成果を上げている畳み込みニューラルネットワーク (CNN) を代表とした深層学習による画像認識技術の応用が求められている．

Computational Ethology ならびに深層学習による画像認識技術は実社会応用も求められている．札幌市円山動物園では動物の健康管理や飼育環境の整備のために，人工知能によるチンパンジーの管理システムの開発を試みている．従来は飼育員が膨大な時間と労力をかけて飼育動物に異常がないか録画したビデオを早送りして観察していた．さらに，動物の健康状態や動物同士の関係を分析するのは熟練の飼育員の経験に頼っていた．この状況を改善するため人工知能によるエソグラムの自動作成を行う．エソグラムとはある特定の個体や種の全行動パターンの目録であり，動物の行動を研究するうえでもっとも基本的な記録である．これによって飼育動物がいつ，どこで，何をしていたのか自動的に収集され，飼育動物の 24 時間監視システムの開発や，最適な環境エンリッチメント [Maple and Perdue 13] の提供ができると考えられる．自動エソグラム作成の先行研究として，加速度センサを用いて野外で行動する鳥類のエソグラムを自動生成する試みはあったが [Sakamoto et al. 09]，本研究においてチンパンジーが活動するのは閉鎖的な環境であるため，動画によってより仔細な行動の分析が可能であるとともに，センサ類を個体に取り付ける必要がないためほぼストレスを与えることなく分析できる．エソグラムを作成するためには個体の識別・トラッキング・行動分類が必要であり，特に個体の識別はエソグラムを作成する上で初めの手順となるため識別可能性を検証する必要がある．

したがって本研究では，エソグラム自動作成にむけた初期段階としてチンパンジーの各個体の識別が可能であるかを検証する．個体識別の手法としては深層学習の一種である CNN を用いる．また，個体識別の精度と汎化性を高めるために求められるデータの数や性質についても検証する．

連絡先: ikeda@complex.ist.hokudai.ac.jp



図 1: 識別する 9 頭のチンパンジー

2. データセットの作成および加工

本研究では札幌市円山動物園のチンパンジー館で飼育されている図 1 に示す 9 頭のチンパンジーの画像データを用いる．撮影環境は朝 11 時頃のチンパンジー館清掃終了後に餌が撒かれた状態で，チンパンジーがケージの中に入れられた時から撮影開始した．撮影者は 9 人であり，それぞれ異なる個体を追跡しつつ数秒おきに撮影を行い，10 分ごとに撮影する個体を交代した．これによって各個体について全撮影者の写真が含まれるため，撮影者の癖により個体分類されることを防ぐことがで

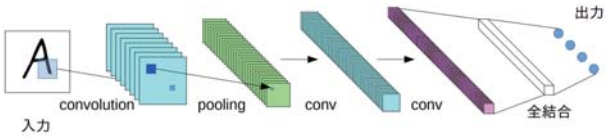


図 2: CNN の処理の流れ

表 1: CNN の構造

	縦×横×チャネル数	フィルタ
入力	128×128×3	-
C1	128×128×32	3×3
C2	128×128×32	3×3
P1	64×64×32	2×2
C3	64×64×64	3×3
C4	64×64×64	3×3
P2	32×32×64	2×2
C5	32×32×128	3×3
C6	32×32×128	3×3
P3	16×16×128	2×2
C7	16×16×256	3×3
C8	16×16×256	3×3
P4	8×8×256	2×2
FC	1×1×1024	-
出力	1×1×9	-

きると考えられる．

撮影された写真は各個体の全身が大きく映るように手動で正方形に切り抜き，128 × 128 ピクセルにリサイズした．また，身体のごく一部しか写っていないものや，ぶれが大きいもの，フォーカスが大幅に合っていないものなど，識別困難であると考えられる写真は取り除いた．また，ほぼ同様の写り方をしている画像は正答率に対して信頼性を欠くため取り除いた．以上の方法によって総数 4,986 枚の画像データを取得した．

3. チンパンジーの個体識別実験

3.1 実験設定

本研究では様々な画像認識タスクにおいて高い精度を示した CNN[LeCun et al. 98] を用いてチンパンジーの個体分類を行う．CNN とは図 2 のように画像の特徴を抽出する畳み込み層と画像をダウンサンプリングしていくプーリング層を繰り返すことで，入力画像から抽象化された特徴を抜き出すネットワークであり，画像認識分野の幅広いタスクに応用されている．なお，CNN の学習は誤差逆伝搬法により行われる．本研究では Tensorflow をバックグラウンドとする Keras をライブラリとして用いた．本研究で用いる CNN の構成は表 1 に示す通り 15 層のネットワークであり，128 × 128 ピクセルのある個体の画像を入力とし，Softmax 関数を用いて 9 頭の個体のそれぞれである確率を出力とする．誤差関数は多クラス交差エントロピーであり，Adam オプティマイザを用いた．バッチサイズは 32 とした．

実験では 2 章にて作成した 4,986 枚の画像のうち各個体ごとに訓練データとテストデータを 4 : 1 の比率でランダムに分

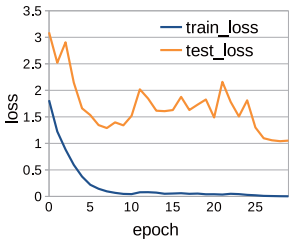


図 3: 誤差の推移

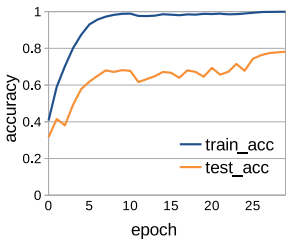


図 4: 正答率の推移

表 2: 各個体ごとのデータ数と正答率

個体名	ジェーン	ココキ	ガチャ	ハル	チャコ
データ数	257	442	659	828	520
正答率	68.2	70.2	75.4	84.4	83.8

個体名	テス	アッキー	スージー	レディ
データ数	425	671	478	706
正答率	73.4	75.4	80.6	81.8

け，訓練データ 3,982 枚，テストデータ 994 枚で 30epoch 学習する．学習は 5 回行い，そのたびに訓練データとテストデータをランダムに選び直し，正答率と誤差の推移について平均をとった．

3.2 実験結果

図 3，図 4 から，訓練データに対する平均誤差の収束が確認でき，訓練データに対する平均正答率も 1.0 近くとなっていることがわかる．テストデータに関しては平均誤差は不安定な結果となったが，平均正答率は 0.78 程度と，9 頭をランダムに分類したときの正答率の期待値である 0.11 と比べて大幅に上回る結果となった．

次に，個体ごとの分類結果の平均を示す．表 2 から，データ数の最も少ないジェーンの正答率が最も低いことがわかる．学習 5 回分の各個体のデータ数と正答率の相関係数は r=0.53(p<0.001) であり，一般的な基準で正の相関が認められた．したがって，データ数が少ないほど正答率は低くなる傾向にあると考えられ，データセットの見直しが求められる．しかし，高い正の相関は認められなかったため，正答率および汎化性を高めるためにはデータの数のみではなく質も考慮する必要があると考えられる．

4. 撮影者および撮影時間帯の違いに応じた汎化性の検証実験

4.1 実験設定

24 時間トラッキングする上で各個体の状況は多様に変化していくと考えられ，いかなる状況でも信頼できる正答率が出せるのか検証する必要がある．本実験で用いた画像データは撮影者の違いや撮影した時間帯の違いによって各個体の状況が異なっていると考えられる．したがって，加工後の画像データが全個体について一定枚数揃っている特定の撮影者 A による画像 400 枚すべてをテストデータとし，それ以外の撮影者による画像 4,586 枚を訓練データとして同様に学習を行った．

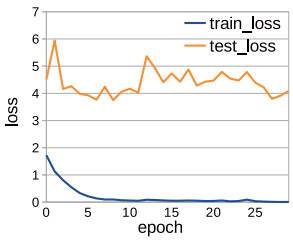


図 5: 撮影者 A 以外の画像を用いて学習した誤差の推移

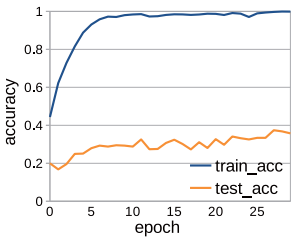


図 6: 撮影者 A 以外の画像を用いて学習した正答率の推移

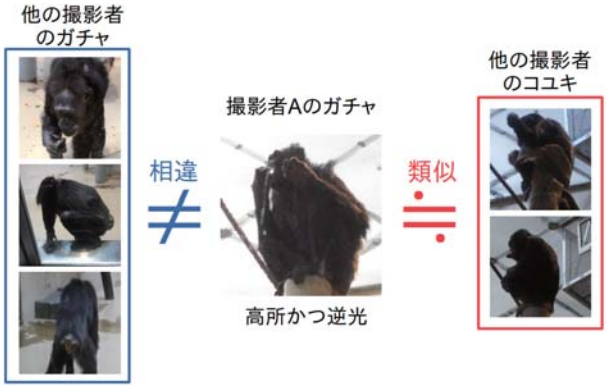


図 7: 撮影者 A のガチャと他の画像の違い

4.2 実験結果

テストデータの誤差は図 5 のように推移し，初めの epoch の学習を終えたあとテストデータの誤差がほとんど下がっていないことがわかる．正答率は図 6 のように推移し，テストデータの正答率は 38 %程度となった．

3 章における学習と比較して訓練データが増加しているにも関わらず正答率が下がってしまった原因として，やはり撮影された個体が写る角度や光量の違いが考えられる．実際のデータ例として図 7 を見てみると，コユキに誤分類された撮影者 A のガチャは逆光のある高所におり，他の撮影者のガチャとは写る角度も光量も異なることがわかる．一方で他の撮影者のコユキの中に高所にいるものが含まれ姿勢も似ていたため，コユキに誤って分類されたと考えられる．したがって，全個体について多様な時間帯の多様な写り方のデータがあれば汎化性が高まり，さらに正答率の向上が見込めると考えられる．

5. おわりに

本研究では，CNN を用いてチンパンジーの個体識別が可能であることを確認した．また，各個体のデータ数やデータの多様性に応じて正答率は変化するため，多数のデータを集めていくことが汎化性を高める上で必要であることも確認した．

今後は自動エソグラム作成にむけ，動画データにおいてチンパンジーの各個体をトラッキングし，行動の分類を行う．なお，自動エソグラム作成においては画像ではなく動画を用いるため，時系列情報を扱える．よって，動画のある特定のフレームのみで識別した結果が誤っていたとしても，過去のフレームの情報によって補完することで正しく識別させることが可能であると考えられる．したがって，時系列情報を扱える物体検出モデルの検討，および多様な動画データの収集とそれらに対する正確なラベル作成が今後の課題である．

6. 謝辞

本研究を進めるにあたり，札幌市経済観光局様，札幌市環境局札幌市円山動物園様，一般財団法人さっぽろ産業振興財団様に様々なご助言，ご援助を戴いた．ここに深謝の意を表する．

参考文献

[Anderson and Perona 14] Anderson, D. J. and Perona, P. : Toward a science of computational ethology. Neuron, 84, 18-31 (2014),

[福永と岩崎 15] 福永津嵩，岩崎渉: Computational ethology: バイオインフォマティクスと動物行動学の融合. 領域融合レビュー, 4, e003(2015)

[Sakamoto et al. 09] Sakamoto KQ, Sato K, Ishizuka M, Watanuki Y, Takahashi A, et al.: Can Ethograms Be Automatically Generated Using Body Acceleration Data from Free-Ranging Birds?. PLOS ONE, 4(4), e5379, (2009),

[Maple and Perdue 13] Maple, Terry and Perdue, Bonnie: Environmental Enrichment. 95-117 (2013),

[LeCun et al. 98] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner: Gradient-based learning applied to document recognition. Proceedings of the IEEE, 86(11),2278-2324 (1998)

Oral presentation | Organized Session | [Organized Session] OS-11

[1B2-OS-11b] [Organized Session] OS-11

Tue. Jun 5, 2018 3:20 PM - 4:40 PM Room B (4F Moon Light)

[1B2-OS-11b-01] Development of Automatic Haiku Generator Using LSTM

○Koki Yoneda[1], Soichiro Yokoyama[2], Tomohisa Yamashita[2], Hidenori Kawamura[2] （1. School of Engineering Hokkaido University, 2. Graduate School of Information Science and Technology, Hokkaido University）

3:20 PM - 3:40 PM

[1B2-OS-11b-02] Verification of Fish Species Estimation Model Based on Echo Sounder Image

○Yudai Hirama[1], Soichiro Yokoyama[1], Tomohisa Yamashita[1], Hidenori Kawamura[1], Keiji Suzuki[2], Masaaki Wada[2] （1. Hokkaido University, 2. Future University Hakodate）

3:40 PM - 4:00 PM

[1B2-OS-11b-03] Efficiency Evaluation of Smart Access Vehicle Service Using Dispatched Taxi Data in Nagoya City

○Junichi Ochiai[1], Ryo Kanamori[2], Keiji Hirata[3], Itsuki Noda[4] （1. Mirai Share Co., Ltd., 2. Nagoya University, 3. Future University Hakodate, 4. AIST）

4:00 PM - 4:20 PM

[1B2-OS-11b-04] A Development of shery prediction AI platform to optimize distribution

○Hiroaki Taka[1], Taro Osabe[2], Satoru Hanzawa[2], Hiroyuki Shioya[3], Junichi Kishigami[3], Masaaki Wada[1] （1. Future University Hakodate, 2. Hitachi, Ltd., 3. Muroran Institute of Technology）

4:20 PM - 4:40 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

LSTMを用いた俳句自動生成器の開発

Development of Automatic Haiku Generator Using LSTM

米田　航紀 *1　横山　想一郎 *2　山下　倫央 *2　川村　秀憲 *2
Koki Yoneda　Soichiro Yokoyama　Tomohisa Yamashita　Hidenori Kawamura

*1北海道大学　工学部
School of Engineering Hokkaido University

*2北海道大学　大学院情報科学研究科
Graduate School of Information Science and Technology, Hokkaido University

The creation of art using deep learning has been paid attention to in recent years.
Also, there is a haiku as an art that has long been popular in Japan.
In this research, we demonstrate the usefulness of deep learning as art creation by making haiku from motifs, which is a general method of creating haikus, using deep learning. First, we train LSTM based on a large amount of past haiku, let it generate a stringa.
Second, we extract the ones that satisfy the condition as a haiku from the generated character string and calculate the evaluation value as to whether it fits the motif image or not.
If the evaluation value is high, it is assumed that the generated haiku matches the motif image.
In this process, we conducted an experiment to confirm whether LSTM was able to learn rules as a haiku.

1. 序論

1.1 研究背景

近年, 深層学習の研究の発展により文章の翻訳や, 画像のキャプション生成など様々な場面で使用されている.

また, 中でも注目を集めている研究として絵などの芸術の生成がある. この分野では DCGAN を使用し, 絵を作成する研究 [1] 等がある.

また, 日本で古くから親しまれている芸術として俳句がある. 俳句は世界最短の定型詩とされ, 日本の伝統芸術である. 俳句の特徴として,17 音である, 季語を含んでいる, 切れ字を 1 つ以下含むといったルールが明確に決められている. そのため, 他の芸術よりも俳句はルールを使用することにより生成された句の評価が比較的行い易い. 数値的に評価することがたやすく工学的な分析が容易であるため, 深層学習に使用される損失関数の計算を定量的に行うことができる. また, 俳句は長い歴史があり日本で広く親しまれているため, 深層学習で使用される教師データが数多く存在している. 従って, 本研究では芸術の生成に深層学習を使用する一例として俳句を使用し, その有用性を検証する. 俳句や和歌を自動生成する研究は昔からされてきているが, 多くは単語を組み合わせ, 何らかの方法で評価値を出して評価が高いものを出力するという仕組みになっている.[2] 中にはディープラーニングを使用したものもあるが, 画像に基づいた俳句を生成するという試みは少ない.

1.2 本研究の目的

本研究では, 深層学習の芸術作成での有用性を示すとともに, 日本の伝統芸術である俳句の作成支援システムの作成を行う. 具体的な俳句の作成方法として, 吟行をはじめとして俳句作成において一般的な方法である「モチーフから俳句をつくる」ことに着目する. 中でもモチーフとして写真を取り上げ, 写真から俳句を作成することを俳句作成過程として, それを深層学習を用いて再現する. 深層学習が芸術作成に有用であるかを検証するため, 作成した俳句に独創性があるか, 俳句のルールを学習できているか, 画像をもとに作成できているかといった面から検証を行う.

連絡先: 米田航紀，札幌市北区北 1 4 条西 9 丁目北海道大学大学院情報科学研究科 9 階　調和系工学研究室，E-mail: yoneda@complex.ist.hokudai.ac.jp

2. データ収集

本研究に必要なデータは大きく分けて 2 種類である.

- 俳句データ
- 俳句と画像のマッチングデータ

以下, それぞれについて解説する.

2.1 俳句データ

俳句を学習する際に使用するデータである. データに含む俳人は小林一茶, 正岡子規, 高浜虚子の 3 人と, 現代の俳人多数及び大塚凱とした.

まず web 上のデータベースのスクレイピングで収集した. 大塚氏の俳句は本人に提供して頂いた. 次に読みがついていない句に対して手動で俳句の読みを付加した. 最後に 17 音になっていない俳句や季語が含まれない俳句,「(」等の記号を含む俳句は学習データとして不適であるため除外した. 最終的には計 38,506 句となった.

2.2 俳句と画像のマッチングデータ

俳句と画像との適合度を学習する際に使用するデータである. 俳句と画像を 1 組として扱うデータであり, このデータで使用する俳句は前述の俳句データで収集した俳句となる. 使用する画像は画像素材販売サイト「imagenavi」に提供していただいた画像である.

画像のアノテーションに俳句の季語が含まれていた場合, その画像と俳句を 1 組として扱うことで, 機械的に収集した. また, 手動で加えることも行った. 同様にして俳句と画像の組み合わせの候補を集め, 全国のボランティアやアルバイトの方々に, どの画像が俳句に適合しているかを判定して頂き, マッチングデータとして加えた. 最終的には 369,754 組収集した.

3. システム

本研究が構築したシステムは, 大きく分けて 3 つの構成に分けることができる.

- 俳句生成
- 俳句フィルタ
- 俳句と画像の適合判定

それぞれの部分について解説する.

3.1 俳句生成

2 章で作成した俳句のデータを入力して学習し, 学習したモデルを使用して文字列を生成する. ここでは学習部分と生成部分に分けて説明する.

3.1.1 俳句学習

本研究では文章生成において成果を上げている LSTM[3] を使用して俳句を生成する.

始めに, 学習データをシャッフルし, 学習データに使用された文字を出現順に若い番号から ID を与える. 次に, 学習データの文字をそれぞれの ID に変換し, バッチに分ける. バッチ内のサンプルは, 予め設定した BPTT の長さ分の ID の列となる. 改行文字にあたる ID が出現した場合でも, そこで区切ることはせず続行する. 最後にサンプルを先頭から順に 1-of-K 符号化し projection layer に入力してベクトルに変換する. そうして得られたベクトルを LSTM に入力する.

LSTM の出力は次に出現する文字の確率であり, 正解データは次の文字の ID 番目が 1 のワンホットベクトルである. サンプルを最後まで入力し終えた段階で LSTM の状態をリセットし, 誤差を計算する.

パラメータは LSTM 層を 3,LSTM ユニット数をそれぞれ 1024, 最適化手法を Adam, 学習率を 0.02, 減衰率を 0.99, エポック数を 300, バッチ数を 50, サンプル長を 100, 目的関数をクロスエントロピーとした.

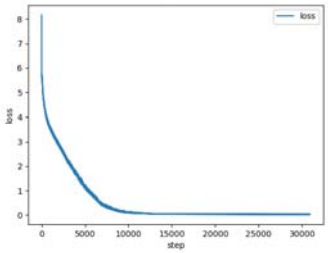


図 1: LSTM の学習の様子

3.1.2 俳句出力

学習した LSTM を使用し, 文字列を出力する.

入力を改行文字とし, 次の文字の確率を計算してルーレット選択をし, 選ばれた文字が次の入力となる. 改行文字出現してから次の改行文字が出現するまでに選択された文字列が俳句候補となる. 改行文字が指定した回数出現した際, 出力を停止する.

3.2 俳句フィルタ

俳句生成部で出力した文字列は俳句としての条件を満たしていない文字列を含んでいるため, 満たしている文字列のみを取り出す. ここでは俳句としての条件を 17 音になっている. 季語を 1 つのみ含む. 切れ字を 1 つ以下含む. この 3 つとする.

3.3 俳句とモチーフ画像の適合判定

ここでは, フィルタを通して俳句と判定された文字列の中から, モチーフ画像に適合する句を抜き出す. そのための方法として, 深層学習を使用し画像と俳句がどの程度適合するかを学習する. 適合度が高ければその俳句をモチーフ画像に基づいて生成した俳句であると定める.

前準備として, 使用する学習データに使われている漢字それぞれに出現順に若い番号から ID を与える. 適合判定では,2 章で作成した画像と俳句の組を学習データとして使用する. 負例として, 同数の画像と俳句の実在しない組を学習データと同数だけランダムに生成する.

まず学習データの画像を Inception-v3 を使用して特徴量ベクトルを得る. 次に学習データの俳句に使用されている漢字の使用回数を数え, その漢字の ID 番目の要素が使用回数となるベクトルを得る. ここまでで得られた 2 つのベクトルを結合し, 入力ベクトルとする. 適合判定では, 全結合層のニューラルネットワークに入力し, 入力された組が実在の組がどうかを判定する. 学習パラメータは中間層が 3 層でそれぞれのユニット数が 1024,512,256 ユニット, エポック数を 1000, 最適化手法を Adam, 学習率を 0.00001, 目的関数をクロスエントロピーとして学習した.

図 3 に評価例を示す. 評価値が高い俳句と評価値を示す.

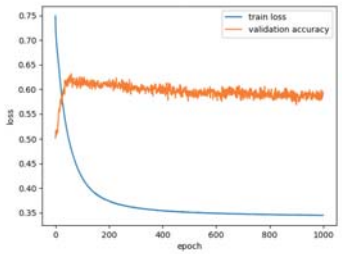


図 2: 画像とのマッチング学習

4. 実験

本研究では 3 つの実験を行う. パラメータを変化させた場合に,LSTM が俳句の性質を学習する能力がどのように変化するかを調べるとともに, 本研究で生成された俳句がモチーフ画像に適合していることを示す.

- 生成された文字列と学習データの類似度に関する実験
- 生成された文字列の俳句フィルタにかけた際の判定の割合に関する実験
- 俳句とモチーフ画像の適合度判定の妥当性に関する実験

以下ではそれぞれの実験について解説する.



日の本の桜も見えず一つ星,1.0
ものなしはうしろく見えて桜かな,1.0
花見ても肩事もなしに蘆の花,1.0
桜垣濃くらがはれと成にけり,1.0
花の春天窓の窓もあなたかな,1.0
心見や桜がさして子のわられ,1.0
死そはる花のはぐれも花見哉,1.0
小坊主が寝に来て桜咲にけり,1.0
足音の心と並ぶ桜哉,1.0

図 3: 画像とのマッチング学習結果

4.1 生成された文字列と学習データの類似度に関する実験

この実験では, 生成された文字列と学習に使用した俳句の類似度の最小値を測る実験を行う.
この実験で使用する類似度として,Levenshtein 距離を使用する.

以下のパラメータを組み合わせて学習して文字列を 10,000 行生成し, 生成した文字列を学習データとの Levenshtein 距離の最小値をそれぞれ計算した.

- LSTM 層数:2, 3
- LSTM ユニット数:256, 512, 1024

他のパラメータは 4.1.1 章で示したものと同様にした.

図 4, 図 5 に結果を示す.x 軸は最小 Levenshtein 距離,y 軸は該当する俳句の割合であり,l は層数,u はユニット数を表す.

図 4 はどちらもユニット数を 1,024 と設定したものであり, 最小 Levenshtein 割合が高い, つまり学習データと同一の文字列を出力することが多いことが分かる.

図 5 はいずれもユニット数が少ないものであり, 最小 Levenshtein 割合が高く, 学習データにあまり類似していない文字列を出力することが多いことが分かる.

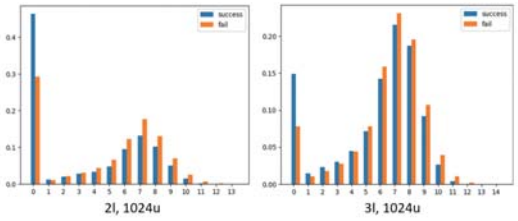


図 4: 学習データに類似した分布

4.2 生成された文字列の俳句フィルタにかけた際の判定の割合に関する実験

この実験では生成された文字列と入力データを俳句フィルタにかけて, それぞれの判定の分布から LSTM が俳句として重要である季語や切れ字と言った要素を学習できているかを調べる. 4.1 章と同様のパラメータで学習した複数のモデルでそれぞれ文字列を学習データと同数出力し, フィルタにかけて判定の内訳を見る. 図 6,7,8 に結果を示す.x 軸はそれぞれのモデルであり, 左端は学習データをフィルタにかけた際の判定結果である.y 軸はその条件で該当した俳句数を表す. 図 6 の timeout の項目は, 処理時間削減のために, 音数を探索する処理に 1 秒以上かかる場合に処理を終了した句の数を表す. 図 8 の cannot read の項目は, 切れ字判定に必要な読みを得られなかった句の数を表す.

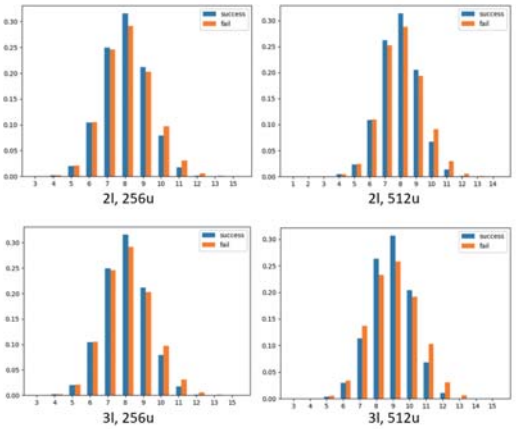


図 5: 学習データに類似していない分布

3 つの図全てにおいてユニット数が 1024 のとき, 学習データとの分布に近く, 学習データの俳句に含まれる季語や切れ字といったルールを学習できたといえる.

また,4.1 章と比較すると, フィルタの判定の分布が学習データに近くなるパラメータは学習データの句を出力する割合が高く, トレードオフの関係であることが分かる.

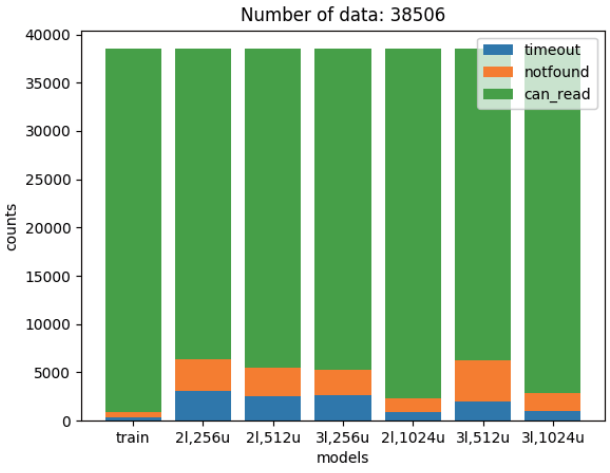


図 6: フィルタ判定分布:音数

4.3 俳句とモチーフ画像の適合度判定の妥当性に関する実験

ここでは, 俳句と画像の適合度判定が妥当であるかを実験する. フィルタを通して得られた俳句と任意の画像を入力していき, 適合度を計算する. 任意の画像に写っているキーワード

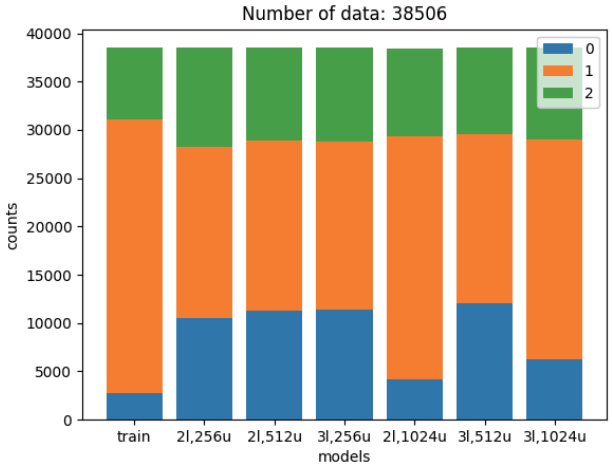


図 7: フィルタ判定分布:季語

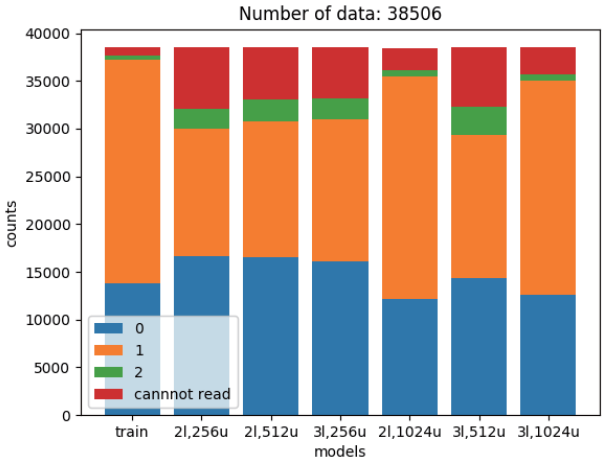


図 8: フィルタ判定分布:切れ字

を設定し, キーワードを含んでいる俳句がそれぞれの評価値でどの程度出現するか確認する. 例えば, 桜の画像なら桜というキーワードである. 結果を図 9,10,11 に示す.

図 9 はキーワードを含む句が多く高い評価をされているが, 図 10,11 は高い評価をされている句が少ない.

従って, 画像に適合する俳句を選ぶことができる画像もあるが, 精度は高くないことが分かる.

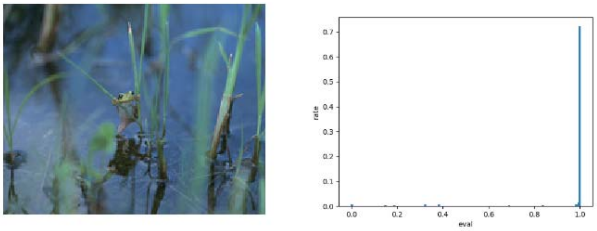


図 9: マッチング評価実験 (キーワード:蛙)

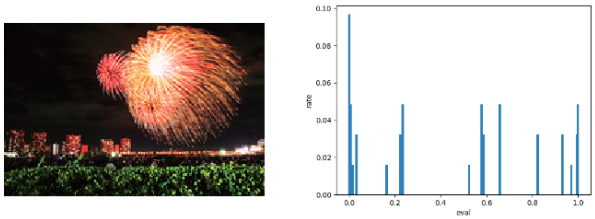


図 10: マッチング評価実験 (キーワード:花火)

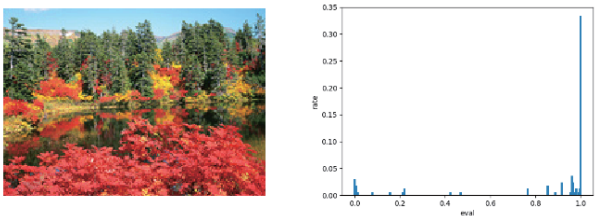


図 11: マッチング評価実験 (キーワード:紅葉)

5. 結論

本研究では一茶など過去の有名な俳人と現在の俳人の句を LSTM に大量に入力することで俳句の音数や季語などのルールを学習した. その学習済み LSTM を使用して文字列を大量に生成し, 俳句としての条件を満たすものを抜き出し, モチーフ画像と適合するかどうかを算出した.

実験結果より,LSTM を使用することで, 俳句のルールを学習できることを確認した. また, モチーフ画像と適合する俳句を抜き出すことができるが, 適合する句を高く評価できないことも多いため, 今後の課題として俳句とモチーフ画像の適合評価器の改善が挙げられる.

謝辞

本研究は札幌 AI ラボにご支援いただき実施されました.

本研究のデータ作成として, データ提供を快く引き受けてくださった大塚凱様, データ作成をお手伝いしていただいた松山市役所及び愛媛大学俳句研究会をはじめとする全国のボランティアの皆様とアルバイトの皆様には心より感謝申し上げます.

参考文献

[1] Alec Radford, Luke Metz, Soumith Chintala,"Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks",2015,arXiv.

[2] Tosa, Naoko, Hideto Obara, and Michihiko Minoh. "Hitch haiku: An interactive supporting system for composing haiku poem." International Conference on Entertainment Computing. Springer, Berlin, Heidelberg, 2008.

[3] Sundermeyer, Martin, Ralf Schlter, and Hermann Ney. "LSTM neural networks for language modeling." Thirteenth Annual Conference of the International Speech Communication Association. 2012.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

魚探音響画像に基づく魚種推定モデルの検証

Verification of Fish Species Estimation Model Based on Echo Sounder Image

平間友大 *1 Yudai Hirama
横山想一郎 *1 Soichiro Yokoyama
山下倫央 *1 Tomohisa Yamashita
川村秀憲 *1 Hidenori Kawamura
鈴木恵二 *2 Keiji Suzuki
和田雅昭 *2 Masaaki Wada

*1北海道大学大学院情報科学研究科 Graduate School of Information Science and Technology Hokkaido University
*2公立はこだて未来大学 Future University Hakodate

The overfishing and depletion of marine resources including tuna have become problems in Japan. Managing to marine resource is necessary to increase catch amount. However, set-net is difficult to separate fish speceis. Therefore, this research used a sonar image obtained by an echo sounder installed in a set-net. We verify of fish species estimation model based on echo sounder image.

1. はじめに

日本の漁獲量は 1989 年以降減少を続けており、水産資源の乱獲や枯渇が問題となっている. 乱獲によって個体数が減れば卵を産む母数が減ることに繋がるため、小さい個体に関しては逃がせるよう漁獲網の網目を大きくしたり、獲る魚種を選ぶなど漁業者ごとに対策が行われている. また、魚種ごとに漁獲量を制限する基準を設けた TAC（漁獲可能量制度）による水産資源の管理体制を整えられてきた. しかし、定置網漁法といった受動的漁法に関しては魚種を選ぶことができず、網をあげる（網起こし）までどんな魚がどれくらい入っているのかわからないのが現状である（図 1）.2017 年には北海道の定置網漁法によって産卵前の太平洋クロマグロ（30kg 以下の個体をメジマグロと呼ぶ）の漁獲量が国際規定で定められた基準を越えているなど、水産資源の管理が課題になっている. そこで、定置網漁場に魚群探知機を設置し、定置網に入った魚を可視化する取り組みが行われている [Wada 2015]. 魚群探知機から得られる音響画像から魚種を認識するシステムを開発することで、定置網を解放して魚を逃がすなど、水産資源管理に役立てることができると考えられる. さらに、網起こし前に魚種・漁獲量を推定することで船員の調整や運送コストの最適化などのメリットも見込まれる.

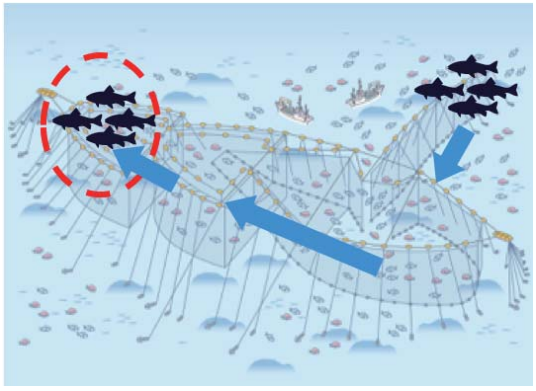


図 1: 定置網漁場のイメージ図

連絡先: 平間友大 北海道大学情報科学研究科
Email:yhirama@complex.ist.hokudai.ac.jp

2. 実験環境と魚探音響画像

北海道函館市木直漁港の定置網漁場に設置された魚群探知機からデータをサーバーに送信するシステムが開発されている [Wada 2015]. この定置網の外周は約 150m であり、魚群探知機は網上に設置されている.

この魚群探知機は 3 秒ごとに音波を発射し、その時刻と受信した反射の強度を含めたデータを 24 時間サーバーに蓄積している. 海中の様子を深さ 0.2343m 間隔で捉え、反応強度を 256 階調で表す. 音響データはこの反応強度と音波発射時刻をまとめたものである. 音響データを画像化（音響画像）する際、反応強度を画素値と捉え、255 を白色、0 を黒色のグレースケールとした.（図 2）のグレー画像が音響画像であり、魚の泳ぐ速さや習性が魚影に現れていることがわかる.

現状では 2015-16 年の 243 日分の音響画像と、獲れた魚種と漁獲量（漁獲リスト）が記録されている. この期間内に観測された魚種は、36 種類である. 漁獲リストを参考にすると 1 日に平均 12 魚種が漁獲されており、各魚種が混ざって定置網内にいることが予想される. 音響画像から魚種を特定する際、複数の魚種が映っていることを踏まえ、システムを構成する必要がある.

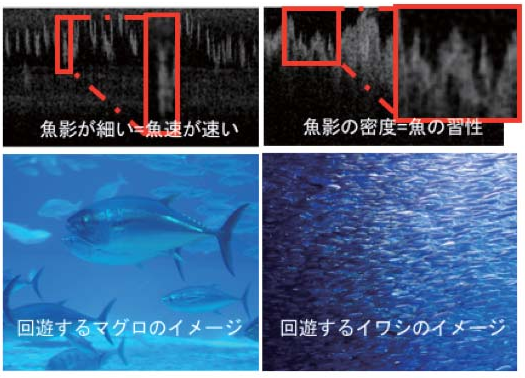


図 2: 魚種ごとの音響画像の特徴

3. 提案手法

従来の研究 [Hirama 2017] から、CNN[Krizhevsky 2012] が音響画像から魚種推定を行うことができることを示している.

音響画像を入力とし、その画像に映っている魚種を出力とする教師あり学習を行い、テスト画像に対して魚種判別を行う推定モデルを作成している. 本研究では、この手法を用いてメジマグロを対象としたテストデータに対するシミュレーションを行う. テストに用いる音響画像は網起こしの 4 時間前から 4 時間分の画像であり、これは実際に音響画像に映った魚影が漁獲リストにあることの整合性をとるために決定されている. 4 時間分の画像に対してメジマグロと判別した画像の割合を判別割合とし、この値を閾値として網を解放するかどうかを決定する手法を用いる.

3.1 畳み込みニューラルネットワーク（CNN）

CNN は畳み込み層とプーリング層による画像の特徴抽出、ニューラルネットワークによる各特徴の重み付けを行い出力値を計算する構造を持っており、学習には大量のデータを必要とすることが一般的である. 本研究では音響画像から魚種を判別することを目的とするため、音響画像を入力、判別対象の各クラスの存在確率 X を出力し、最も高いものを選択する. 本研究では、その他とメジマグロの 2 クラス分類を行う（図 3）.

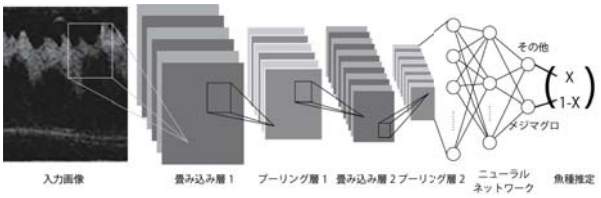


図 3: 畳み込みニューラルネットワーク

4. 教師データの作成

学習に必要な入力画像のセグメント化とアノテーションを行い、教師データを作成する.

音響画像からメジマグロと思われる範囲を目視によって抽出する. 全漁獲データ 243 日中、メジマグロの漁獲があるのは 25 日間である. その中でも目視可能な 300kg 以上の漁獲のある音響画像 8 日間を学習・検証の対象とし、アノテーションを行う. また、メジマグロではない負例のその他の音響画像は、メジマグロの漁獲がない日からランダムで 8 日間抽出する.

本実験では、横 25 ×縦 165 ピクセルにセグメントした. 定置網内の情報に例えると 75 秒間、水深約 39 メートルの範囲の海中の様子を捉えたものとなる. これを 1 枚の画像とし、音響データにエラーがある時間帯は画像化しない. 生成した画像枚数は、メジマグロ約 2 万枚、その他約 2 万枚である. このうち約 3 万枚を学習データとし、残り約 1 万枚を検証データとする.

5. 実験結果と考察

メジマグロ画像とその他の画像合わせて 12 日間を学習データ、4 日間を検証データとした 4 分割交差検証を行った. 最も精度の高いモデルにおいて、2epoch 時に約 86 %の正答率を示した.3. で述べた判別割合を閾値とし、メジマグロの漁獲削減量と誤判別によるその他の魚種の損失量を（図 4）に示す. 判別割合 0.3 を閾値とした場合、メジマグロの削減量は過去 2 年間で 4,494/5,395(kg) であり、誤判別によるその他の損失量は 180,439kg/548,720(kg) となった. メジマグロの削減量と誤判別によるその他の魚種の損失量はトレードオフの関係である. しかし、誤判別した画像は検証データに含まれていないパターンの負例画像が多く、学習で用いる負例画像を十分に検証していく必要があると考えられる.

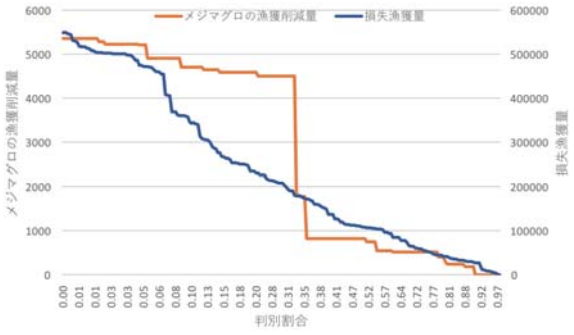


図 4: 判別割合によるメジマグロの削減量と損失量

6. まとめ

メジマグロをはじめとした水産資源管理により、定置網漁場などの受動的漁法では魚種推定システムが求められている. そこで、定置網内に魚群探知機を設置し、CNN を用いて魚探音響画像を学習して魚種推定モデルを作成した. 検証データにおいて 86 %の判別精度を得たが、テストデータから誤判別の改善には負例データを十分に設計する必要があることが分かった. 今後は負例データの検証や、漁業者による教師データのアノテーションを行なっていく.

謝辞

本研究は、公益財団法人北海道科学技術総合振興センター「地域産学官 AI/IoT 実証モデル委託事業」の支援により実施しています. ここに記して謝意を表します.

参考文献

[Wada 2015] Ramadhona Saville, Katsumori Hatanaka, Masaaki Wada: ICT application of real-time monitoring and estimation system for set-net fishery, Proceedings of OCEANS'15 MTS/IEEE Washington(2015).

[Hirama 2017] Yudai Hirama, Soichiro Yokoyama, Tomohisa Yamashita, Hidenori Kawamura, Keiji Suzuki, Masaaki Wada: Discriminating Fish Species by a Echo Sounder in a Set-Net Using a CNN, The 21st Asia Pacific Symposium on Intelligent and Evolutionary Systems(2017).

[Krizhevsky 2012] Krizhevsky, Alex, Ilya Sutskever, and Geoffrey E. Hinton: Imagenet classification with deep convolutional neural networks, Advances in Neural Information Processing Systems(2012).

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

名古屋市のタクシー配車データを用いた Smart Access Vehicle Service の効率性評価

Usability Evaluation of Smart Access Vehicle Service Using Dispatched Taxi Data in Nagoya City

落合純一[*1] Junichi Ochiai
金森亮[*2] Ryo Kanamori
平田圭二[*3] Keiji Hirata
野田五十樹[*4] Itsuki Noda

[*1] 株式会社未来シェア Mirai Share Co., Ltd.
[*2] 名古屋大学 Nagoya University
[*3] 公立はこだて未来大学 Future University Hakodate
[*4] 産業技術総合研究所 AIST

This paper presents a simulation evaluation of Smart Access Vehicle Service (SAVS) using dispatched taxi data in Nagoya city. Recently, demand responsive transports (DRTs) are getting a lot of attention not only in rural areas, but also in urban areas. Because reservations are necessary at least several hours before to use DRTs, most of the DRTs are low convenience. On the other hand, SAVS is a DRT, which can be provided in real time. Therefore, SAVS can convert exclusive taxi services to shared taxi services. The simulation results for multiple time zones with different OD patterns and demand numbers indicate that SAVS can dispatch more efficiently than the taxi service.

1. はじめに

従来，採算が取れない地方公共交通の再構築の手段としてデマンド応答型交通（DRT）は注目されていた[国交省 13][国交省 14]. 公共交通が十分に発達していない地方都市では，自家用車が移動手段として必須となっている. 自家用車が普及するほど公共交通の利用者は減るため，採算が取れない公共交通のサービスの質は低下し，さらに公共交通の利用者は減るという悪循環となってしまっている. その結果，電車や路線バスを容易に利用できない公共交通の空白地域や，ほぼ乗客がいない路線バスが運行する状況が発生してしまう. この状況を打開するため，DRT が運用されてきた.

近年，都市部でも DRT が注目されてきている. タクシー事業者からなる全国ハイヤー・タクシー連合会[1]によると，平成 27 年のタクシー運転手の平均年齢は 59.0 歳であり，タクシー運転手の高齢化と今後のタクシー運転手の減少が懸念されている. また，イベントや天候による需要の不安定さにより，タクシー待ちの長蛇の列が発生する場合がある. このような問題点を解決するため，タクシーの新しいサービスとして，2018 年 1 月より東京都で，同年 2 月より愛知県で乗合タクシーの実証実験が始まった.

本稿では，愛知県名古屋市を対象に，独占型サービスのタクシーを共有型サービスの乗合タクシーに置き換えた場合の効果をシミュレーションで評価する. シミュレーションは，2016 年 10 月 26 日水曜日のタクシー配車データを利用し，OD パターンとデマンド数が異なる 4 つの時間帯（終電後の 0:00-2:00，出勤時の 8:00-10:00，昼間の 14:00-16:00，需要ピーク時の 19:00-21:00）を対象とする. 車両数を 100-600 台の間で変化させ，待ち時間，乗り合いによる迂回時間，乗合回数を比較することで，乗り合いの効率性を評価する.

連絡先：落合純一，株式会社未来シェア，北海道函館市美原 2-7-21 万勝ビル 1F，0138-85-8991，ochiai@miraishare.co.jp

[1] http://www.taxi-japan.or.jp/

2. Smart Access Vehicle Service（SAVS）

2.1 概要

筆者らは，持続可能な公共交通を構築するために SAVS を提案した[中島 16]. SAVS の主な特徴の一つに，リアルタイムに提供可能なドア・ツー・ドアの DRT がある. 従来の DRT は，数時間前までの予約が必要なことや，乗降位置が固定されていることなど，利便性が高いサービスとはいえない. そこで，いつでも，どこでも，利用可能な DRT を SAVS の基幹技術として導入した. この技術に関してはシステム実装も行っており，北海道函館市，東京都お台場エリア，長野県諏訪市，鳥取県境港市などで実証実験を行い，その有用性を示してきた.

2.2 配車計算

SAVS で処理されるデマンドは，独占型の交通サービスであるタクシーと同様のデマンド状態遷移を持つ（図 1）. 停留所などの目印がないドア・ツー・ドアの交通サービスでは，車両が乗車位置に到着後，利用者と車両が互いに探し合うことを考慮する必要がある. 本稿では，これをランデブー時間と定義する.

SAVS は，時々刻々と発生するデマンドに対して，リアルタイムにデマンドごとに配車計算し[野田 08]，その結果を利用者に通知する. 実サービスを考えると，新たに発生したデマンドの配車計算によって，既存の車両に割り当てられているデマンドに何かしらの変更が生じた場合，利用者に通知する必要がある. 過剰な通知は利用者にとって好ましくないものであるため，SAVS の配車計算では下記の制約を導入している.

- 既存デマンドの車両の変更を行わない
- 車両のルートの順序関係を保持する

これにより，既存デマンドには大きな変更は生じず，新規デマンドに対しては全探索が可能となっている.

しかし，SAVS は乗り合いを許容する交通サービスであることから，新規デマンドの割り込みにより，既存デマンドの乗車・降車に遅延が生じることがある. SAVS では，許容遅延時間の最大値を制約として考慮している. SAVS のパラメータを表 1 に示す.

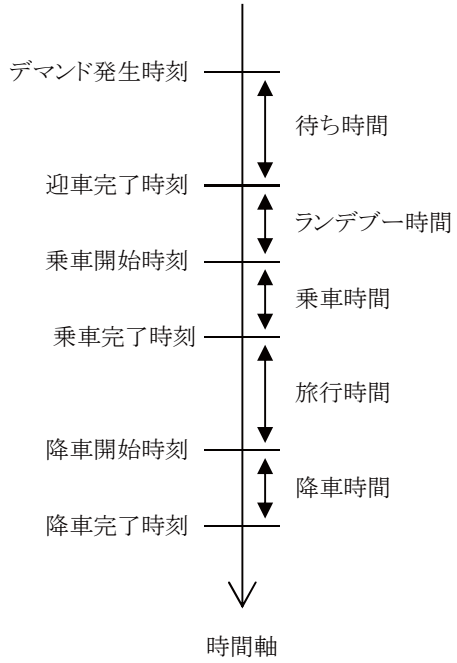


図 1　SAVS のデマンドの状態遷移

表 1　SAVS の配車計算のパラメータ

パラメータ	意味
車両速度	平均速度(km/h)
ランデブー時間	利用者と車両が探し合う時間
乗車時間	1 人あたりの乗車に要する時間
降車時間	1 人あたりの降車に要する時間
許容遅延時間	既存デマンドに対する遅延の最大値

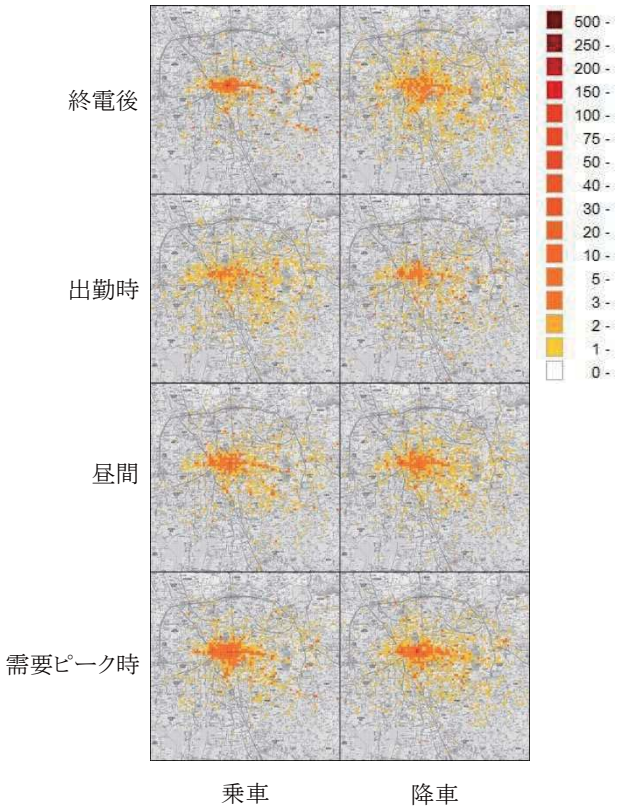


図 2　時間帯ごとの OD パターンとデマンド数

表 2　時間帯ごとの OD の最短経路長

時間帯	最小値	最大値	平均値
終電後	134	17526	3723
出勤時	165	19886	3112
昼間	118	16191	2569
需要ピーク時	118	16070	2601

3. シミュレーション方法

3.1 道路網データ

道路網データは，フリーの地理情報データであるオープンストリートマップ(OSM)[2]を利用した．対象エリアは，名古屋市中心街を含む 22km 四方(緯度 35.04-35.24，経度 136.79-137.03)とした．道路種別は，有料道路と狭い道路を除き，trunk，primary，secondary，tertiary，unclssified，residential の 6 種を用いた．これらの道路種別による対象エリアの道路網データは，ノード数が 115024，リンク数が 310914 であった．

3.2 タクシー配車データ

本研究では，終電後の 0:00-2:00，出勤時の 8:00-10:00，昼間の 14:00-16:00，需要ピーク時の 19:00-21:00 の 4 つの時間帯を対象とし，2016 年 10 月 26 日水曜日のタクシー配車データを利用した．図 2 に時間帯ごとの乗降位置を，表 2 に時間帯ごとの OD の最短経路長を示す．図 2 を見ると，終電後の乗車位置は主に集中しているが，終電後の降車位置は疎らであることがわかる．出勤時は，乗車位置よりも降車位置の方が中心部に集中している．昼間と需要ピーク時は，乗車位置と降車位置に目立った違いは見られないが，昼間よりも需要ピーク時の方が赤い面積が広くなっている．終電後は中心部から郊外へ，出勤時は郊外から中心部へ，昼間と需要ピーク時は中心部内の移動が考えられる．よって表 2 より，終電後と出勤時は，昼間と需要ピーク時よりも移動距離が長い．

タクシー配車データには，利用者の乗降位置，利用者の乗降時刻が含まれているが，人数は含まれていなかった．よって，すべてのデマンドは 1 人と仮定した．また，タクシー利用者が移動を思い立った時刻は不明であるため，乗車時刻をデマンド発生時刻と仮定した．

図 1 において，乗車完了時刻と降車完了時刻はタクシー配車データに含まれているため，利用者ごとの旅行時間と降車時間の和はデータとして存在する．OSM データにより OD 間の最短経路長は求まるため，車両速度(表 1)を与えることで旅行時間は求まる．よって，車両速度と降車時間を変数とすることで，タクシー配車データとの誤差が求まる．車両速度と降車時間に対して旅行時間と降車時間の和を計算した結果とタクシー配車データとの誤差を図 3 に示す．図 3 は，青に近いほど計算結果とタクシー配車データの誤差が小さく，赤に近いほど誤差が大きいことを意味している．各時間帯で誤差が最も小さくなる車両

[2] http://www.openstreetmap.org

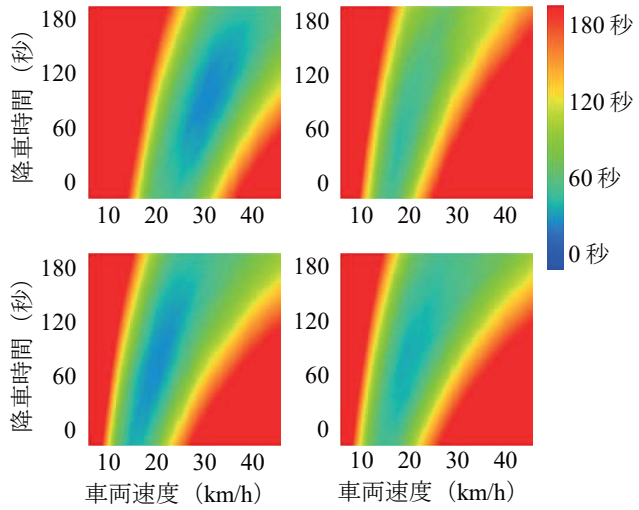


図 3 タクシー配車データに基づく車両速度と降車時間（左上：終電後，右上：出勤時，左下：昼間，右下：需要ピーク時）

表 3 各時間帯の車両速度と降車時間

時間帯	車両速度（km/h）	降車時間（秒）
終電後	27.8	92
出勤時	19.1	62
昼間	21.2	86
需要ピーク時	20.0	81

速度と降車時間を表 2 に示す．図 3 と表 2 より，終電後の車両速度は他の時間帯より速い傾向があり，出勤時の降車時間は他の時間帯より短い傾向があることがわかる．

3.3 配車計算の目的関数とパラメータ

本研究では，式(1)を配車計算の目的関数とした．

$$\min \sum_{i=1}^{n} (w_i + d_i) . \quad (1)$$

$$d_i = t_i - s_i . \quad (2)$$

ここで，nは未降車のデマンド数，w_iはデマンドiの待ち時間，t_iはデマンドiの旅行時間，s_iはデマンドiの最短経路での旅行時間である．よって，式(2)で計算されるd_iは，デマンドiの乗り合いによる迂回時間を意味している．これにより，なるべく利用者が待たずに車両に乗れ，なるべく効率的に乗り合いして利用者を運ぶことを可能にしている．

表 1 で述べたパラメータに関して，車両速度と降車時間は表 2 の値を用いた．ランデブー時間と乗車時間はタクシー配車データから推定できないため，シミュレーションでは 0 秒とした．許容遅延時間を 0 秒とすると，新規デマンドは既存デマンドの後ろにのみ割り当てられることになる．シミュレーションでタクシーと SAVS を平等に比較するため，許容遅延時間を 0 秒としてシミュレーションした結果をタクシーの結果と仮定した．許容遅延時間が 0 秒のとき，式(1)のd_iは 0 となるため，タクシーとしての配車計算は待ち時間を最小化することになる．一方，SAVS の許容遅延時間は 24 時間としてシミュレーションした．

4. シミュレーション結果

シミュレーションは，車両の定員を 3 人とし，車両数を 100 台から 600 台まで変化させ，待ち時間，乗り合いによる迂回時間，乗合回数を比較した．

4.1 待ち時間による比較

平均待ち時間（分）に関して，タクシーと SAVS を比較した結果を表 3 に示す．リアルタイムに提供する交通サービスの利便性として，待ち時間 10 分をしきい値として仮定し，待ち時間 10 分以下となる箇所に下線を記した．

表 3 より，すべての時間帯で，タクシーより少ない車両数で SAVS は車両待ち時間 10 分を満たしていることがわかる．同様に，同じ車両数であれば，SAVS はタクシー以下の待ち時間が得られている．タクシーの場合，新規デマンドは車両のルートの後ろに追加されるだけであるが，SAVS は状況に応じて割り込みが発生する．これにより，タクシーよりも早く車両に乗ることが可能となっている．一般的に，利用者にとっての DRT のメリットとして，乗り合いによる割引運賃がある．それに加え，需要に対して車両数が足りていない状況ほど，SAVS を運用することで，利用者は早く乗車できることも大きなメリットであると言える．

4.2 乗り合いを考慮した比較

表 3 より，SAVS はタクシーよりも待ち時間が小さいことが言えたが，乗り合いの不便さを考慮しなければタクシーとの平等な比較とは言えない．乗り合いによる平均迂回時間（分）と平均乗合回数を表 4 に示す．ここで，迂回時間は式(2)で計算されるものであり，乗合回数は乗ってから降りるまでに何組の他人と顔を合わせたかを表すものである．例えば，ある車両が A の乗車，B の乗車，B の降車，C の乗車，C の降車，A の降車のルートで移動した場合，A は B と C と顔を合わせているため，A の乗合回数は 2 である．一方，B と C はそれぞれ A のみと顔を合わせているため，B と C の乗合回数は 1 である．

表 4 より，ほとんどの状況で，SAVS の待ち時間削減の効果の方が，乗り合いによる迂回時間の影響より大きいことがわかる．しかし，需要ピーク時の車両 600 台の結果のように，需要に対して十分な車両数を稼働できるとき，乗り合いの迂回時間の影響で，タクシーより SAVS の方が非効率になってしまっている．車両数が足りている状況では，タクシーでも SAVS でも空席の車両がすぐ迎えに行くことができる．しかし，時々刻々と発生するデマンドごとに配車計算するため，その後に発生するデマンドを正確に予測できないかぎり，結果的に非効率な乗り合いになってしまう可能性がある．

タクシーと SAVS を比較して，最も乗り合いの効果が高いのは終電後である．終電後は乗車位置が中心部に集まっており，中心部から郊外への移動距離も長いため，効率的な乗り合いが発生しやすいと考えられる．さらに，需要に対して車両数が足りていると考えられる 600 台の結果においても，平均して 1 回以上は乗り合いが発生しており，他の時間帯と異なる傾向が得られた．一方，出勤時の乗り合いの効果は低かった．出勤時の OD パターンは終電後と逆で，降車位置が中心部に集中しており，終電後と同様に移動距離は長い．乗車位置が疎らな場合，時々刻々と発生するデマンドごとに配車する結果，車両も常に動き回るため，似ている OD のデマンドが少し異なる時刻で発生してしまうと，異なる車両に割り当てられてしまう．よって，降車位置が集中しているよりも，乗車位置が集中していることの方が SAVS にとって重要である．

中心部内の移動である昼間と需要ピーク時に関しては，昼間よりも需要ピーク時の方が乗り合いの効果が高い．この 2 つの時

表 4 タクシーと SAVS の平均待ち時間(分)の比較

車両数	終電後		出勤時		昼間		需要ピーク時	
	タクシー	SAVS	タクシー	SAVS	タクシー	SAVS	タクシー	SAVS
100	161	55	87	32	125	41	259	118
150	69	18	33	12	43	11	133	39
200	31	12	16	9	12	7	69	16
250	19	10	10	7	6	6	36	10
300	15	9	9	7	5	6	22	8
400	12	8	6	5	4	4	10	6
500	11	7	5	4	4	4	7	6
600	10	7	4	4	4	4	5	5

表 5 平均迂回時間(分)と平均乗合回数

車両数	終電後		出勤時		昼間		需要ピーク時	
	迂回時間	乗合回数	迂回時間	乗合回数	迂回時間	乗合回数	迂回時間	乗合回数
100	5	1.90	3	1.37	4	1.68	5	2.02
150	3	1.71	2	0.80	2	1.00	4	2.03
200	3	1.50	1	0.49	1	0.50	3	1.74
250	2	1.37	1	0.28	0	0.29	2	1.34
300	3	1.37	0	0.22	0	0.26	2	1.12
400	2	1.24	0	0.13	0	0.13	1	0.81
500	2	1.15	0	0.07	0	0.11	1	0.64
600	2	1.11	0	0.04	0	0.10	1	0.52

間帯は乗車位置も降車位置も規則性はないため，デマンド発生頻度が低いと似た OD のデマンドが発生せず，乗り合いが効率的に行われないことが考えられる．よって，規則性がないドア・ツー・ドアの運用では，デマンド発生頻度を事前調査することが重要となる．

5. おわりに

本稿では，現実の名古屋市のタクシー配車データを用いて，SAVS の乗り合いの効果について述べた．OD パターンとデマンド数が異なる終電後，出勤時，昼間，需要ピーク時の 4 つの時間帯を対象に，定員 3 人の車両を 100-600 台で変化させてシミュレーションを行った．シミュレーション上で SAVS とタクシーを平等に比較するため，新規デマンドのルートの割り込みが発生しない設定でシミュレーションした結果をタクシーの結果として用いた．シミュレーション結果により，乗車位置が集中していることと，デマンド発生頻度が高いことが乗り合いを効率的に行う上で重要なことがわかった．

今後の課題として，需要予測を考慮してシミュレーションを行うことがあげられる．需要予測を考慮していない本研究では，時々刻々と発生するデマンドの OD パターンによっては，タクシーよりも SAVS の方が非効率になってしまうケースがあった．これは，需要予測を考慮することで解決できると考えられる．また，出勤時のように乗車位置が疎らで降車位置が集中している場合，需要予測を考慮することで，終電後と同様の効率が得られると考えられる．

謝辞

本研究に取り組むにあたり，つばめ自動車株式会社の天野清美様からタクシー配車データをご提供頂き，タクシー業務について貴重なご助言を頂いた．また，本研究の一部は，総務省戦略的情報通信研究開発推進事業(SCOPE)地域 ICT 振興型研究開発 162301003 の助成によって行われた．

参考文献

[国交省 13] 国土交通省: デマンド型交通の手引き，入手先〈http://wwwtb.mlit.go.jp/hokushin/hrt54/com_policy/pdf/5-1demand.pdf〉，2013.

[国交省 14] 国土交通省: 続・デマンド型交通の手引き，入手先〈http://wwwtb.mlit.go.jp/hokkaido/bunyabetsu/tiikikoukyoukoutsuu/31manyuaru/10zokudemandotebiki_tyuubu.pdf〉，2014.

[中島 16] 中島秀之，小柴等，佐野渉二，落合純一，白石陽，平田圭二， 野田五十樹， 松原仁: Smart Access Vehicle System: フルデマンド型公共交通配車システムの実装と評価，情報処理学会論文誌，Vol.57，No.4，pp.1290-1302，2016.

[野田 08] 野田五十樹，篠田孝裕，太田正幸，中島秀之: シミュレーションによるデマンドバス利便性の評価，情報処理学会論文誌，Vol.49，No.1，pp.242-252，2008.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

流通の最適化のための漁場予測 AI プラットフォームの開発

A Development of fishery prediction AI platform to optimize distribution

高博昭 *1 Hiroaki Taka　長部太郎 *2 Taro Osabe　半澤悟 *2 Satoru Hanzawa　塩谷浩之 *3 Hiroyuki Shioya　岸上 順一 *3 Junichi Kishigami　和田雅昭 *1 Masaaki Wada

*1公立はこだて未来大学 Future University Hakodate　*2日立製作所 Hitachi, Ltd.　*3室蘭工業大学 Muroran Institute of Technology

In this study, we aim to develop a fishery prediction AI platform. In this platform, catch amount data and environment data are stored in a database. The future catch amount is predicted by AI using the stored data. The platform will offer two advantages: optimization of distribution material such as the size of tracks, the number of tracks, the number of packing material, and the amount of ice; and giving added value to marine products. We predicted the catch amount of squid, salmon, and yellowtail by Neural Networks. However, the prediction error is still large. Therefore, we plan to improve the prediction error, and collect more long-term catch amount data and environment data.

1. はじめに

近年，北海道で水揚される水産物の水揚量の傾向が変化している．例えば，マリンネット北海道 *1 で提供されているデータによれば，北海道では主要な魚種であるサケやイカなどの水揚量の減少が続く一方で，これまでほとんど漁獲されることがなかったブリの水揚量の増加傾向が見受けられる．また，この問題は単に北海道に限った問題ではなく，日本各地において水産物の水揚量の傾向が変化している．地域経済を支える水産業の持続性を確保するためには，単に環境に適応した漁業を実現するだけではなく，漁業と加工や小売を結ぶ流通業の効率化も実現する必要がある．

本研究では，主に流通事業者を対象とした，未来の水揚量および漁場の予測を行うための AI プラットフォームの実現を目指す．本稿では，プラットフォームの概要とニューラルネットワークによる予測結果を中心に述べる．

2. 漁場予測 AI プラットフォーム

本節では，漁場予測 AI プラットフォームの概要と，プラットフォームがもたらす効果について述べる．

2.1 プラットフォームの概要

図 1 に，本研究で実現を目指している漁場予測 AI プラットフォームの概要を示す．このプラットフォームでは，各漁港での魚種ごとの水揚データと，海水温などの環境データを取得し，データベースで一元管理する．また，過去の水揚データおよび環境データから，AI によって各漁港における各魚種の水揚量の予測を行う．予測した結果は，専用のアプリケーションによって流通事業者に提供し，流通事業者の意思決定支援を行う．

2.2 プラットフォームによる効果

本プラットフォームによる恩恵は，二点あると考えられる．まず一点目は，流通資材の最適化が可能になることである．例えば，各地の水揚量に応じて，トラックの大きさやその台数，水産物を保存するための木箱，発泡スチロールなどの梱包材の数量や，鮮度を保つための氷の量などを適切に選択することが可能になる．

もう一点は，迅速な手配が可能になることによる高付加価値化である．事前に水揚が予測されることによって，水産物の鮮度を保ったまま，今まで以上に早く集荷・配送することが可能となり，水産物を集荷する際の輸送経路の最適化にもつながることが期待される．これにより，迅速化による付加価値を付与することができるとともに，飲食店や小売店などへの提供もスムーズに行うことができる．

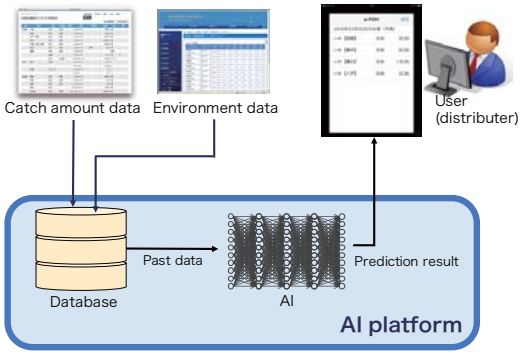


図 1: 漁場予測 AI プラットフォーム

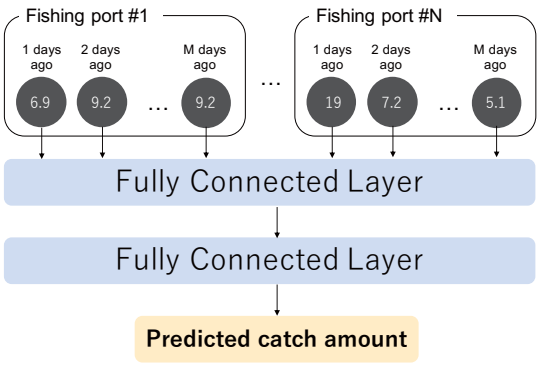


図 2: ニューラルネットワークによる漁場予測

連絡先: 高博昭, 公立はこだて未来大学, 〒 041-8655 北海道函館市亀田中野町 116-2, taka[at]fun.ac.jp

*1 http://www.hro.or.jp/list/fisheries/marine/

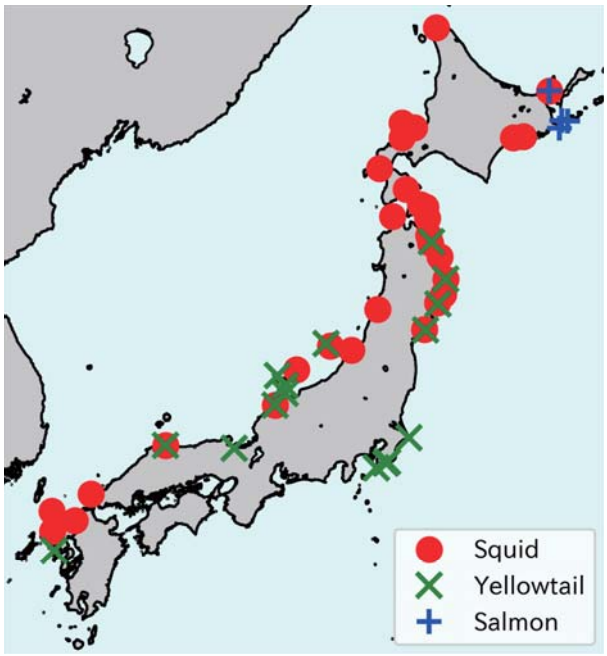


図 3: 対象とした漁港の分布

3. 予測

本研究では，北海道での主要な魚種であり観光資源としても有名であるスルメイカとサケ，北海道ではほとんど漁獲されることがなかったブリの 3 魚種を対象とした予測を実施した．本節では，予測方法と予測結果について述べる．

3.1 予測方法

今回，ニューラルネットワークを用いてスルメイカ，ブリ，サケの水揚量予測を行った．現状，日本各地の環境データの取得はできていないため，時事水産情報 *2 で提供されている各漁港の魚種ごとの水揚データのみを用いた．

図 2 に，ニューラルネットワークによる予測の概念図を示す．ニューラルネットワークへの入力は，N 漁港分の過去 M 日分の過去の水揚データとし，出力は特定の漁港の予測水揚量とした．したがって，入力ユニット数は $N \times M$，出力ユニット数は 1 となる．複数の漁港の水揚データを対象とした理由は，今回対象とした魚種はいずれも回遊魚であるため，複数の異なる漁港のデータを用いれば，回遊の傾向によって水揚量を予測できると考えられるためである．なお，水揚データは 2006 年以降のデータを使用した．

スルメイカの予測については，$N = 30$，$M = 30$，ブリについては，$N = 16$, $M = 30$ とし，中間層は 2 層の全結合層として通年の予測に取り組んだ．中間層のユニット数は対象とする魚種・漁港によって異なる．一方，サケについては，時事水産情報で提供されるデータはほぼ北海道内のものに限られていたこと，また 9 月〜11 月のみにデータが集中していたことから，他の 2 魚種とは異なるアプローチで予測を実施した．具体的には，$N = 4$，$M = 14$ とし，水揚データに加えて，予測する週に対応する週番号を入力することとした．中間層は 3 層の全結合層 (ユニット数は入力に近い層から順に 200-100-100)，出力は各漁港の 1 週間の予測水揚量とした．したがって，入力ユニット数は $4 \times 14 + 1 = 57$，出力ユニット数は $4 \times 7 = 28$ となる．

*2 http://suisan.jiji.com/apps/

表 1: 各魚種の漁港ごとの予測誤差

Fish species	Fishing port	Prediction error (t)
Squid	Wakkanai	5.29
	Rausu	2.64
	Hakodate	2.03
	Hachinohe	0.14
Yellowtail	Hachinohe	3.03
	Ishinomaki	6.18
	Choshi	8.16
	Kanazawa	3.27
Salmon	Nemuro	1.71
	Habomai	3.41
	Ochiishi	1.71
	Rausu	8.53

図 3 に，今回の予測でデータを用いた漁港の位置を示す．いずれの魚種も，水揚量が上位の漁港を選択している．スルメイカについては北海道や三陸，本州日本海側の漁港，ブリは三陸，本州日本海側，房総半島沖，サケについては北海道道東地方の漁港を中心に選択した．

3.2 予測結果

表 1 に，各魚種について主要な漁港の予測誤差を示す．スルメイカについては，八戸の予測誤差が 0.14t と低いものの，他の漁港についてはいずれも 1t を超える予測誤差となった．同様に，ブリとサケについても，いずれの漁港も 1t 以上の誤差が生じていることが分かる．2.2 節では，本プラットフォームのメリットとして，流通資材の最適化が可能になる点をあげている．しかし，現状の予測誤差の数値では，トラックのサイズや台数などの最適化は実現できないと考えられるため，さらなる精度向上が必要である．

4. まとめ

本稿では，本研究で開発を目指している漁場予測 AI プラットフォームの概要と，現時点での水揚量の予測結果について述べた．プラットフォームの仕組み自体はほぼ完成しているものの，AI による予測誤差が大きく実用化までには至っていない．今後は，予測精度の改善につとめ，北海道，さらには日本全国の水産業の持続的発展に貢献することを目指す．

現時点では，水揚データのみを用いた予測となっている．また，水揚データについても 2006 年以降からの 10 年程度のデータしか得られていない．そのため，より長期間の水揚データと，まだ使用できていない環境データを入手・蓄積する必要がある．また，ニューラルネットワークのパラメータチューニングや，ニューラルネットワーク以外の機械学習の方法なども検討する必要がある．

謝辞

本研究は，本研究は公益財団法人北海道科学技術総合振興センター地域産学官 AI/IoT 実証モデル委託事業の支援を受けたものである．関係者諸氏に深謝する．

[1C1] [General Session] 5. Web Intelligence

座長:黄 宏軒（理化学研究所革新知能統合研究センター）

Tue. Jun 5, 2018 1:20 PM - 2:40 PM Room C (4F Orchid)

[1C1-01] Assigning BSH Headings to People on the Web

○Masayuki Shimokura[1], Harumi Murakami[1] （1. Osaka City University）

1:20 PM - 1:40 PM

[1C1-02] Developing an Interface for Beginning Application Sharing Smartly in a Group of Cooperative Work

○Satoru Iwata[1], Tadachika Ozono[1], Toramatsu Shintani[1] （1. Department of Computer Science, Graduate School of Engineering, Nagoya Institute of Technology）

1:40 PM - 2:00 PM

[1C1-03] Recommender System using Image Shape Feature for CNN

○Yufeng Duan[1], Ryosuke Saga[1] （1. Osaka Prefecture University）

2:00 PM - 2:20 PM

[1C1-04] Combining semi-supervised learning and singular value decomposition to Cold-Start problem

○Takumi Uchida[1], Kei Nakagawa[1,2], Kenichi Yoshida[1] （1. University of Tukuba, 2. Nomura Asset Management Co., Ltd）

2:20 PM - 2:40 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

Web 上の人物への BSH の付与
Assigning BSH Headings to People on the Web

下倉 雅行 Masayuki Shimokura
村上 晴美 Harumi Murakami

大阪市立大学大学院創造都市研究科
Graduate School for Creative Cities, Osaka City University

We investigate a method that assigns Basic Subject Headings (BSH) 4th edition to the results of web people searches to help users select and understand people on the web. By assigning BSH headings to people, well-formed keywords can be assigned. In this paper, we examine the following combination of factors: (a) web-page rank, (b) position inside HTML, (c) synonyms, and (d) document frequency. We report our results of experiment using an 80-person dataset.

1. はじめに

我々は Web 上の人物の選択と理解を支援するために，Web 上の人名検索結果の要約と可視化研究を行っている[村上 09]．その中で，人物に位置情報，職業[上田 09]，NDC（図書館の分類記号）[村上 16]，NDLSH（国立国会図書館の件名標目）[下倉 17]等を付与してきた．本研究では，人物に日本図書館協会の基本件名標目表（BSH）第 4 版（BSH4）の件名標目を付与する．人物に BSH4 を付与することにより，精度の高い（ゴミの少ない）キーワードが付与でき，探索的検索等の応用が可能である．

本稿では，Web における人名検索結果から得られた Web ページに BSH4 を付与する方法を検討した．Web 上の 80 人物に対して，検索ランキング，文書内の位置，参照語，文書頻度の 4 種類を組み合わせた 405 パターンについて比較した実験結果を報告する．

2. BSH

BSH（Basic Subject Headings）は，日本図書館協会が提供する件名標目表であり，最新は第 4 版[日本図書館協会 99]である．件名標目は，目録を検索する手がかりとして提供されており，資料の主題をことばで表現したものである．BSH 第 4 版（BSH4）には，件名標目，参照語，説明付き参照，細目がある．また，各項目の中に最上位標目，上位標目，下位標目，直接参照，直接参照有り，関連標目等が含まれている．

3. 方法

3.1 手法

先行研究[佐藤 05]で使われた 20 の日本人氏名を用いて，Google Web APIs で 50 件の検索を行い，検索結果から同姓同名人物を手動で分離した 80 人分の Web ページ（HTML 文書）を利用した．人物毎の HTML 文書に対し，BSH4 の標目を付与する．

まず，BSH4 の件名標目のみを抜き出し，そこに直接参照があれば参照語を抽出する．

標目と参照語について，文字列が長い方がより詳細な意味を付与できると考えて，文字列の長いものから順に，以下の(a)と(b)で与えられるタグを除いた HTML 文書と照合してカウントする．一致した箇所は半角空白 1 つに置き換えて，次の標目または参照語を処理する．たとえば文書中の「人工知能」という文字列を処理する際に標目「人工知能」はカウントされるが標目「知能」はカウントされない．標目や参照語をカウントした後に重み付けを行い該当する標目のスコアを算出する．

組合せ条件として以下の 4 種類を用意した．

(a)Web ページの検索ランキングの利用：人物毎の上位 1, 3, 5, 10 件および全件の 5 パターン．

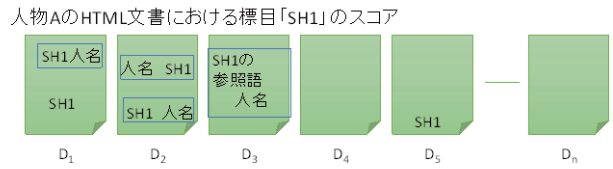
(b)HTML 文書内の位置の利用：タイトル，全文，検索語（人名）の前後の文字（前後 20, 40, 60, 80, 100, 150, 200）の 9 パターン

(c)参照語の利用 ：参照語を利用しない，標目の 0.5 倍の重みで利用，標目と同じ重みで利用の 3 パターン

(d)標目および参照語の文書頻度の利用：何もしない，文書頻度（df）/利用した全文書数（N）をかける，利用した全文書数（N）/文書頻度（df）をかけるの 3 パターン

これらを組み合わせると 5×9×3×3=405 パターンとなる．図 1 に標目のスコア計算例を示す．

最上位のスコアを持つ標目を該当人物に付与する．ない場合は「なし」とする．



パターン (a) 上位5件，(b) 人名の前後x文字，(c) 文書頻度/全文書数，(d) 参照語0.5倍
SH1: 3回出現；SH1の参照語：1回出現×0.5=0.5
(3+0.5)×3/5=3.5×0.6=2.1

パターン (a) 上位3件，(b) 全文，(c) 全文書数/文書頻度，(d) 参照語なし
SH1: 4回出現
4×3/2=4*1.5=6.0

図 1：スコア計算例

3.2 評価

人物に付与する最も適当な BSH4 の標目を著者らが 1 つ選定し，正解データとした．たとえば，元野球選手の江川卓氏は標目「野球」，関西学院大学教授の三浦麻子氏は標目「社会心理学」とした．80 人物全員に付与できた．

評価指標は以下のとおりとする．

$$\text{正解率} = \frac{\textit{自動的に付与されたBSHが正しい人物数}}{\textit{人物数}}$$

連絡先：下倉 雅行，大阪市立大学大学院創造都市研究科，大阪市住吉区杉本 3-3-138，masayuki@karekinada.com

$$\text{適合率} = \frac{\textit{自動的に付与されたBSHが正しい人物数}}{\textit{自動的にBSHが付与された人物数}}$$

$$\text{再現率} = \frac{\textit{自動的に付与されたBSHが正しい人物数}}{\textit{手動で付与された正しいBSHがある人物数}}$$

$$\text{F 値} = \frac{2 \times \textit{適合率} \times \textit{再現率}}{\textit{適合率} + \textit{再現率}}$$

$$\text{総合精度} = \frac{\textit{正解数}}{\textit{人物数}}$$

ただし，総合精度の正解数は手動で付与できなかった人物に対して自動で付与できない場合は正解とするが，今回の場合は手動で付与できない人物がいないため，正解率と同じとなる．

4. 方法

正解率においてどのパターンが最も良かったかを表 1 に示す．

全体（80 人物）について最も良かったパターンは，「上位 10 件，全文を利用し，参照語なし，df/N」であり，正解率は 27.5%（22/80）であった．

人物毎の文書数によって傾向が異なることが観察されたため，1, 2, 3 文書以上，11 文書以上，3 文書以上 10 文書以下に分けて調べた．1 文書しかない 35 人物の場合「全文（参照語は利用しない）」が最も良かった．3 文書以上の 33 人物の場合，「上位 10 件，人物名の前後 150 文字を利用し，参照語は標目の半分の重みで，df/N を利用する」が最も良かった．

表 1 正解率の高いパターン

文書数	上位件数	利用箇所	参照語	文書頻度	正解率
全体	10	全文	0	df/N	0.275 (22/80)
1	1	全文	0	1	0.286 (10/35)
2	3	前後 200	0	1	0.333 (4/12)
3 以上	10	前後 150	0.5	df/N	0.333 (11/33)
11 以上	5	前後 40	1	df/N	0.389 (7/18)
3～10	10	前後 80	0	df/N	0.267 (4/15)

表 2 に正解率の高いパターンの適合率，再現率，F 値，総合精度を示す．全体的に 30%前後という結果が得られた．

表 2 正解率の高いパターンの評価

文書数	適合率	再現率	F 値	総合精度
全体	0.278	0.275	0.277	0.275
1	0.294	0.286	0.290	0.286
2	0.333	0.25	0.286	0.250
3 以上	0.343	0.333	0.338	0.333
11 以上	0.389	0.389	0.389	0.389
3～10	0.286	0.267	0.276	0.267

比較のためにベースラインとして余弦を用いた方法を実装した．MeCab を用いて標目と参照語と文書から名詞を抽出して用語とした．全体で最も良かったパターンと条件を合わせるために，上位 10 件，全文，参照語なし，文書頻度を用いた．標目から抽出した用語の重みは出現頻度×df/N とした．その結果，余弦を用いた方法では正解が得られなかった．

以上より，全体としては，Web ページ全てよりも上位 10 件に抑え，HTML 文書の全文を利用し，参照語を利用せず，多くの文書に出現する語に重み付けすると良いことがわかった．

5. 関連研究

統制語を文書に付与する方法は機械学習を行うものと行わないものに大別され，本研究は機械学習を行わないものである．機械学習を行わない場合，余弦がベースラインの一つとなっている．余弦を利用しても正解が得られなかったことを考えると本研究では良い結果が出ていると言える．

NDLSH を人物に付与する研究[下倉 17]において，全体として良いパターンは「上位 10 件，人物名の前後 100 文字，同義語は標目の半分の重みで，文書頻度 df/N を利用する」であった． NDLSH における同義語と BSH4 における参照語とは基本的に同じである．すなわち，上位 10 件と文書頻度 df/N を利用する点は同じであり，利用箇所と参照語については異なった．結果の相違点については，BSH4 と NDLSH の収録語数の違いによる可能性がある．本研究で使用した標目の収録数は，BSH4 は 7847 件，NDLSH は 2016 年 9 月現在で 19521 件であった．今後詳細な検討が必要である．

6. おわりに

Web における人名検索結果から得られた Web ページに BSH4 を付与する方法を検討した．Web 上の 80 人物に対して検索ランキング，文書内の位置，参照語，文書頻度を組み合わせた 405 パターンについて比較実験を行った．結果として，上位 10 件の文書の全文を利用し，参照語を利用せず，標目の出現文書数を利用した全文書数で割ったものをかけたものを利用することが一番よいということがわかった．

今後の課題としては，文書数ごとに適したパターンのさらなる調査，上位標目や下位標目等の利用，最上位以外のデータの検証，実験データの追加，等があげられる．

参考文献

[村上 09] 村上 晴美，上田 洋：Web 人名検索結果の要約と可視化を目指して: 2009 年度人工知能学会全国大会（第 23 回）論文集 (2009)

[上田 09] 上田 洋，村上 晴美，辰巳 昭治: Web 上の同姓同名人物識別のための職業関連情報の抽出，システム制御情報学会論文誌，Vol.22，No.6，pp.229-240 (2009)

[村上 16] 村上 晴美，浦 芳伸，片岡 祐輔: Web 上の人物への図書館の分類記号の付与と人物ディレクトリの開発，システム制御情報学会論文誌, Vol.29, No.2, pp.51-64 (2016)

[下倉 17] 下倉 雅行，村上 晴美：Web 上の人物への NDLSH の付与，人工知能学会全国大会（第 31 回）論文集 (2017)

[日本図書館協会 99] 日本図書館協会件名標目委員会編，基本件名標目表 第 4 版，日本図書館協会 (1999)

[佐藤 05] 佐藤 進也，風間 一洋，福田 健介，村上 健一郎：実世界指向 Web マイニングによる同姓同名人物の分離；情報処理学会論文誌：データベース，Vol.46, pp.26-36 (2005)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

協調作業におけるグループ内アプリケーション共有開始手続きの円滑化のためのインタフェースの試作

Developing an Interface for Beginning Application Sharing Smartly in a Group of Cooperative Work

岩田 知 *1　大囿 忠親 *1　新谷 虎松 *1
Satoru Iwata　Tadachika Ozono　Toramatsu Shintani

名古屋工業大学大学院工学研究科情報工学専攻
Department of Computer Science, Graduate School of Engineering, Nagoya Institute of Technology

Sharing application window among users may improve cooperative works. However, configurations of sharing multiple application windows among multiple PCs are complicated. We implemented a management system for the configuration. The main idea of the system is to introduce an analogy of classrooms, which helps users to understand and make the configurations. The system provides a novel interface for management of groups in a classroom. This paper shows the implementation and evaluation of the system. Specifically, we realized a practical application window sharing system by optimizing streaming of windows.

1. はじめに

PC を用いた協調作業において，作業中のネイティブアプリケーションのウィンドウ画面を，参加者間で共有することは有用である．先行研究では，ウィンドウ単位での画面共有に焦点を当て，アプリケーション仮想共有システムを開発した [1]．しかし，先行研究には，共有を開始するまでの操作が煩雑であるという課題があった．アプリケーションを共有するためには，共有するアプリケーションや共有相手の選択を行い，共有が可能な環境の構築が必要である．本稿ではこの手続きを共有開始手続きと呼称する．この共有開始手続きが円滑に進まない場合，かえって協調作業を妨げてしまう．

本研究の目的は，円滑な共有開始手続きを可能とするインタフェースを実装することで，協調作業の支援を行うことである．本研究では，あらかじめグループ内で利用する端末の情報をサーバに保管しておくことで，ウィンドウ画面の配信先端末を自動で決定し，共有開始手続きの負担を軽減するインタフェースを開発した．本稿ではアプリケーション仮想共有システムと，本研究で開発したインタフェースについて述べる．

2. アプリケーション共有システム

本章では実行例や図を用いながら，本研究で開発したアプリケーション共有システムについて述べる．ここで，アプリケーションを公開する側をホストとし，閲覧する側をゲストとする．本システムは，ホスト側のデスクトップ上に表示されたアプリケーションのウィンドウを，ゲスト側のデスクトップ上に表示する．

図 1 は本システムの実行例である．図内には，計算機 1，計算機 2，計算機 3 の三つの PC がある．また，破線で囲まれているのは各端末のデスクトップ上に表示されたウィンドウを示す．実行例では計算機 2 および 3 のデスクトップ上に表示されているアプリケーションのウィンドウ画面を，2 枚ずつ計算機 1 へ配信している．配信された画面はシステムが開いたウィンドウで再生され，リアルタイムで同期している．

本研究では，ホスト側，およびゲスト側で起動するための，

連絡先: 岩田知，名古屋工業大学工学研究科情報工学専攻，愛知県名古屋市昭和区御器所町，052(735)5584，iwasato@toralab.org



図 1: 実行例：アプリケーション共有

本システムを組み込んだアプリケーションの開発に Electron を利用した．Electron は Web 技術をアプリケーション開発に利用できるライブラリである．本システムの P2P 通信や，ウィンドウ画面のストリーミング配信は，WebRTC 技術を応用した．また，ゲスト側は Web アプリケーションとしての開発も行い，iPad などのモバイルデバイスからでもブラウザを用いてアプリケーションを共有することができる．

3. 開発したインタフェース

本章では本研究で開発した，共有開始手続きの円滑化を可能とするインタフェースについて述べる．グループ内で利用する PC 端末の情報を事前に設定しておくことで，ウィンドウ画面の配信先を自動で決定し，共有開始手続きを軽減するインタフェースを開発した．図 2 はグループを管理するためのインタフェースである．グループ作成ボタンでグループを作成できる．作成したグループは，グループ一覧に追加される．グループ内メンバー一覧には，グループ一覧で選択したグループに属する PC 端末の一覧が表示される．アプリケーション共有ボタンで共有するウィンドウ画面を選択する画面が表示され，選択および決定すると，現在選択中のグループに属する PC 端末のデスクトップ上に共有されたウィンドウ画面を表示する．また，グループ内メンバー一覧の中の一台に対してのみウィンドウ画面を配信するといったことも可能である．



図 2: グループ管理インタフェース

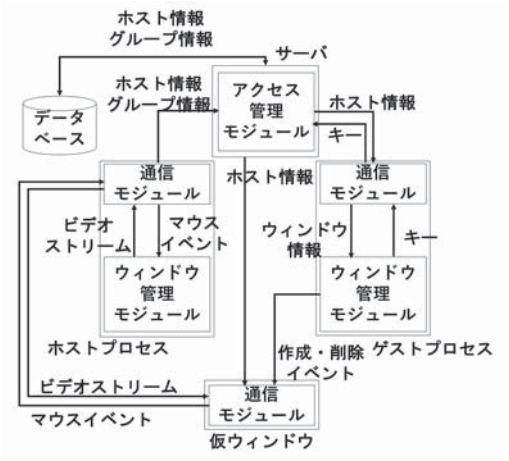


図 3: システム構成図

4. システム構成図

本章では本システムの実装手法について述べる．図 3 は本システムの構成図を示す．本システムは大きくホストプロセス，ゲストプロセス，サーバ，仮ウィンドウの四つに分けることができる．ホストプロセスは通信モジュールおよびウィンドウ管理モジュールを持っている．ウィンドウ管理モジュールの役割は，ウィンドウのビデオストリームの取得およびマウスイベントをポストすることである．通信モジュールはサーバや仮ウィンドウとの通信を行う．サーバには，ホスト側のデスクトップ上に表示されているウィンドウや，それらを一般公開するかどうかなどの情報を送信する．サーバでは，ホストプロセスおよびゲストプロセス間の通信を行なっている．ホストプロセスから送られたホスト情報はデータベースに格納される．また，サーバ内にはアクセス管理モジュールがある．アクセス管理モジュールでは，各ホストが一般公開するウィンドウ群と，事前に登録したグループに関する情報を管理している．ゲストプロセスは通信モジュールおよびウィンドウ管理モジュールを内包する．通信モジュールはサーバとの通信を行う．サーバから受け取ったホスト情報から，ホスト名やウィンドウ情報などを抜き出し，ホスト選択リストや仮ウィンドウ選択リストに表示している．ウィンドウ管理モジュールでは通信モジュールから受け取ったウィンドウ情報から仮ウィンドウ作成イベントを発生させ，仮ウィンドウを表示する．

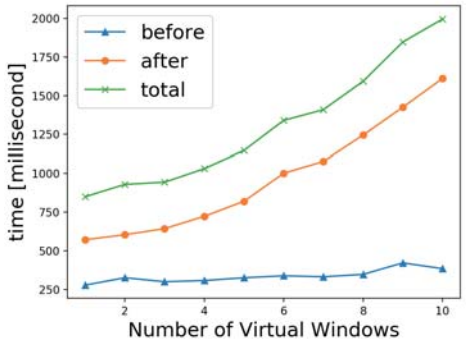


図 4: 全体時間

5. 評価実験

本章では評価実験について述べる．評価実験では，実際にゲスト側 PC のデスクトップ上にウィンドウが表示されるまでの経過時間を調査した．経過時間は，ゲスト側 PC のデスクトップをビデオカメラで撮影し，アプリケーション共有の操作を完了してから，ウィンドウが表示されるまでのフレーム数をビデオカメラの FPS で割ることにより求めた．ビデオカメラは FPS が 60 のものを用いた．また，共有したウィンドウ画面のサイズは 960x1,920 とし，同時に共有するウィンドウ数は 1 から 10 枚とし，各枚数の場合を同じ手法で測定した．

図 4 は，ビデオカメラで撮影した結果から取得した各時間である．横軸はゲスト側 PC のデスクトップ上に表示されたウィンドウ数，縦軸は計測した時間を示す．before が共有されたウィンドウのフレームが表示されるまでの時間，after がフレームが表示されてから共有されたウィンドウの画面が表示されるまでの時間である．また，total は before と after の和である．本システムはウィンドウのフレームが表示されてから P2P 通信を始め，デコードなどの WebRTC に関連する処理を行うようになっている．実験結果より，WebRTC に関連する処理が共有されたウィンドウ数に依存することがわかった．共有されたウィンドウ数が増えるほど経過時間は増すが，10 枚でもおよそ 2,000ms であり，実用的であると考えられる．

6. おわりに

本稿では協調作業支援で利用されるアプリケーション共有システムにおける，共有開始手続きの円滑化が可能なインタフェースについて述べた．協調作業を行うグループを管理するためのインタフェースを実装した．グループ内の PC 端末をアプリケーション共有先の対象とすることで，共有開始手続きを軽減する．評価実験では本インタフェースを用いた場合に，実際に共有が開始されるまでに必要な時間を計測することで，実用性について評価した．要する時間は最大でもおよそ 2,000ms であり，実用的であると判断した．

参考文献

[1] Satoru Iwata, Tadachika Ozono and Toramatsu Shintani.: Any-Application Window Sharing Mechanism based on WebRTC, *2017 6th IIAI International Congress on Advanced Applied Informatics*, vol.00, pp.808-813(2017).

CNN による画像形状特徴を利用した推薦システム

Recommender System using Image shape Feature for CNN

段玉鋒[*1]
Yufeng Duan

佐賀亮介[*1]
Ryosuke Saga

[*1] 大阪府立大学院人間社会システム研究科
Graduate School of Humanities and Sustainable System Sciences, Osaka Prefecture University

PMF (Probabilistic Matrix Factorization) is a well-known approach of recommending systems. It has achieved wide use not only in research but also in industry. In recent years, this algorithm has been combined with some side information, and the accuracy of recommendation has been improved. In this paper, we propose a novel probabilistic model using image shape features that integrates convolutional neural network (CNN) into probabilistic matrix factorization (PMF)

1. はじめに

推薦システムは情報過多において，ユーザが好むと思われる問題を解決する手段である．特に，PMF(Probabilistic Matrix Factorization) [Salakhutdinov 08]はよく使われる推薦手法であり，広く使用されている．

一方，昨今では，ユーザ評価だけでなくテキストや画像のクラス情報を組み合わされたものが提案されている．例えば，Kimらは，ConvMF という畳み込みニューラルネットワーク（CNN）を確率的行列分解（PMF）に統合した新しい推薦モデルを提案している[Kim 16]. ConvMF は文章のコンテスト情報をキャプチャし更に推薦精度を向上させる．しかしながら，デザインを重要視している服や靴など，ファッションに関する服飾製品においては，テキストや画像のカテゴリだけでは十分でなく，画像に表れている商品の形状を考慮する必要がある．そして，現状，この画像形状の特徴を利用している推薦システムが存在しない．

本論文では，CNN を用いた画像形状特徴を PMF に統合し，デザインを重要視している商品に向けた推薦システムを提案する．そのための，画像形状するモデルを提案する．このモデルを ISFMF と呼ぶ．

2. 関連研究

2.1 PMF

Salakhutdinov らは，PMF (Probabilistic Matrix Factorization) という情報推薦手法を提案している．確率行列分解とは，ユーザ数 N, アイテム数 M, 整数 D と採点行列 $R \in \boldsymbol{R^{N\times M}}$ を仮定し，この R を $D \times N$ のユーザ行列 U と $D \times M$ のアイテム行列 V に行列分解することである．ユーザ i によるアイテム j の予測採点値 $\hat{r}_{ij}$ は，ユーザ行列 u_i とアイテム行列 v_j の内積である(i.e. $\hat{r}_{ij} = u_i^T v_j$)．最適な行列 U と行列 V を見つける方法は実際の採点値と予測の採点値の残差平方和からなる損失関数 E を最小にするであり，式(1)で表される．

$$min\, E(U,V) = \sum_i^N \sum_j^M \frac{I_{ij}}{2}\left(r_{ij} - u_i^T v_j\right)^2 + \frac{\lambda_U}{2}\sum_i^N ||u_i||^2 + \frac{\lambda_V}{2}\sum_j^M ||v_j||^2 \quad (1)$$

2.2 DeepContour

Shen らは，DeepContour という輪郭検出手法を提案している[Shen 15]. 教師あり学習で CNN に色々な画像の形状の特徴を学習させ，図1のように形状のみを抽出した画像を生成できる．そして，Positive-Sharing Loss function という関数を開発した．この関数で画像のある所は輪郭かどうかを判断できる手法である．

連絡先：佐賀亮介，大阪府立大学院人間社会システム研究科，599-8531，大阪府堺市中区学園町 1-1，saga@cs.osakafu-u.ac.jp

3. 提案手法

3.1 ISFMF の確率モデル

図 2 は CNN を PMF に統合する ISFMF の確率モデルの概要を示したものである．ユーザ数 N, アイテム数 M と次元数 D があり，採点行列 $R \in \boldsymbol{R^{N\times M}}$ を仮定する．次に，採点行列 R が再構築できるユーザ潜在行列 $U \in \boldsymbol{R^{D\times N}}$ とアイテム潜在行列 $V \in \boldsymbol{R^{D\times M}}$ を求める．

しかし，従来の PMF のアイテム潜在行列と異なり，我々のアイテム潜在行列は三つの変数から生成されると仮定する．S(アイテム j の画像形状特徴)，W (W は CNN の全ての重みを示す変数で，w_d は各重み) と ∂_V (潜在行列 V のガウス雑音) である．従って，ISFMF の損失関数 E は式(2)で表される．



図 1: DeepContour

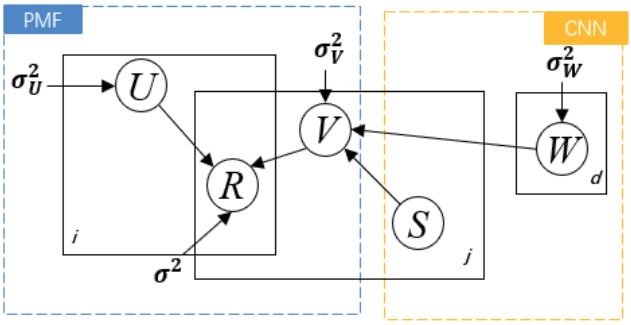


図 2: ISFMF の確率モデル

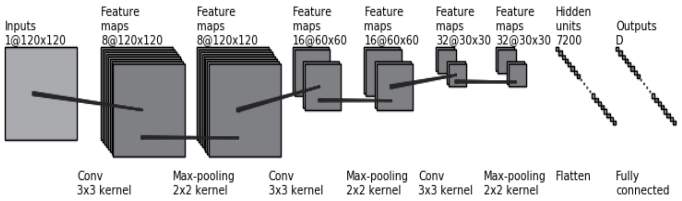


図 3:CNN のアーキテクチャ

$$min\ E(U,V,W) = \sum_i^N \sum_j^M \frac{I_{ij}}{2}\left(r_{ij} - u_i^T v_j\right)^2 + \frac{\lambda_U}{2}\sum_i^N ||u_i||^2$$

$$+\frac{\lambda_V}{2}\sum_j^M \left||v_j - cnn(W, S_j)\right||^2 + \frac{\lambda_W}{2}\sum_d^{|w_d|}||w_d||^2 \qquad (2)$$

ただし，$\lambda_U = \frac{\sigma^2}{\sigma_U^2}$, $\lambda_V = \frac{\sigma^2}{\sigma_V^2}, \lambda_W = \frac{\sigma^2}{\sigma_W^2}$ であり，I_{ij}は評価値があるときに 1，それ以外は 0 をとる． また， $\partial_V, \partial_U, \partial_W$ はそれぞれ U，V，Wのガウス雑音である．式(2)をu_iとvそれぞれ偏微分すると

$$\frac{\partial E}{\partial u_i} = \left(r_{i,j} - u_i^T v_j\right)v_j - \lambda_U u_i \qquad (3)$$

$$\frac{\partial E}{\partial v_j} = \left(r_{i,j} - u_i^T v_j\right)u_i - \lambda_V(v_j - cnn(W, S_j)) \qquad (4)$$

そして，確率的勾配降下法でu_iとv_jを更新し，最適なユーザ潜在行列Uとアイテム潜在行列Vを得ることができる.

3.2 ISFMF の CNN アーキテクチャ

図 3 は我々の CNN アーキテクチャである．DeepContour で処理したアイテム j の画像を入力し，次元数 D の画像形状潜在ベクトルが生成される．そして，生成されたベクトルは PMF に渡され，行列分解に組み込まれる.

4. 評価実験

4.1 実験概要・データセット

本実験では，服飾に関する商品において提案手法の性能を評価する. 実験には Amazon product data[McAuley 15,He 16]の Clothing, Shoes and Jewelry の採点データと画像データを利用する. 今回は服飾データのみを対象とするため，服飾以外のもの，画像がないもの，また商品説明がないものをデータセットから削除した．また，ユーザの採点数によってデータ密度が異なる三つのデータセットを作り，それらのデータセットを元に訓練データと評価データにランダムに分けた（表 1）.

- M1 :採点数が 1 件未満のユーザを削除したデータセット
- M2 :採点数が 2 件未満のユーザを削除したデータセット
- M3 :採点数が 3 件未満のユーザを削除したデータセット

本実験では，訓練データと評価データを分割するために，訓練データの行列サイズは，元データの行列と同じサイズに設定している．ただし，M1 はユーザ数，アイテム数ともに巨大であり，データがあまりにも疎であり，訓練データと評価データに分割できないため，今回の実験では M1 に関しては使用しない.

また、本実験では， PMF，ConvMF と提案手法を比較した．ここで，パラメータは以下のように設定した.

- U と V の次元数 D を 50 に設定した.
- 入力画像のサイズを 120*120 に設定した.
- 共通パラメータ（λ_U，λ_V）は様々な組み合わせを事前に評価したものを用いた（表 2）.

また，評価尺度として，RMSE（root mean squared error）を用いた（式 (5)）.

$$\text{RMSE} = \sqrt{\frac{\sum_{i,j}^{N,M}(r_{ij} - \hat{r}_{ij})^2}{ratings}} \qquad (5)$$

4.2 結果と考察

各モデルの RMSE の結果を表 3 に示す. 表 3 により, 提案手法である ISFMF は全体的に最も良い精度が得られている.

5. おわりに

本稿では, CNN を用いた画像形状特徴を PMF に統合するモデルを提案した. デザインに重視するアイテムにおいて, 画像形状特徴の有用性が証明された.

今後は商品のテキスト情報と画像形状特徴を一緒に利用するモデルを構築することを試みる.

参考文献

[Kim 16] D. Kim, C. J. Oh Park, et al, Convolutional Matrix Factorization for Document Context-Aware Recommendation, ACM, pp.233-240, 2016

[McAuley 15] J. McAuley, C. Targeet, J. Shi, A. Van den Hengel. Image-based recommendations on styles and substitutes, SIGIR, pp.43-52, 2015

[He 16] R. He, J. McAuley, Modeling the visual evolution of fashion trends with one-class collaborative filtering, WWW, pp.507-517, 2016

[Salakhutdinov 08] R. Salakhutdinov, A. Mnih, Probabilistic Matrix Factorization, NIPS, pp.1257-1264, 2008

[Shen 2015] W. Shen, X. Wang, Y. Wang, X. Bai, Z. Zhang, DeepContour: A Deep Convolutional Feature Learned by Positive-Sharing Loss for Contour Detection, CVPR, pp.3982-3991

表 1:データ密度が異なる三つのデータセット

datasets	Users	Items	Ratings	density
M1	94562	22027	105994	0.0051%
M2	8222	8513	19654	0.0281%
M3	1796	4148	6802	0.0913%

表 2: 各モデルの最適な共通パラメータ

models	M2		M3	
	λ_U	λ_V	λ_U	λ_V
PMF	0.1	0.1	1	0.1
ConvMF	1	10	10	0.1
ISFMF	1	0.1	1	0.1

表 3: テストデータの RMSE

datasets	PMF	ConvMF	ISFMF
M2(70%訓練データ)	1.64	1.33	**1.27**
M2(80%訓練データ)	1.60	1.26	**1.21**
M3(70%訓練データ)	1.76	1.27	**1.18**
M3(80%訓練データ)	1.59	1.29	**1.26**

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

半教師学習と特異値分解によるCold-Start問題へのアプローチ

Combining semi-supervised learning and singular value decomposition to Cold-Start problem

内田 匠 *1*3 Takumi Uchida　中川 慧 *2*3 Kei Nakagawa　吉田 健一 *3 Kenichi Yoshida

*1*3筑波大学大学院 ビジネス科学研究科 University of Tsukuba Graduate School of Business Sciences

*2野村アセットマネジメント株式会社 Nomura Asset Management Co., Ltd

機械学習を用いてWebマーケティングには多くの課題があり、その一つにCold-Start問題がある。例えば通販サイトなどでユーザーに商品を推薦する場合、ユーザーと商品の購買ログやレビューログを取り扱うことになる。しかし、Webのマーケティングデータはロングテールになる傾向があるため、多くのユーザーや商品のログデータは少なく、数件程度しかないことも多い。商品の推薦システムではこの過去ログに基づいてユーザーに対して商品を提示するため、ロングテールの商品は提示されにくく一部の人気商品ばかりが提案される事になる。本研究では、このCold-Start問題に対して半教師学習と特異値分解を組み合わせた手法を提案する。また、提案した手法をMovieLensが提供している映画の評価スコアデータで検証した結果を報告する。

1. はじめに

Cold-Start問題は特にWebマーケティングの推薦システムにおける問題として、重要な研究課題となっている [Shi 14]。Cold-Start問題とは、推薦システムにおいて、推薦するためのデータが少ない新規ユーザーや新規アイテムに対する評価が難しいことをいう。Cold-Start問題を解決する意義は新商品やマイナーな商品の適切な提案を可能にする点にある。未だユーザーの目に触れた事のない商品を高い精度で提示できるのであれば、企業はユーザーに対してより多様な価値提供が可能になる。

Cold-Start問題を解決するためのアプローチとして、コンテンツベースの協調フィルタリング [Schein 02] やユーザークラスタを応用するもの [Lika 14]、半教師学習を用いたもの [Zhang 14] など多くの研究がある。その中でも本研究では半教師学習を用いたアプローチの改善手法を提案する。半教師学習とは、観測されたデータをLabeled Data、まだ観測されていないデータをUnlabeled Dataとし、Labeled DataとUnlabeled Dataの両方を利用した学習法全般をいう。具体的には、[Zhang 14] が提案した半教師学習を用いた推薦システムに特異値分解を組み合わせることを提案する。[Zhang 14] の手法は、例えばwebページの分類をする際の画像、文章や、推薦システムにおけるユーザーとアイテムのようなデータが二つの素性に分解できることを仮定する必要がある [Blum 98]。一般に、データどうしに相関がある場合、それらのモデル内での役割は同じであり、そのままでは利用できない。そこで、データをいったん特異値分解により次元削減することでデータ間の相関を取り除く。これが特異値分解を組み合わせる動機である。したがって本手法は、推薦システム以外のデータの素性が容易に分解できないような領域にも適応が可能である。

本論文の構成は次の通りである。2章で、先行研究 [Zhang 14] の手法を概観し、3章で提案手法の紹介を行う。そして、4章で、MovieLensが提供している映画の評価スコアデータで検証した結果を報告する。

連絡先: 内田 匠, 筑波大学大学院 ビジネス科学研究科, 〒112-0012 東京都文京区大塚 3-29-1

2. 先行研究

[Zhang 14] は半教師学習の [Blum 98] の Co-training を Cold-Start 問題の解決のために応用した手法 (CSEL) を提案した。Co-training は、データが2つの素性に分解できると仮定し、それぞれの素性について分類器を個別に用意し、観測されたLabeled Dataのみでそれぞれ学習する。1つ目の分類器で高い確信度で分類できたUnlabeled Dataを、2つ目の分類器の次回の学習に用い、逆に2つ目の分類器で高い確信度で分類できたUnlabeled Dataを1つ目の次回の学習に用いる。これを繰り返して学習データを拡大する手法である。Cold-Start問題の原因はロングテールには十分なログが存在しない事にある。CSELはその不足したログをCo-trainingによって推定追加することで、ロングテールの推薦精度を改善した。

CSELの概要をまとめる。CSELは推薦に利用する変数をA) ユーザーの属性変数、B) 商品の属性変数、C) ユーザーと商品の相性変数に分解した上で、2つの推定モデルを別々の変数を使って学習する。具体的には、ある推定モデルではAとCの変数を使って学習し、もう片方の推定モデルではBとCの変数を使って学習する。次に、それぞれの推定モデルがUnlabeled Dataを予測しその予測値の信頼度を評価する。上位の信頼度をもつデータを学習データに追加した上で再び学習を行う。このように学習と推定追加を繰り返し行い、ロングテールのデータを増加させた上で最終的な学習を行う。CSELを映画の評価スコアデータであるMovieLensのデータで検証した結果、ロングテールにおいて特に予測精度の改善が見られた。

半教師学習での推定追加における課題は、その推定値の信頼度である。推定値を学習データに追加してそのままの同じモデルで再学習する場合、推定誤差を強化する方向に作用する懸念がある。CSELはユーザーと商品の組合せ情報という推薦システムに特有のデータ構造を利用し、それぞれ違う推定モデルがデータを評価するCo-trainingを活用することでこの問題を解決した事例といえる。

3. 提案手法 - CSEL with SDV

提案手法のアルゴリズムはCSELを基本としつつ、それぞれのCo-training推定モデルが学習に用いるデータが特異値分

解を応用して生成されている点が大きく異なる。本研究で提案する手法は、Co-training における推定モデルの多様性を、特異値分解をデータに適用しておくことで、データ間の相関を取り除き、モデル間の多様性を担保することを着眼点としている。また、どの推定値を学習に追加するかの判断基準となる信頼度については、一つのサンプルに対する異なる推定モデルからの推定値の標準偏差の逆数を用いた。つまり、複数のモデルからの推定値の分散が小さいほど信頼度が高いとしている。これは異なるモデルであるのに同じような推定値を出力してきた場合はその推定値の信頼度は高い、という仮定を根拠としている。この提案手法の概略を図 1 にて示す。

まず始めに、すでに目的変数が観測出来ている Labeled Data と観測出来ていない Unlabeled Data を同じ説明変数行列 X として扱う。次に、この説明変数行列を特異値分解を応用して、以下の数式のように複数の行列に分解する。

$$X = U\Sigma V^T \quad (1)$$

$$= \sigma_1 u_1 v_1^T + \sigma_2 u_2 v_2^T + \cdots + \sigma_q u_q v_q^T \quad (2)$$

σ_i は固有値、u_i, v_i は X の左特異値ベクトルと右特異値ベクトルである。q は X が $n \times m$ の行列とすると $min(n, m)$ である。$u_i v_i^T$ は行列 X と同じ次元をもつ行列となりそれぞれが行列 X を構成する要素となっている。また、$u_i v_i^T$ は互いに基底である別々の特異値ベクトルから生成されるため、他の $u_i v_i^T$ との間には Co-training に必要な十分な多様性を有していることが期待できる。

Co-training で採用できる推定モデルの数は 2 ～ q 個まで任意に選択することができ、その予測アルゴリズムについても説明変数に行列データをとれるものであれば何を用いても良い。

このような処理を繰り返すことで、観測できなかったデータの推定値の信頼性を確認しながら学習データに追加する。追加されたデータにロングテールがあれば、ロングテールの推定精度を改善する可能性がある。

4. 実験

提案手法の有効性を確認するために、MovieLens[Harper 16] の映画のレビュースコアデータに適応して検証を行った。このデータにはユーザー ID と映画 ID に 1〜5 の評価スコアが観測されている。ユーザーの属性情報として性別、年齢、職業、映画の属性情報としてジャンルと制作年度がある。これらの属性情報に加えて、推薦システムでよく用いられる潜在因子分析によるユーザーと映画の相性因子も説明変数とした。さらにこれらの説明変数間の二次の公差項も追加している。検証では、過去の 7 日間のレビューデータを学習データとし、次の 7 日間を教師データとしてユーザーの評価スコアを予測した。指標値は予測誤差の絶対値の平均とした。

また本データでは、7 日間の間に 100 本以上の映画を視聴しているユーザー ID が存在していた。現実的に個人による視聴とは考えにくく本検証では不適切なデータだと判断したため、学習期間である 7 日間中に 20 本以上の映画を視聴したユーザー ID は検証から除外した。このデータ除外をすると 7 日間で約 14,700 件のレビューログが存在している。

評価の際には学習と教師データを 7 日間スライドして 10 週分の平均値を確認した。比較対象のモデルとして、観測できた Labeled Data のみで学習したモデルとの比較を行った。Co-training に用いた推定モデルの数は 2 と 5 を検証してそれぞれの予測精度に違いがあるかを比較した。Unlabeled Data の推定追加は、信頼度が最も良かった 1,000 件の追加を 10 回繰り返した。これにより学習データは平均して約 68% 増加することになる。予測の手法としては二次の正則化項つきの線形回帰モデルを採用した。Co-training のモデルも最終予測のモデルもこの手法を採用した。

表 1: Co-traing with 2 and 5 models

映画の観測数	モデル数:2	モデル数:5	差
000〜	1.058	1.059	-0.001
001〜	1.028	1.065	-0.037
002〜	1.023	1.05	-0.027
003〜	0.94	0.956	-0.016
004〜	0.929	0.917	0.012
005〜	0.932	0.916	0.016
006〜	1.023	1.021	0.002
007〜	1.043	1.031	0.012
008〜	0.881	0.874	0.007
009〜	0.91	0.87	0.04
010〜	0.902	0.933	-0.031
020〜	0.792	0.79	0.002
030〜	0.785	0.814	-0.029
040〜	0.999	0.983	0.016
050〜	0.85	0.831	0.019
060〜	0.825	0.824	0.001
070〜	0.795	0.785	0.01

Co-training に 5 つの推定モデルを使った結果を図 2 に示す。図 2 の結果から、提案手法が観測されたデータだけの学習と比較して全体的な予測精度が良いことが分かった。学習データ中には存在しなかった商品 ID の予測精度が大きく改善していることが確認できた。本手法は新商品のレビュー予測については有効であると言える。しかし、よく見られていた映画の推定精度が改善している一方で、1 から 6 件程度のレビューがついた映画については予測精度は悪化する傾向が見られた。これは当初の仮説に反する結果となった。

次に Co-training に用いる推定モデルの数を 2 と 5 にした場合の比較を表 1 に示す。表 1 からは、Co-training で用いるモデルの数を比較しても優位な改善は見られなかった。

5. まとめ

本研究では半教師学習の Co-Training について特異値解析を組み合わせた Unlabeled データの推定追加の手法について提案し検証を行った。

その結果、MovieLens の映画の評価スコアの予測精度を改善することに成功した。特に学習データでは観測されなかった映画の予測精度を大きく改善できた。一方で、当初の仮説に反しロングテール映画での予測精度は改善しなかった。また、推定追加するデータの信頼度計算を Co-traning の異なる推定モデルの推定値の標準偏差の逆数としたことから、モデルの数を増やせばより予測精度が改善すると仮説したが、それを実証する結果は得られなかった。

今後の研究としては、Unlabeled Data の選出方法についてより合理的な手法について検討したい。また本手法は Web マーケティングの推薦システム以外にも適応が可能であることに着目し、他の領域での類似課題が解決可能かについても検証していきたい。

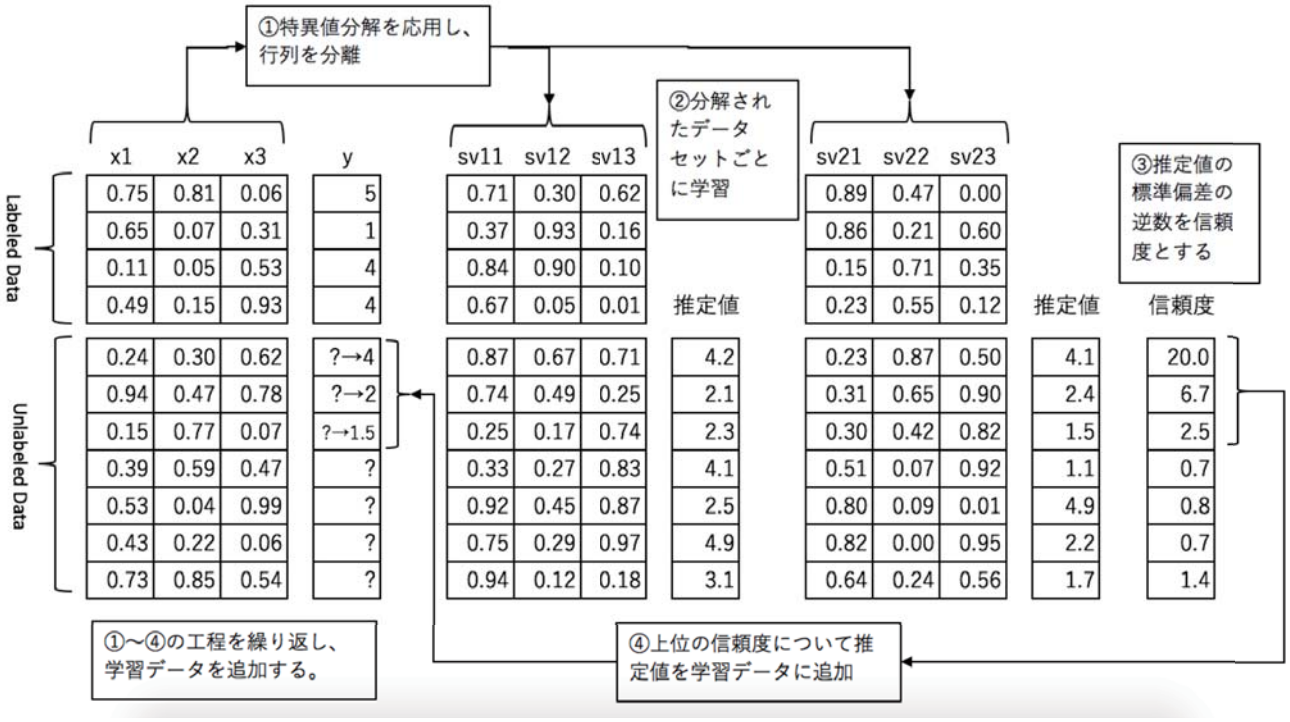


図 1: Proposed Method

参考文献

[Blum 98] Blum, A. and Mitchell, T.: Combining labeled and unlabeled data with co-training, in *Proceedings of the eleventh annual conference on Computational learning theory*, pp. 92–100ACM (1998)

[Harper 16] Harper, F. M. and Konstan, J. A.: The movielens datasets: History and context, *ACM Transactions on Interactive Intelligent Systems (TiiS)*, Vol. 5, No. 4, p. 19 (2016)

[Lika 14] Lika, B., Kolomvatsos, K., and Hadjiefthymiades, S.: Facing the cold start problem in recommender systems, *Expert Systems with Applications*, Vol. 41, No. 4, pp. 2065–2073 (2014)

[Schein 02] Schein, A. I., Popescul, A., Ungar, L. H., and Pennock, D. M.: Methods and metrics for cold-start recommendations, in *Proceedings of the 25th annual international ACM SIGIR conference on Research and development in information retrieval*, pp. 253–260ACM (2002)

[Shi 14] Shi, Y., Larson, M., and Hanjalic, A.: Collaborative filtering beyond the user-item matrix: A survey of the state of the art and future challenges, *ACM Computing Surveys (CSUR)*, Vol. 47, No. 1, p. 3 (2014)

[Zhang 14] Zhang, M., Tang, J., Zhang, X., and Xue, X.: Addressing cold start in recommender systems: A semi-supervised co-training algorithm, in *Proceedings of the 37th international ACM SIGIR conference on Research & development in information retrieval*, pp. 73–82ACM (2014)

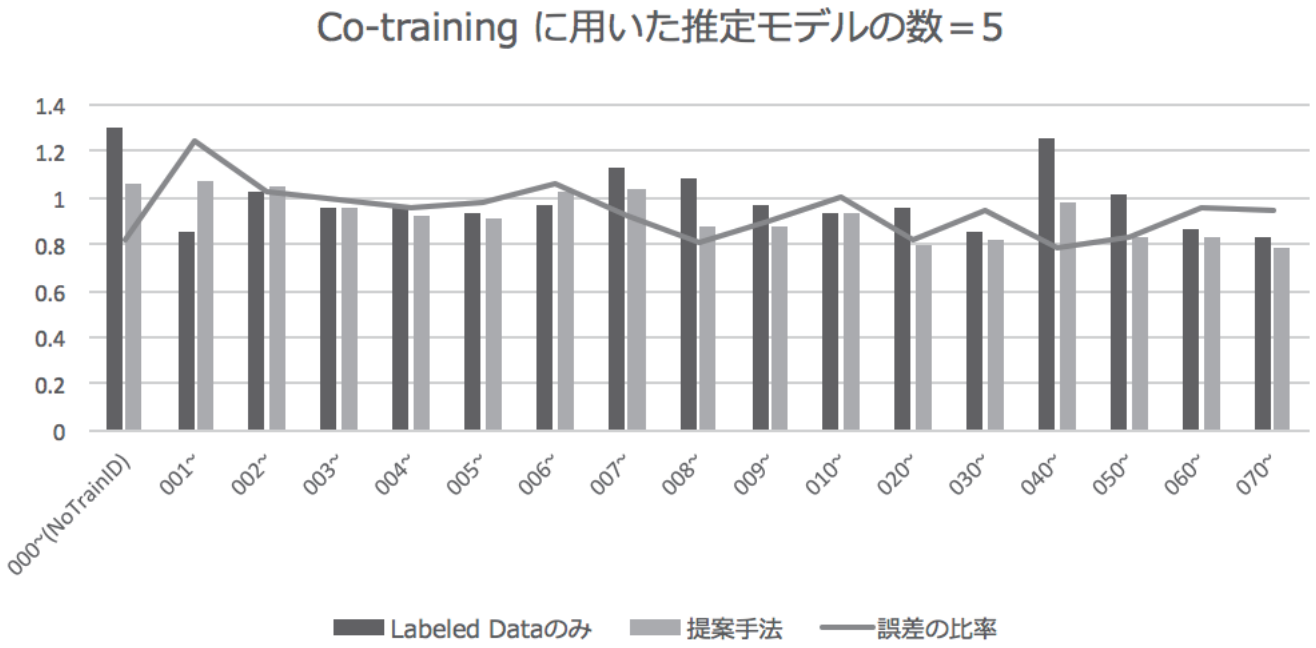


図 2: 棒グラフがそれぞれの予測誤差の絶対値の平均。線グラフが二つの手法の誤差の比率で 1 よりも低い場合は提案手法が良いと言える。

Oral presentation | Organized Session | [Organized Session] OS-8

[1C2-OS-8a] [Organized Session] OS-8

Tue. Jun 5, 2018 3:20 PM - 4:40 PM Room C (4F Orchid)

[1C2-OS-8a-01] Proposal of Context Search Engine for Integrated Use of Open and Private Data

○Taichi Okahisa[1], Yasufumi Takama[1] （1. Tokyo Metropolitan University）

3:20 PM - 3:40 PM

[1C2-OS-8a-02] Analysis of issues for creating co-creative value through marketing data among companies.

○yutaka oguchi[1], tsuchida naohiro[1] （1. NIPPON RESEARCH CENTER,LTD）

3:40 PM - 4:00 PM

[1C2-OS-8a-03] An Experiment of Causal Knowledge Extraction from Reuter News

○Hiroki Sakaji[1], Jason Bennett[2], Yusuke Miyao[3], Kiyoshi Izumi[1] （1. The University of Tokyo, 2. Sumitomo Mitsui Asset Management Company, Limited, 3. National Institute of Informatics）

4:00 PM - 4:20 PM

[1C2-OS-8a-04] Data Landscape in the Era of Data 3.0

○Teruaki Hayashi[1], Yukio Ohsawa[1] （1. The University of Tokyo）

4:20 PM - 4:40 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

ローカルデータ・公開データを統合利用可能なコンテクスト検索エンジンの提案

Proposal of Context Search Engine for Integrated Use of Open and Private Data

岡久太一　　高間康史
Taichi Okahisa　Yasufumi Takama

首都大学東京大学院システムデザイン研究科
Graduate School of System Design, Tokyo Metropolitan University

This paper aims to extend the context search engine so that it can retrieve both of open and private data. The context search engine has been developed for answering trend-related queries. While it is designed to store and retrieve publicity available data (open data), it is supposed that users often have data that can't be disclosed to the outside due to problems such as privacy protection. Making it possible to access both of such local data and open data in integrated manner would lead to effective utilization of data such as value creation from data. In order to examine the utility value of local data without sharing its contents, this paper introduces the concept of Data Jacket into the context search engine. Experimental results show its effectiveness.

1. はじめに

本稿ではローカルデータと公開データを統合利用可能なコンテクスト検索エンジンを提案する.「動向に関する問い」というドメインに依存しないタスクに特化することで，より高度な基本検索機能を提供するコンテクスト検索エンジンが研究されている [高間 15]．従来のコンテクスト検索エンジンは公開可能なデータをサーバに集約したものを検索対象としており，プライバシー保護などの問題で外部に公開できないようなデータを利用することができない．しかし，ローカルデータを外部公開データと組み合わせることは，データからの新たな価値創造など，その有効活用につながると考える．そこで本稿では，ローカルデータと公開データの両者を統合して検索可能なシステムを提案する．具体的には，データの概要情報のみを記載した Data Jacket[大澤 14] を共有することによって，非公開データ自体を外部に公開することなく，データの利用価値を検討することを可能とする．プロトタイプシステムを実装し，ユーザ実験によって提案手法の有効性を示す.

2. 関連研究

2.1 コンテクスト検索エンジン

コンテクスト検索エンジン [高間 15] とは,「動向に関する問い」というドメインに依存しないタスクに特化した，既存検索エンジンよりも高度な検索が可能な検索エンジンである．Web 上に公開されている動向情報を収集し，特徴的変動を抽出することで，動向情報の検索を可能とする.「検索期間」「アイテム名」「特徴的変動」「検索結果の出力タイプ」「単位」「統計データ名」がクエリとして入力可能であり，以下の 3 タイプの基本検索機能と組み合わせることで高度な検索が可能となる.

1. 指定したアイテムに関する動向が特徴的変動を示した期間の検索
2. 指定した期間に特徴的変動を示したアイテム・動向の検索
3. 指定したアイテムに関する動向が特徴的変動を示した期間に［同様の／対照的な］変動を示したアイテム・動向の検索

連絡先: 高間康史，首都大学東京大学院システムデザイン研究科，〒 191-0065 東京都日野市旭が丘 6-6, ytakama@tmu.ac.jp

2.2 Data Jacket Store

Data Jacket[大澤 14] とは，データの内容を説明する概要情報を記載したものである．これを共有することで，プライバシー保護などの問題で外部に公開することができないようなデータの利用価値を検討することが可能となる．早矢仕ら [早矢仕 16] は，過去に活用された Data Jacket から，自分以外のユーザが考案したデータの活用方法を発見可能とするために，データ利活用知識モデルを提案している．これに基づき，データ利活用方法検討を支援する検索システム Data Jacket Store を開発している.

3. 提案インタフェース

3.1 ローカルデータ・公開データの統合検索機能

従来のコンテクスト検索エンジンは，Web 上に公開されている動向情報を収集し，サーバに集約したものを検索対象としていた．収集した動向情報から特徴的変動を抽出してデータベースに格納することで，コンテクスト検索エンジンで検索可能となる．この処理をユーザがローカルに保持している時系列データを対象に行い，検索可能にする．提案システムでは，外部サーバに登録されている公開データを検索可能にするために，コンテクスト検索エンジンが提供する API 機能を利用し，ローカルデータ・公開データを選択または統合して検索可能とする.

3.2 Data Jacket の導入

コンテクスト検索エンジンに Data Jacket を導入することで，ローカルデータと外部公開データの統合利用に貢献することが期待できる．データ利活用知識モデルによるアプローチ [早矢仕 16] を採用し，Data Jacket 検索システムを導入することで，過去に自分以外のユーザが発見した知見から，新たな知見の発見が可能となることが期待できる．コンテクスト検索エンジンでは，動向情報の変動に関して発見した知見を共有することが重要との考えに基づき,「知見」「特徴的変動」「Data Jacket」を連結したものをデータ利活用知識と定義する.「あ

る知見がある動向情報の特徴的変動から発見された」ことを表す述語（discover）及び,「ある動向情報の特徴的変動がある動向情報から獲得された」ことを表す述語（get）を定義し，モデル構築に利用する．この時，Data Jacket を作成した動向情報から特徴的変動を獲得した際に入力した「クエリ」をプロパティとして定義し,「特徴的変動」と「Data Jacket」を連結する際に付与する．この二つのモデルを図式化したものを図 1 に示す．Data Jacket 検索システムは，これらのモデルに基づき他者の知見などにアクセス可能とする．

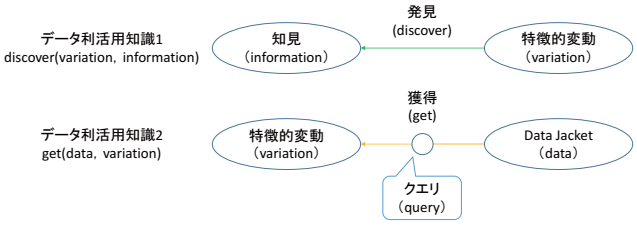


図 1: データ利活用知識モデルの図式化

4. 評価実験

4.1 概要

工学系大学生・大学院生 10 名の実験協力者に，コンテクスト検索エンジンを用いて，あるアイテムと関係があると思われるアイテムを 5〜15 分で可能な限り多く見つけてもらうタスクを行ってもらった．知見・特徴的変動・Data Jacket それぞれのデータベースから発見された Data Jacket の有用性を評価する 3 問のタスクを用意し，Data Jacket 検索システムなしのコンテクスト検索エンジンを用いて各タスクについて回答してもらった後，Data Jacket 検索システムありのコンテクスト検索エンジンを用いて同一タスクについてさらに回答してもらう．タスク内容を 2 パターン用意し，それぞれ実験協力者 5 人に回答してもらった．実験終了後，回答者とは別の実験協力者 2 人に，それぞれ 5 人分の回答の妥当性を 0〜2 点で評価してもらい，1 点以上の場合は正解とし，0 点の場合は不正解とした．

それぞれのタスクについて見つけたアイテムの正解数を図 2，図 3，図 4 に示す．タスク 1 は,「指定された期間に急上昇したアイテムを一つ探し，そのアイテムと関係があると思われるアイテムを探す」というタスクであり自由度が高かったため，実験協力者 B，F，I，J は Data Jacket 検索システムなしでも比較的多数の正解アイテムを発見できている．しかし，10 名中 9 名の実験協力者では，Data Jacket 検索システムを

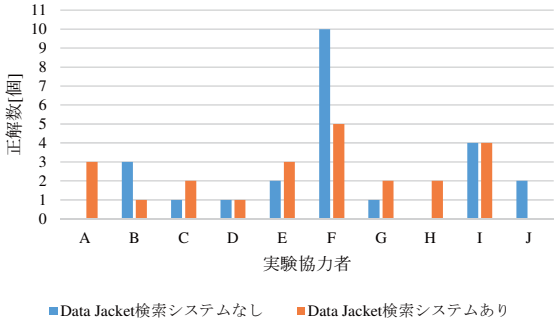


図 2: タスク 1 で見つけたアイテムの正解数

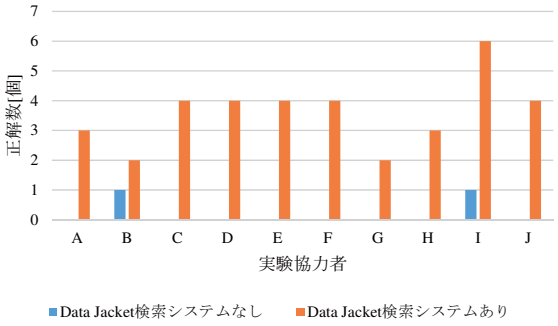


図 3: タスク 2 で見つけたアイテムの正解数

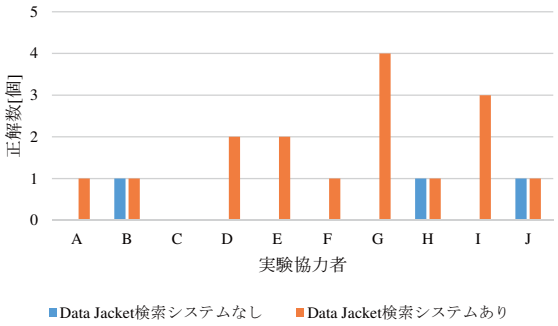


図 4: タスク 3 で見つけたアイテムの正解数

利用することで，さらにアイテムを発見している．特に 5 名の実験協力者においては，Data Jacket 検索システムを利用した場合の方が，より多くの正解アイテムを発見できている．また，他の 2 つのタスクは,「指定されたアイテムと関係があると思われるアイテムを探す」というタスクであったが，Data Jacket 検索システムなしの場合，関係のあるアイテムを見つけるのに苦労していたことがわかる．実験協力者 C のタスク 3 を除き，Data Jacket 検索システムを利用することで正解アイテムを発見できている．以上から，Data Jacket 検索システムを利用して過去の知見を頼りにすることで，関係があるアイテムの発見が容易になると考える．

5. おわりに

本稿では Data Jacket を導入し，ローカルデータと公開データを統合利用可能とするコンテクスト検索エンジンを提案した．評価実験の結果，Data Jacket 検索システムを利用することで，Data Jacket や過去に発見された知見を活用できることを示した．今後は，Data Jacket や知見の増加に対応可能な検索手法について検討する予定である．

参考文献

[高間 15] 高間，加藤，桑折，石川 : 動向に関する問いを対象とした検索エンジンの提案，人工知能学会論文誌，Vol.30, No.1，pp.138-147，2015.

[大澤 14] 大澤 : データジャケット-創造的コミュニケーションのあるデータ市場のために-，人工知能，Vol.29，No.6，pp.622-627，2014.

[早矢仕 16] 早矢仕，大澤 : Data Jacket Store : データ利活用知識構造化と検索システム，人工知能学会論文誌，Vol.31, No.5，pp.A-G15_1-9，2016.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

企業間でのマーケティングデータによる共創的価値創出に向けた課題分析

Analysis of issues for creating co-creative value through marketing data among companies.

小口 裕[*1]
Yutaka Oguchi

土田 尚弘[*1]
Naohiro Tsuchida

[*1] 株式会社日本リサーチセンター
NIPPON RESEARCH CENTER, LTD

In recent years, it has become increasingly important for many companies to utilize data obtained from consumers in their marketing. While various companies exchange and utilize marketing data with each other, the approach to extract co-creative value is still in the process of improvement. In this research, by using IMDJ (Innovators Marketplace on Data Jackets), we analyzed expectations, needs, and problems for data exchange, based on the characteristics of marketing data and players. We also proposed incentive design for marketing data exchange with other companies.

1. はじめに

近年のマーケティングにおいて、生活者から得られたデータの利活用の重要性が、これまで以上に高まっている。伝統的にはアンケートデータを主としたマーケティングリサーチ、近年では WEB ログや SNS といったデータが利活用されるようになっている。しかしマーケティングデータが多様化して、利活用の重要性が高まるにつれて、実務的な課題も顕在化している。

たとえば、これら多様なデータのうち、どれをマーケティング課題に対して利活用すればよいのか、どのようにその価値を引き出せばよいのかわからない、また企業で一度使用されたデータは、その戦略的な再利用が図られることなくストックされてしまい、その価値を十分に活かしきれていない、との声もある。

また、サービス・ドミナント・ロジック[Vargo 04]や顧客体験の重視[Lemon 16]に代表されるように、生活者の視点がモノからコトに移行しつつある。本来ならば、多様なデータから、生活者の多面的な「コト」を理解していく必要があるものの、現状は個々のデータで生活者の断片を切り取るような、局所的な生活者理解のための分析やデータ利活用に留まるケースもみられる。

さらなる課題として、近年のマーケティングでは共創とよばれるステークホルダー間のコラボレーションが重要になっている[Kotler 16]。企業内・企業間におけるデータの相互流通や利活用の重要さが増しているが、そのインセンティブが上手に設計できておらず、データ開示のリスクのみがクローズアップされ、その流通が進まないという膠着もみられる。

これらの問題に対しては、マーケティングにおけるステークホルダー同士が、データの利活用方法を議論して、お互いのインセンティブを萌芽させるアプローチが有効である。本研究では、IMDJ（Innovators Marketplace on Data Jackets）を用いて、マーケティングデータの利活用に関する課題を分析し、共創やデータ流通の促進に向けた実務的なアプローチを考察した。

2. 先行研究

2.1 Innovators Marketplace for Data Jackets (IMDJ)

IMDJ は、データジャケット（DJ）を用いてデータの利活用方法を検討するための、ゲーム型ワークショップである[早矢仕 14]。DJ とは、あるデータがどのようなデータであるのかを説明・要約したメタデータである。データの利活用方法を、DJ を用いて議論することで、データそのものの共有によって生じるかもしれないプライバシーの問題やビジネス機会損失といったリスクを低減することができる。参加者は IMDJ において、データ保有者、利用者（データ利活用についての要求を出し、その報酬を払う）、提案者（データ利活用のアイデアを出す）の役割を担う。その役割に沿ってデータ利活用提案（ソリューション）を生成し、互いに評価しあいながら、さらにその価値を高めていく。

2.2 データエクスチェンジ

データエクスチェンジとは、データのやり取りについて交渉相手を定め、コミュニケーションを通じて決定した範囲でデータを提供し、または提供を受ける戦略である[大澤 17]。データエクスチェンジに参加するメリットは、①データ市場で自らのデータをアピールして評価を得る、②自らのデータと組合せできる他のデータや、適用できる分析方法を知る、③自らのデータの利活用方法を知り、その価値を知る、④データと分析方法の組合せを知り、意思決定に役立てられる、という点が挙げられる。

マーケティングで必要なデータは、これから何をすべきか、という指針を示し、その意思決定に資するデータであるとされる[朝野 00]。そこで本研究では、IMDJ におけるマーケティングのステークホルダー（例：マーケッター）による相互の議論を通して、データエクスチェンジや共創への期待を確認すると共に、データを意思決定に活かす上での課題や、データエクスチェンジを促進する実務的なアプローチを考察する。

3. 実施

3.1 実施方法

IMDJ の実施概要は次の通りである（表1）。IMDJ の参加者は、異なる業種からそれぞれ1社、マーケティングリサーチ部門のマネージャーもしくは実務担当で構成された。DJ は参加者が自社のマーケティングデータを加工して、当該 IMDJ 限りの前提で提供した。各社にとって秘匿性の高い変数は除外し、アンケートデータの様に DJ1枚の変数（設問）が多い場合は、変数のタイプや系列によって分割して別の DJ とした。DJ に含まれる内容は、タイトル、データの概要（データの取得目的や調査課

連絡先：小口 裕,株式会社日本リサーチセンター,東京都中央区日本橋本町 2-7-1,03-6667-3452,oguchiyk@nrc.co.jp
土田尚弘,株式会社日本リサーチセンター,東京都中央区日本橋本町 2-7-1,03-6667-3137, tuchidanh@nrc.co.jp

題など)、取得方法(データの設計情報など)、変数(設問や定義など)の4項目とした。

表 1:IMDJ 実施概要

参加企業：	民間企業 7 社（人数：15名） （日用品、食品、保険、メディア、インフラ、通信など異業種から 1 社ずつ参加） ＊マーケティングデータを扱う部門関係者
場所：	株式会社日本リサーチセンター
時期：	2017年8月

3.2 データ

参加社から提供された DJ は 32 件となり、内訳は以下の通りである(表 2)。DJ 計 32 件のうち、アンケートデータが 20 件(62.5%)で 6 割強となり、次いで営業履歴、コールセンターの応答履歴、SNS などアンケート以外の DJ が 12 件(37.5%)となった。また、商品購入のきっかけ・商品選択時に生じた問題・苦情など、自由回答(テキスト情報)を含むものが 10 件(31.3%)、競合企業など自社以外の商品やチャネル、ブランド評価に関する変数(設問)を含む DJ が 7 件(21.9%)となった。

表 2:DJ の内訳(n=32)

データの内容	件	%
アンケート	20 件	62.5%
アンケート以外のデータ	12 件	37.5%

自由回答（テキスト）を含む	10 件	31.3%
競合関係	7 件	21.9%

また、DJ 計 32 枚に含まれる変数(設問)の内訳は以下の通りである(表 3)。DJ に含まれる変数の数は平均 8.6 変数であった。また、顧客ターゲットを絞り込む際に用いられる性別・年代など、対象者のデモグラフィックに関するものが、平均 3 変数、価値観・意識・こだわり・イメージ・認知・好感・意向・満足度・重視点など、生活者の意識・感情・態度に関する変数が、ほぼ全ての DJ に含まれており、平均 1.5 変数となった。

表 3:DJ に含まれる変数の数(n=32)

設問内容		平均数
全体		8.6 変数
	デモグラフィック設問	3 変数
	意識に関する設問	1.5 変数

3.3 KeyGraph(R)による分析

これらの DJ 同士の関係を可視化して、参加者による俯瞰的な議論を促すため KeyGraph(R)による分析を行った。KeyGraph(R)とは、定められたテーマで集められた情報群(データ)から、頻度は低いが意思決定において重要だと考えられるキーワードを抽出し、関係性を可視化するアルゴリズムである[大澤 03]。対象となる情報群に含まれる言葉と言葉の関係をノードとリンクで可視化することができる。本研究では、DJ の変数の情報から可視化されたノードを「青」、同様にデータ概要や取得方法から可視化されたノードを「赤」で表現した。なお、参加者による多面的な議論を促すため、日本リサーチセンターで、生活者やマーケティングに関係する行政のオープンデータを含む 21 枚の DJ を追加して、計 53 件の DJ を分析対象とした。

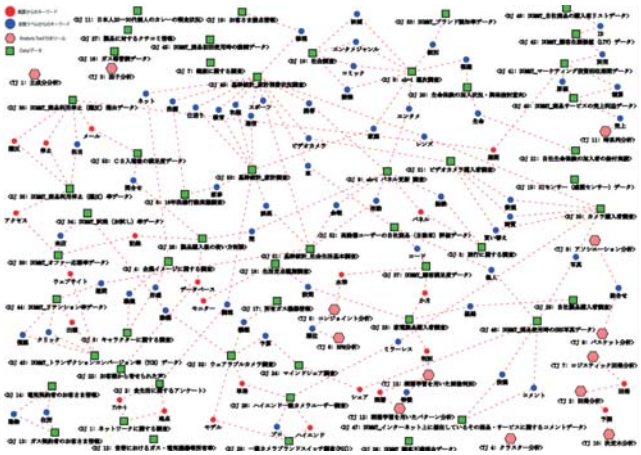


図 1:KeyGraph(R)による DJ の可視化結果

KeyGraph(R)による分析(図1)の結果、青ノード:62 個、赤ノード:22 個、同様にリンク(ノードとノードの間に引かれ、両者の関係を示す)として、青ノードへのリンク:57 本、赤ノードへのリンク:18 本が可視化された。また被リンク数をみると、家計消費状況調査(12 本)が最も多くなり、家計調査(8 本)、社会生活基本調査(5 本)などの行政オープンデータが続いた。

3.4 データ利活用要求・ソリューション分析

KeyGraph(R)に対して、データ利用者から利活用のついての要求が計 38 件提示された。また、それらの要求に対するソリューションが計 8 件考案された。また、これら 8 件のソリューションの考案にあたり、DJ が計 26 件、ソリューション1件につき平均 3.1 件が利活用された。最も多く使われた DJ は一般生活者を対象とした「生活定点観測調査」の 4 件であり、次いで、同じく一般生活者を対象とした「娯楽全般に関する社会調査」が 3 件のソリューションで利活用された(表 4)。

また 8 件のソリューションのうち、参加者から最も評価を獲得したのは「家庭・家事・夫婦」をテーマとしたソリューション(5 ポイント)、次いで食生活や生活習慣に関するテーマとなった。

表 4:ソリューションへのDJの利活用件数(2 件以上)

ＤＪ内容	利活用件数
生活定点観測する調査	4 件
娯楽全般に関する社会調査	3 件
健康に関する調査	2 件
所有機器の情報	2 件
家電商品購入者の調査	2 件
商品口コミ調査	2 件

表 5:ソリューションへの参加者の評価数(2pt 以上)

ソリューションの内容	評価数
家庭・家事・夫婦	5 pt
食生活とエネルギー使用	2 pt
生活習慣と健康	2 pt
商品利用の次期購入意向の関係	2 pt

4. 考察

4.1 生活者の多面的理解への期待

IMDJに提供されたマーケティングデータの DJ のうち、約 4 割弱(37.5%)が営業訪問履歴、コールセンターや SNS などのアンケート以外のデータであった。また自由回答で生活者の意識や感情を把握する目的の変数が 3 割強(31.3%)、競合の商品・チャネルやブランドについての変数が 2 割強(21.9%)となった。これらのデータのみからの言及は難しいが、伝統的なマーケティングデータのアンケートや POS(Point of Sales)データに加えて、営業訪問履歴などの顧客接点の記録、問合せ記録、SNS などのバラエティの広さや、意識・感情を把握する変数の多さから、生活者をより多面的に解釈しようという近年のマーケティング傾向が伺える結果となった。

次に、IMDJ の結果から、マーケティングデータの利活用を図る上での特徴や、データに対するニーズを考察する。

提示されたソリューションをみると、家庭・家事・夫婦(円満な夫婦像のペルソナ作成の提案)や、食生活とエネルギー、生活習慣と健康(お金の使い方と健康についての提案)など、商品開発のニーズにダイレクトに応えるソリューションというよりは、生活者を広く深く捉えていく目的の提案が上位となった。

この結果からも、生活者の重視点がモノからコトへと移行する中で、生活者をより広い視点、かつ精緻に内面を捕捉してこうという近年のマーケティングの傾向が伺える。

4.2 マーケティングデータの特性と利活用ニーズ

DJ の変数から可視化された青ノードが、データ概要や取得方法から可視化された赤ノードと比べて、総数やリンク数で大きく上回った。特にアンケートデータの場合、設計者が変数を意図をもって設計・設定することが多く、結果として、変数から生じた青ノードが相対的に多くなったものと思われる。

また、ソリューションに利活用された DJ は、上位から「生活定点観測する調査」「娯楽全般に関する社会調査」となり、いずれの DJ も、生活者の広範なライフスタイル、デモグラフィック変数で構成されていた。これらの DJ について参加者から「定点である」「長期間、継続的に取得されている」「項目が汎用的で扱いやすそう」との評価があった。この結果から、このような汎用性の高い多くの変数を定期定点に収集しているデータの利活用ニーズが伺える結果となった。

また、リンク数が多い DJ は、家計消費状況調査(12 本)、家計調査(8 本)、社会生活基本調査(5 本)となり、いずれも総務省の統計調査データとなった。この結果は、マーケティング領域における行政オープンデータの可能性を示唆するものだが、IMDJ では、いずれのソリューションでも利活用されなかった。

ただし、行政オープンデータと他のノードとのリンクに着目すると、家計調査と娯楽全般に関する社会調査が「家庭」という青ノードでリンクし、さらに他の業界のマーケティングデータとリンクして派生するケースや、家計消費状況調査とカメラの購入実態調査がリンクして、そこから、当該業界の他の調査と「画質」「ミラーレス」といった専門性が感じられるワードの青ノードとリンクして派生するケースが見られた。これらのデータは、利活用の少ない行政オープンデータから、他業界や特定業界の深いデータにブリッジするデータといえる。ブリッジするデータには、ソリューションでの利活用件数が上位のデータも含まれており、これからの行政オープンデータの利活用促進に向けて、このようなブリッジデータが、媒介の役割を果たす可能性が示唆された。

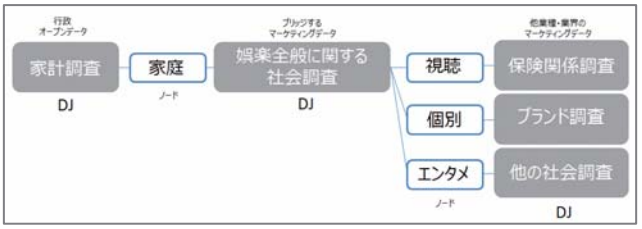


図 2:家計調査からのブリッジ

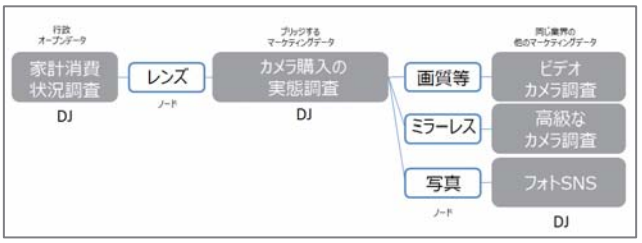


図 3:家計消費状況調査からのブリッジ

4.3 データエクスチェンジへのニーズと課題

次に IMDJ を通じたマーケティングの共創、特に企業間におけるコラボレーションについて考察する。すでにデータ利活用の目途が立っており、自社のみでデータを保有することがビジネス展開上重要であることが分かっている場合、データ共有の動機が薄まる傾向がみられる[経済産業省 15] 。マーケティングデータのうち、特にアンケートデータは、自社での利活用を前提に設計されるため、その傾向が強くなることが想定された。

IMDJ の後、参加者にデータエクスチェンジついてのヒアリングを行った。その結果、「社内におけるデータ流通の壁を超えてデータを利活用する必要性」「自社の DJ に意見がもらえる喜び」「DJ で社内交流を進める機会創出への意欲と期待」など、データエクスチェンジを進めるリスクや手間が企業間ほど高くはなく、知識やコミュニケーションがハイコンテクストで共創の効果が得られやすい社内(インハウス)でのデータエクスチェンジへの期待を感じさせる声が多く見られた。

一方、社外とのデータエクスチェンジに対しては、ソリューションにも多く用いられた「生活定点観測する調査」「娯楽全般に関する社会調査」」などについて「このデータが(自社でも)使えるならば(データ取得コストを下げる観点で)購入を検討したい」といった声が見られた。これは、一般生活者のライフスタイルやデモグラフィックなど、マーケティングで汎用性のある変数を、定期・定点的に取得しているデータのエクスチェンジへの期待とも解釈できる。

一方で、「他社のマーケティングデータを活用してビジネスを行う場合の権利・運用が気になる」といった実務上のハードルを指摘する声もみられた。

5. 結論

マーケティングデータの利活用について、本研究では IMDJ を利用して、その期待やニーズ、そして課題を分析した。

まず、近年のマーケティングにおける「モノからコト」への重視点の移行に伴い、複数のデータを多面的に解釈する必要が生

じているが、伝統的なアンケートデータや POS データに加えて、営業接点や CRM データ、コールセンター、SNS などが利活用されている実態が確認された。また、生活者をより広く深く捕捉していくための変数が多く見られ、それらを利活用して考案されたソリューションにも同様の傾向が見られた。断言はできないものの、多面的な視点から生活者と向き合って、深く解釈していこうという近年のマーケティング傾向を感じさせる結果となった。

一方で、DJ に含まれる変数の数は平均 8.6 変数、内容もバラエティに富むことから DJ1枚の情報量が増え、参加者から DJ の直感的読解が難しいとの声があった。この点は、マーケティングデータ、特にアンケートデータを DJ に用いる際の IMDJ 運営上の課題である。DJ 作成者（参加者）からの内容説明の機会を設けるなど参加者間の DJ 共有への対処が必要である。

KeyGraph(R)による分析結果をみると、青ノードが多くみられたことから、変数が意図をもって設計されるアンケートデータの特徴を感じさせる結果となった。一方で、データの概要項の内容が、青ノードの変数情報と冗長になり、青ノードが増えてしまった可能性も否めない。今後はデータの概要に「データ利活用目的」の記入を参加者に徹底するなどの配慮が必要である。

また、ソリューションでは、広く汎用性のある変数を定期定点収集しているデータが積極的に選ばれる傾向がみられた。行政オープンデータのリンク数が多く、今後のマーケティング領域での利活用可能性が示唆された。一方で、これらのデータはソリューションでは用いられなかった。但し、行政オープンデータから個別領域のデータを媒介（ブリッジ）するデータが確認された。これらは行政オープンデータの利活用促進に向けた手がかりとなることが期待される。

マーケティングにおける共創、特に企業間のコラボレーションについては、IMDJ 後の参加者へのヒアリング結果から、データ開示へのハードルが比較的低く、ハイコンテクストな共創環境が得られやすいインハウスでのデータエクスチェンジへの期待が伺えた。その一方で、社外とのデータエクスチェンジについては、共創というよりデータ収集コストの低減を意図したニーズに留まり、データによる共創やデータの社外提供へのインセンティブを感じさせる声は多くなかった。権利・運用の実務上のハードルを指摘する声もあり、今後に向けた課題とした。

6. 今後の展望

上述の通り、企業間のコラボレーションにおいては、コスト観点からのデータ購入ニーズがみられた一方で、共創という本来のインセンティブが上手に機能していない様子が伺えた。

この点への対応策として、よりハイコンテクストな企業間フォーラムを設定し、企業間のデータチェンジや共創への期待を高めるアプローチが考えられる。本研究における IMDJ 参加者は、異なる業種で同じマーケティング業務に携わる関係者であった。しかし、マーケティング業務は本来、ターゲットとする市場セグメントや顧客像、自社のポジショニングにより、その内容が大きく異なるものと想定される。

IMDJ の運営は、広すぎず、狭すぎもしない、ちょうど良い規模の参加者で、互いに信頼関係が保たれ、親和性が高いチーム構成が良いとされる[大澤 2017]。たとえば、マーケティングでは、マーケティングデータの取り扱い実績が豊富な事業者が、ターゲットとする市場セグメントや顧客のデモグラフィック（例：若年層、シニア）など、マーケティング施策に沿った括りで参加者を募ってフォーラムを構成し、参加者間のマーケティング課題や前提知識をハイコンテクストに保つことで、データの提供や共創インセンティブを高められる可能性がある。

また、マーケティングにおけるデータエクスチェンジ上の課題として、特にアンケートデータの場合、ワンショットで収集されたデータが比較的多いため、時間を軸としたデータ結合が難しいことから、異なるデータ間で共通変数を設定するなど、データエクスチェンジを前提とした設計と規格化が必要と思われる。また、変数自体に企業の設計意図が込められるパターンや、複数の変数の纏まり（系列）で初めて意味をなすデータセットも見られたことから、DJ 作成上で、それらへの配慮が必要と思われる。

また、マーケティングデータはその利活用目的から、生活者のデモグラフィックやライフスタイルなど個人特定につながりやすく、ケースによっては過去の病歴などの機微情報に類する変数が含まれることがある。生活者を広く深くとらえる汎用的なデータへのニーズが確認されたことから、匿名加工の在り方など、プライバシーに十分に配慮したデータエクスチェンジの運用・ガイドライン設計が重要と思われる。

謝辞

本研究における IMDJ 実施において、東京大学大学院工学系研究科の大澤幸生教授、並びに早矢仕 晃章助教には理論・実践の両面から多くのご指導を頂きました。ここに感謝の意を表します。

参考文献

[Vargo 04] Vargo, S. L. & Lusch, R. F.: Evolving to a New Dominant Logic for Marketing, *Journal of Marketing*, 68(1), pp.1-17, 2004.

[Lemon 16] Lemon, K. & Verhoef, P. C.: Understanding Customer Experience Throughout the Customer Journey, *Journal of Marketing*, 80(6), pp.69-96, 2016.

[Kotler 16] Kotler, P., Kartajaya, H.,Setiawan, I.: *Marketing 4.0: Moving from Traditional to Digital*, Wiley, 2016.

[朝野 14] 朝野熙彦：マーケティングリサーチ工学, 朝倉書店, 2000.

[大澤 17] 大澤幸生, 早矢仕晃章, 秋元正博, 久代紀之, 中村潤, 寺本正彦：データ市場, 近代科学社, 2017.

[早矢仕 14] 早矢仕晃章, 大澤幸生：データの価値と利用方法発見のための創造的コミュニケーションとメタデータ記述方法の提案, 2014 年度人工知能学会全国大会（第 28 回）, 2014.

[経済産業省 15] 経済産業省: 我が国経済社会の情報化・サービス化に係る基盤整備（データ駆動型イノベーション創出に関する調査事業 調査研究報告書,経済産業省, 2015.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

ロイターニュース記事からの因果関係抽出の試み

An Experiment of Causal Knowledge Extraction from Reuter News

坂地 泰紀 *1 Hiroki Sakaji　ベネット ジェイスン *2 Jason Bennett　宮尾 祐介 *3 Yusuke Miyao　和泉 潔 *1 Kiyoshi Izumi

*1東京大学 The University of Tokyo　*2三井住友アセットマネジメント Sumitomo Mitsui Asset Management Company, Limited　*3国立情報学研究所 National Institute of Informatics

In this paper, we try to develop a method for extracting causal expressions from news articles. First, we investigated clue expressions that are included in news articles. Next, we focused on specific clue expressions and developed the method to extract causal expressions.

1. はじめに

近年，人工知能分野の手法や技術を，金融市場における様々な場面に応用することが期待されており，例えば，膨大な金融情報を分析して投資判断を支援する技術が注目されている．さらに，最近では証券市場における個人投資家の比重が増大しており，個人投資家に対して投資判断の支援を行う技術の必要性が高まっている．

投資家にとって，企業の業績に関する情報は，投資判断を行ううえで重要であるが，企業の業績だけでなく，その業績要因に含まれる因果関係が重要である．例えば，原因「猛暑」，結果「冷房需要の盛り上がり」といった因果関係を投資家に提示することで,「猛暑」の場合には,「冷房需要」が高まる可能性があることを個人投資家が知ることができるというメリットがある．そして，その原因「猛暑」に対する結果「冷房需要の盛り上がり」の因果関係から，猛暑の年には，冷房に関する事業を行っている企業の業績が好調に推移することが期待できる．

そこで我々は，ロイターニュース記事に含まれる因果関係を抽出するために，その調査をまず行った．その後，構文解析結果を用いた抽出手法の開発を試みた．

2. ロイターニュース記事中の因果関係の調査

我々は，ロイターニュース英文記事中の因果関係を表す手がかりとなる表現 (手がかり表現) を調査するため，ランダムに 20 記事選び，その中に含まれる因果関係と手がかり表現を調査した．ここで我々が対象とする因果関係の定義としては，The penn discourse treebank(PTDB)[Prasad 07] における “Cause” に該当する．手がかり表現と因果関係を調査した結果，381 文中 30 個の因果関係を発見することができた．加えて，表 1 に示す手がかり表現を得ることができた．

表 1 より，一般的に因果関係を示す手がかり表現である「because」や「as」などは見つけることができた．しかしながら，「since」や「from」等の他の手がかり表現は調査中に含まれていなかった．調査の結果，大きく分けて「will keep」や「cause」などの動詞である手がかり表現と,「because」や「because of」などのその他の手がかり表現があることが分かった．ここで，先行研究である Mirza et al.[Mirza 14b] の手法によると，彼女らは手がかり表現として **affect verbs**, **link verbs**, **causative verbs** と **CSIGNAL** を用いている．CSIGNAL は，前置詞 (because of, as a result など)，接続詞 (because, since, so that)，副詞 (so, threfore, thus) や特殊な表現 (the reason why, the result is, that is why) から構成される．このうち，affect verbs, link verbs, causative verbs が動詞である手がかり表現に該当し，SIGNAL がその他である手がかり表現に該当する．すなわち，定義の細かさは異なるが，我々が調査した結果は，Mirza et al.[Mirza 14b] が定義した手がかり表現と同様の分類となったことを意味する．

表 1: 調査で得られた手がかり表現一覧

That's why	1	affected	1
after	1	will keep	1
as	3	because	8
because of	2	will pressure	1
buoyed by	1	due to	1
fuelled by	1	helped by	1
meant that	1	partly because of	1
partly on	1	prompted by	1
was aided by	1	will also dampen	1
will check	1	will entice	1

さらに，調査を進めたところ，Mirza et al. や Khoo et al. などの手法でも用いられている手がかり表現「because」において，因果関係を含まない例を見つけることができた．

> ”They won't let North Korea get away with it **because** others might try the same thing,” said Redeker at BNP Paribas.

この文では，might が含まれているため，意味として仮定を表しており，原因・結果を表す因果関係ではない．

上記のように,「because」が含まれていれば必ず原因・理由の因果関係を示すわけではないということが分かった．つまり，because などの手がかり表現が含まれている場合において，因果関係を意味する文か否かを判定する手法が必要となってくる．判定手法の試みに関しては，4. 節にて述べる．

3. 因果関係抽出の試み

我々は，まず，because と will +動詞である手がかり表現について，原因・結果を抽出できる手法を開発した．日本語における因果関係抽出手法としては，我々が開発した手法 [Sakaji 08] が

連絡先: 坂地泰紀，東京大学大学院工学系研究科，sakaji@sys.t.u-tokyo.ac.jp

存在する．それに対して，英語文における因果関係抽出手法としては，Chang et al.[Chang 06] の手法や Khoo et al.[Khoo 00] の手法，Mirza et al.[Mirza 14a] の手法が存在する．上記で挙げた手法のほとんどでは，構文解析の結果を利用して因果関係を抽出している．本研究においても，構文解析の結果を利用する．

本研究では，構文解析器として Stanford CoreNLP*1 を利用する．例えば，以下の文を構文解析器にかけると，図 1 のような結果が得られる．

> It may augur well for the local economy **because** the Philippines is heavily dependent on remittances from overseas Filipino workers.

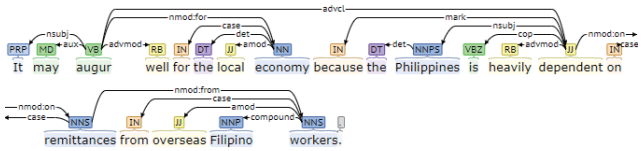


図 1: 構文解析した結果

上記例にタグ付けしたところ，以下のような結果が得られた．

> <effect>It may augur well for the local economy</effect> <clue>**because**</clue> <cause>the Philippines is heavily dependent on remittances from overseas Filipino workers.</cause>

また，will ＋動詞からなる手がかり表現の例を以下に示す．

> <cause>Fears of war in Iraq and a stand-off with North Korea about nuclear weapons</cause> <clue>**will keep**</clue> <effect>the dollar weak in the first half of the year.</effect>

上記結果から，手がかり表現 because では，「結果表現, 手がかり表現, 原因表現」の順に出現し，手がかり表現 will ＋動詞では，「原因表現, 手がかり表現, 結果表現」の順に出現することが分かった．日本語においても，手がかり表現によって，原因表現と結果表現の出現する順番が異なることは，我々が過去に行った調査で分かっている．英語文においても，同様に，手がかり表現によって原因表現と結果表現の出現する位置が異なることが分かった．

我々は，日本語においては，5 つの構文パタンで因果関係を抽出する手法を開発した．英語文においても，Khoo et al.[Khoo 00] の手法が示すように，構文パタンが存在すると考えられる．今後は，手がかり表現の種類によって，構文パタンは異なるのか，または，同様なのかを調査し，適切な抽出手法を開発することを試みる．

4. 因果関係判定手法の試み

前節の述べたように因果関係の有無を判定する手法の必要があったため，その手法の開発を試みた．前節で取得した手がかり表現を含む文をランダムに 4,000 文抽出し，因果関係が含まれるか否かのタグを付与した．その結果，4,000 文中 1,599 文に因果関係が含まれていた．我々は，調査のために，タグ付けしたデータのうち 3,000 文を学習データに，1,000 文を評価データにして，いくつかの機械学習手法を試した．その結果を表 2 に示す．結果より，機械学習によっての分類性能の差はほどんどなかった．

表 2: 機械学習により判定した結果

	適合率	再現率	F 値
SVM	0.737	0.906	0.813
RandomForest	0.730	0.977	0.836
BiLSTM	0.741	0.950	0.832

5. まとめ

本研究では，ロイターニュース英文記事に含まれる因果関係を調査し，その抽出を試みた．調査した結果，Mirza et al.[Mirza 14b] が用いていた手がかり表現と類似した手がかり表現を得ることができた．構文解析手法を用いて，いくつかの手がかり表現を対象に，因果関係抽出手法を開発することはできたが，他の手がかり表現から抽出を行う手法はまだ開発できていない．今後の課題としては，全ての手がかり表現を利用して因果関係を抽出する手法を開発し，その性能評価を行うことが考えられる．

参考文献

[Chang 06] Chang, D.-S. and Choi, K.-S.: Incremental cue phrase learning and bootstrapping method for causality extraction using cue phrase and word pair probabilities, *Information Processing and Management*, Vol. 42, No. 3, pp. 662–678 (2006)

[Khoo 00] Khoo, C. S., Chan, S., and Niu, Y.: Extracting Causal Knowledge from a Medical Database Using Graphical Patterns, in *Proceedings of the 38th ACL*, pp. 336–343 (2000)

[Mirza 14a] Mirza, P.: Extracting temporal and causal relations between events, in *Proceedings of the ACL 2014 Student Research Workshop*, pp. 10–17 (2014)

[Mirza 14b] Mirza, P. and Tonelli, S.: An analysis of causality between events and its relation to temporal information, in *Proceedings of COLING 2014, the 25th International Conference on Computational Linguistics: Technical Papers*, pp. 2097–2106 (2014)

[Prasad 07] Prasad, R., Miltsakaki, E., Dinesh, N., Lee, A., Joshi, A., Robaldo, L., and Webber, B. L.: The penn discourse treebank 2.0 annotation manual (2007)

[Sakaji 08] Sakaji, H., Sekine, S., and Masuyama, S.: Extracting Causal Knowledge Using Clue Phrases and Syntactic Patterns, in *7th International Conference on Practical Aspects of Knowledge Management (PAKM)*, pp. 111–122 (2008)

∗1 https://stanfordnlp.github.io/CoreNLP/

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

データ 3.0 時代のデータランドスケープ

Data Landscape in the Era of Data 3.0

早矢仕晃章*1
Teruaki Hayashi

大澤幸生*1
Yukio Ohsawa

*1 東京大学大学院　工学系研究科　システム創成学専攻
Department of Systems Innovation, School of Engineering, The University of Tokyo

The potential expectations for discovering problems and solving them by combining data and knowledge in different domains have been increasing. However, there are many social barriers to its realization. Data is originally the property that expresses the observed phenomena or events in the world in symbols and character strings, which is Data 1.0 in this paper. Afterward, Data 2.0 has been developed by the privilege of personal devices or Internet of Things, which is the era of linked data stored in different domains. While the benefits of data 2.0 are immeasurable, the technologies and discussions to combine only data are reaching the limits. In this paper, we propose "Data 3.0" as a new stage in the cross-discipline data utilization and discuss the Data Landscape in the era of Data 3.0.

1. はじめに

近年，様々な分野で蓄積された膨大なデータを利用し，意思決定に役立てようとする動きが活発になり，ビッグデータの世界的なブームも起きた．さらに，人工知能（AI）の普及も後押しし，データの役割はますます重要となってきている．そのような社会背景の中で，既存の分析技術や統計学では扱えないデータが登場してきた．さらに今まで AI が主要技術ではなかった分野においても AI 関連技術に対する注目が集まっている．そこで，一つの企業や組織のデータではなく，異なる領域のデータや知識，AI 技術を流通・交換・連携させることで新しい価値を発見し，問題解決を行う動きが進展してきた．

本質は変わらないものの，データを取り巻く環境，役割，価値は時代と共に大きく変容してきた．原初のデータは，世の中で起こる複雑な現象を理解するために，対象を観察し，特徴を抽出し，符号化したものであった．すなわち，データの本質は，事実を文字，数値，記号として記述したプロパティであると言える．だが，ビッグデータのように計算機やセンサーの高度化によって，膨大かつ高粒度なデータが取得可能となった．このような技術の進展によって，蓄積されたデータの再利用によって付加価値を生み出したいというニーズが高まり，様々な技術やサービスが誕生した．さらに，異なる領域の異種のデータを繋げることにより，新しい発見を促す技術も発展してきた．その中で，Web 上でデータを交換するプラットフォームを事業化したデータ市場の一形態も登場してきた．そして，AI 技術の社会実装により，異なる領域のデータを組み合わせるだけでなく，知識との融合によって問題を発見し，解決を目指す動きが萌芽し始めた．以上のように，人類の歴史の中で登場した初期のデータと比較し，現在のデータは質や量のみならず，意義，利用価値，役割が大きく異なっていると言えよう．

連絡先：早矢仕晃章，東京大学大学院　工学系研究科　システム創成学専攻，hayashi@sys.t.u-tokyo.ac.jp
大澤幸生，東京大学大学院　工学系研究科　システム創成学専攻，ohsawa@sys.t.u-tokyo.ac.jp
This research was supported by JST, CREST. 本研究の着想を得るにあたり，2018 年 3 月に退官された東京大学大学大学院工学系研究科システム創成学専攻教授　大橋弘忠先生の最終講義を参考にさせて頂きました．ここに感謝致します．

本稿では，異分野のデータ連携と知識の融合の時代におけるデータを「データ 3.0」と定義し，異分野データ連携の課題とデータ 3.0 時代におけるデータの在り方とデータがもたらす世界の見え方（データランドスケープ）について論ずる．

2. データの役割とその変遷

2.1 データ 1.0 からデータ 2.0 へ

原初のデータとは，文字，数値，記号として記述可能な事実であり，分からない現象を理解するために用いられてきた．例えば，太陽や星の位置を記録することで時間や年月を把握したり，様々な物理量に単位系を与えることで共通理解を得ることなどが挙げられる．つまり，データは実世界の複雑な現象を解釈可能とするために，分析対象の特徴を切り出し，仮想世界の中で対象を再構成するために誕生した．データを用いることによって，人間は実世界及び社会の事象を処理し，理解し，知識を伝達することができるようになった．これがデータの始まりであると筆者らは考える．つまり，この黎明期におけるデータは，伝達，解釈，処理に適する形式（文字，数値，記号）に表したものであり，「データ 1.0」と呼べる段階であったと言えよう．データ 1.0 におけるデータの扱い方は分析（analysis）であり，すなわち「ある事柄の内容や性質を明らかにするため，細かな要素に分けていくこと」であった．

続く「データ 2.0」はデータの統合（synthesis）の時代となる．データ 1.0 におけるデータ分析は，物事を理解するために，より細かく局所的に事象を観察し，データ化すること物事の内容や性質を明らかにすることが主であった．しかし，分野が細分化し，取得可能なデータも多岐に渡り，変数同士の組み合わせも膨大となる中，「分析」という語は従来の語義である「細かな要素に分けていく」作業だけでなく，異なる領域のデータを結合することで物事の内容や性質を理解する試みも含むようになった．つまり，対象とする事象だけでなく，対象事象の周辺で起こっている事象を含めて，大局的に見ることで大きな物事の関連性を発見することが求められるようになった．データ 2.0 と呼べるこの潮流は，データ融合（data fusion）や，オープンデータ，Linked Data [Berners-Lee 06], Linked Open Data などのセマンティック Web 技術や社会的な運動の原動力となった．オープンデータ

の盛り上がりによって，行政が保有するデータに誰もがアクセス可能となる社会に対する期待も高まった．データ 2.0 はデータの公開と民主化の時代でもあったと言えよう．

2.2 データ 3.0 におけるデータ市場

データ 2.0 の時代には，Web の発展，スマートフォンなどのパーソナルデバイスの普及やセンサーの高度化，Internet of Things（IoT）の進展などによって様々な領域のデータを連結させた結果，分野横断的なデータ駆動型イノベーションが起こり，多くの成功を収めた．しかし，データ 1.0 の時代と比較してさらに多様なデータが取得され，結合されるようになった結果，データモデルが複雑化・多様化した．もちろん，全ての人がデータについて詳しいわけではない．誰もがアクセス可能なデータのネットワーク（知識ベース）を作っても，データの構造を把握している人，あるいは設計者しか欲しいデータを検索・発見できなくなってしまった．しかも，ビッグデータのブームに代表されるように，データの設計者でさえ全体像を把握することが困難なほどにデータは膨大となった．データ 2.0 時代のデータは人間の認知の限界を超えてしまった．例えば，関連分野の論文でさえも全てを読破することがほぼ不可能となったことが挙げられる．さらに，有益な分析結果を得るためには，単一のデータソースだけでなく，複数のデータを適切に組合せることが重要[Ellram 16]であるが，データの組み合わせは無数にあり，全ての組み合わせを考慮することはもはや不可能である．行政や自治体では，オープンデータ戦略に則り，データを公開したもののなかなか利用されていないという問題も存在する[狩野 18]．データ 2.0 によって，データが広く社会のシステムに普及した一方で，システムの複雑化によって逆にデータ保有者とデータ利用者の溝が深まってしまったとも言える．

データ 2.0 がもたらした恩恵は計り知れないものの，上述のように，データのみを結合する技術及び議論は限界を迎えつつある．そこで，本稿ではデータ利活用における新たなステージとして，「データ 3.0」を提案する．データ 3.0 の社会では，データだけでなく，データと人間の知識が結びつき，問題の発見と解決が行われることが期待される．データ 3.0 時代におけるデータは，従来のデータ 1.0 及びデータ 2.0 におけるデータとは，性質が異なる．データ 1.0 ではデータは未知の現象を理解するためのものであった．そしてデータ 2.0 では，データ同士を繋げることで新しい価値や知識が生み出されてきた．続くデータ 3.0 のデータは，人間の知識と結合することで人と人を繋ぐ役割を果たすものである[1]．すなわち，データ 3.0 によってデータを介して人と人が出会い，既存の領域では扱えない問題を発見し，知識の連携によって異業種共創が行われる社会となると考えられる．

筆者らは，現在の社会はデータ 2.0 からデータ 3.0 への過渡期に位置すると考えている．日本では，2014 年にデータ駆動型イノベーション創出戦略協議会が創設され，民間ではデータエクスチェンジ・コンソーシアム等が設立された．これらの取り組みの目的は単純にデータを結合することではなく，異分野データ連携による人の邂逅である．つまり，データにはプライバシーの問題，データの用途の不透明性，ビジネス機会の損失などの問題が内在しているため，通常は秘匿にされることが多いが，これらの取り組みはデータを介して人と人が出会い，共創する環境の創造が目的であるという点で，データ 2.0 におけるデータとは性質が異なることが分かる．さらに 2016 年には経済産業省と民間企業が協業し，異なるデータ事業者が連携できるデータ流通市場の事業化に着手している．Web をプラットフォームとするデータの市場の誕生もデータ 3.0 に向かう一つの社会的な動きであると見ることができる．すでに，Microsoft Azure，Qlik，KDnuggets，Factual，Infochimps といった，データを売買・交換するサービスが登場してきている．また，データ提供者とデータ利用者のコミュニケーションによるデータの価値化を促す仕組みとして，個人のオンラインショップの購買履歴や健康情報などを一括管理する「情報銀行（Information Bank）」という仕組みも実現しようとしている [秋山 13, 砂原 14]．情報銀行とは，パーソナルデータを取り扱うハブとなる組織であり，そこに各個人が情報を預け，集積された情報を活用し，情報を預託した個人に何らかのメリットを返す仕組みを提供する．「銀行」というメタファーを用いているのは，各利用者が，自分が預託した情報を的確に把握できるようにし，それらの情報の利用方法の把握することを可能とするためである．さらに上述のコンソーシアムや協議会の興隆に加え，日本データ取引所[2]がデータの取引を仲介する市場を開拓し，EverySense 社[3]がセンシングデータの流通マーケットプレイスなど展開し，データ流通推進協議会[4]がデータの運用方法の策定及びプラットフォーム整備を進めているように，異なる分野のデータを取引きするための場を創生することにより，データの流通を促進させる仕組みがデータ市場の一形態として社会実装されてきている．以上に概観したように，異なる領域のデータを組み合わせることで新しい価値を発見し，分野を横断して知識と結合させて問題発見と解決をするデータ 3.0 が萌芽し始めている．

しかし，データ 2.0 からデータ 3.0 に完全に移行できたわけではない．データを交換し，取引きするデータ市場が展開されているが，それらには様々な問題が存在する．Web をプラットフォームとする現在のデータ市場は，データの表層的な情報を Web 上に陳列するだけに留まっており，ステークホルダー間のコミュニケーションによるデータの価値化と，イノベーションの場としての市場の機能が有効に働く環境としてはまだ十分ではない．なぜなら，データの表層的な情報を列挙しただけでは，データ提供者とデータ利用者の間での利用方法の提案，評価というコミュニケーションの活性化による知識の交換に至るのは難しいからである．また，利用者とのコミュニケーションが欠如していれば，データ保有者も自身が保有するデータの価値を理解する機会を得ることができない．データの価値は利用文脈に大きく依存すること[Hayashi 17b]を考慮すると，データの適切な価値付けが行われないだけでなく，利用価値が不明確なデータは，市場というプラットフォームに登場することができない．そのため，データを連結し入手可能な状態にするだけでなく，人間の知識と結びつけることで価値あるデータを選び，入手する交渉や熟考を伴う検討の場としてのデータ市場が必要なのである[大澤 17]．すなわち，変数によるデータの結合だけでなく，共通の目的や知識によってデータを繋ぐ必要がある．データ 3.0 時代のデータ利活用と異分野データ連携を促すためには，変数の結合だけでなく，データを結びつける人間の知識やデータの利用文脈をも結合することが重要となる．

[1] データ 3.0 と比較し，データ 1.0 及び 2.0 が劣っているというわけではないことに注意したい．データが変容したのではなく，データを取り巻く社会と人が変化したことがデータ 1.0 からデータ 2.0，そしてデータ 3.0 に推移しつつあることの本質である．

[2] http://j-dex.co.jp/

[3] https://every-sense.com/

[4] https://data-trading.org/

3. データランドスケープ

データは主として変数と値によって構成されている．データ 2.0 において，データの連結はデータの変数を揃えることによって達成される．つまり，共通する変数を有しているデータ同士は結合可能性が高いと言える．しかし，データ 3.0 においては，データと人間の知識の融合によって異分野の共創が実現することはすでに述べた．本章では，それらの違いをデータランドスケープとして俯瞰的に分析する．

図 1 は 1098 件のデータジャケット（Data Jacket: DJ）[Ohsawa 13, Hayashi 17a]を用いて異なる領域のデータを「変数」と「文脈」によって連結したネットワーク（データランドスケープ）である．異分野データ連携によるデータ駆動型イノベーションを実現するためには，世の中に存在するデータの構造とそれらの関係を正しく理解する必要がある．つまり，個々のデータを分析するのではなく，データによって構成されるデータの母集団がどのような構造的特徴を有しているのかを調べることが重要である．データランドスケープは，データが作り出す世界の傾向や特徴を定量的に評価するためにデータの関係を俯瞰し，知識を体系付けるための可視化である．

データジャケット（Data Jacket: DJ）は，データ自体を秘匿としたままデータの概要情報を記述するためのフレームワークである．データの概要情報とは，データに関する説明文，含まれる変数の名前，保存形式，共有条件などを意味する．つまり，DJ はデータのデータ，すなわちメタデータの一形態である．しかし，通常のメタデータは機械可読性を高めるための記述方法であるが，DJ は人間がデータについて理解し，議論可能とすることを目的としている．この手法により，データの中身は公開できなくとも，どこにどのようなデータが存在し，どのような情報を有しているのかおよそ把握可能となる（図 2）．また，異なるフォーマット，異なる粒度の変数ラベルを有するデータを共通の記述ルールによって構造的にメタデータ化することで，様々な形式のデータを統一的に扱うことができる．変数ラベルとは，データ固有の変数を自然言語によって記述された説明文を意味する．

データランドスケープでは，各ノードは DJ を表し，DJ 同士が共通する変数ラベルを保有している場合は青色のリンク，共通する文脈を持っている場合は赤色のリンクが張られるものとする．例えば，「東京都の病院の位置情報」と「東京都に設置されている警察署の設置情報」という DJ が「緯度」と「経度」という変数ラベルを共通して有していた場合，2 つの DJ には青色のリンクが張られることになる．また，同データが「東京都における位置データ」という文脈を共有している場合，2 つの DJ は赤色のリンクで結ばれる．なお，文脈は DJ に含まれるデータの概要説明（データ概要）の説明文から単語を抽出して用いた．

図 1 は DJ を用いてデータランドスケープの可視化を行ったものである．図 1 の上図は変数の繋がりから表現されたデータランドスケープと文脈の繋がりから表現されたデータランドスケープの合成ネットワークである．表 1 に DJ を用いたデータランドスケープのネットワークの特徴量を比較した．「変数」は変数によるネットワークを表し，「文脈」は文脈によるネットワーク，そして「変数+文脈」は変数及び文脈によるネットワークを表す．表にあるように，文脈によるネットワークの平均次数は 33.46 と高く，リンク密度 0.030 とやや高い．一方，変数のみの繋がりによるネットワークでは，平均次数は 20.57，リンク密度は 0.019 であった．つまり，文脈によるネットワークの方が密なネットワークを作りやすい性質を持っていることが分かる．一方，変数によるネットワークは同類選択性が 0.586 と高く，コンポーネント数が 374 個と多いことから，同じようなデータは互いに密なネットワークを構成するものの他のデータとは繋がりは疎となる．一方，文脈によるネットワー

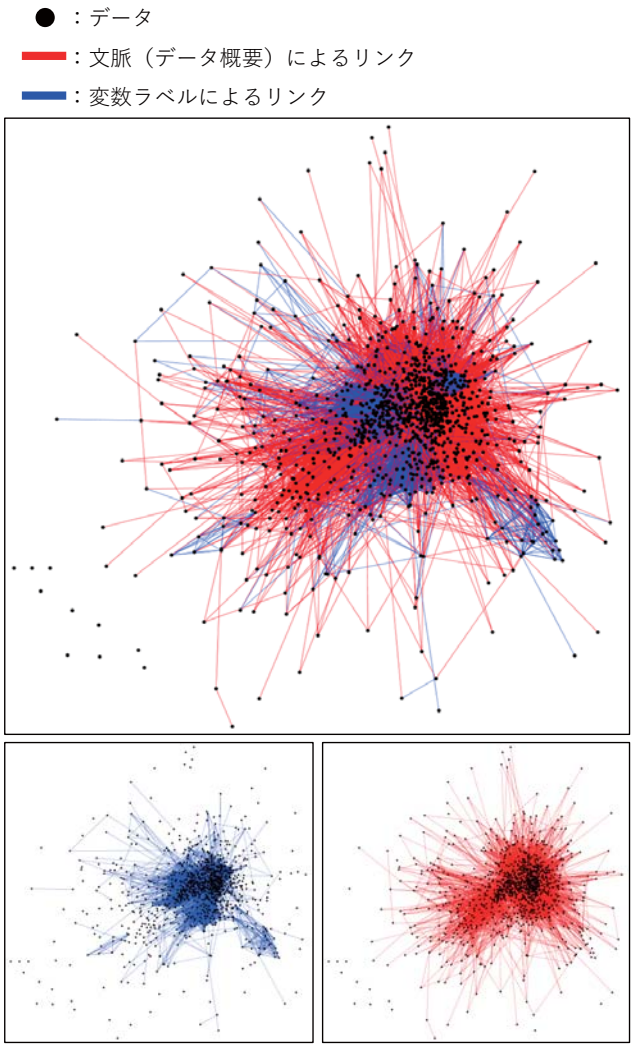


図 1　DJ を用いたデータランドスケープ（上図：変数と文脈による合成ネットワーク．下図左：変数によるネットワーク．下図右：文脈によるネットワーク）

DJ No. XX【購買履歴データ】	
概要	東京都の◯◯スーパーマーケットで収集されている顧客の購買行動履歴。
収集方法・コスト	ポイントカードとPOSによって取得
共有条件	共有不可
データの種類	表形式、テキスト、数値
保存形式	CSV
分析・シミュレーション	時系列分析
変数ラベル	氏名、性別、顧客ID、支払金額、購入品目、日にち
分析結果	• その日の売上の計算 • 今後の売上の予測と仕入れの推定
期待される分析	顧客の購買行動とリピート率を計算し、ロイヤルカスタマーの特定が可能かもしれない。
コメント	有効なデータの組み合わせが発見されればデータの提供あるいはコラボレーションもあり得る。

図 2　DJ の記入例（[早矢仕 18a]より引用）

クは同類選択性が 0.185 と比較的低く，さらにコンポーネント数は 26 個であった．つまり，文脈によるネットワークは局所的に塊を作るのではなく，大局的に密なネットワークを構成することが分かる．さらに，リンク数を見てみると，変数と文脈の合成ネットワークは 28902 であり，変数のネットワークは 11292，そして文脈のネットワークは 18367 である．変数によるリンクと文脈によるリンクの両方で繋がっているデータはごくわずかであり，リンク数は 757 と極めて少ないことが分かる．つまり，変数と文脈の両方が共通しているデータは非常に少ない．そして，この結果によって，変数を介したネットワークだけでは繋がりえないが，共通の利用文脈を補完することによってデータが結合可能となることも示唆される．すなわち，変数によるネットワークがデータ 2.0 のデータランドスケープ（図 1 の青色リンクのみの繋がり）を表し，人間の知識によってデータの共通の利用文脈が発見され融合するデータ 3.0 のデータランドスケープ（図 1 の赤色と青色リンクによって構成されるネットワーク）とすると，データ 3.0 では異分野のデータが密に融合していると言うことができる．

表 1　データランドスケープのネットワークの特徴量

特徴	変数	文脈	変数 +文脈
ノード数	1098	1098	1098
リンク数	11292	18367	28902
平均次数	20.57	33.46	52.64
リンク密度	0.019	0.030	0.048
クラスタ係数	0.465	0.531	0.509
同類選択性	0.586	0.185	0.146
コンポーネント数	374	26	11

4. おわりに

異なる分野のデータと知識を結合することで問題を発見し，問題解決を行うことへの期待が高まっているものの，その実現には多くの障壁が存在する．本稿では，データ 3.0 時代におけるデータの在り方についてデータランドスケープを用いて所見を述べた．“Data is the new oil（データは新しい石油である）”と言われて久しい．確かにデータは石油と同様に意思決定において重要な材であり，ビジネスにおいては経済財であるかもしれないが，石油はそれ自体ただの物質であり，データは記号の羅列に過ぎない．石油は適切な加工を施すことによって価値が生まれる．そして，データは適切な利用文脈が与えられ，分析などに利用されることで，情報となり，人間の意思決定に役立つ知識となる．つまり，データの利用価値を策定するプロセスとは，データに文脈を与える行為に相当する．異なる分野のデータに文脈を与えるプロセスの実現と異業種共創のプラットフォーム[岩佐 18, 佐々木 18, 早矢仕 18b]が生まれてきていることから，データ 3.0 は徐々に社会に浸透しつつあると考えられる．現在はデータ 2.0 からデータ 3.0 への過渡期である．これからのデータ駆動型社会の実現には，データ・AI 技術・人間の相互作用による異分野のデータと知識の連携によるイノベーションの場であるデータ市場の整備が重要と言える．

参考文献

[秋山 13] 秋山寛子, 山内正人, 柴崎亮介, 砂原秀樹: 情報銀行システムにおける個人情報蓄積機構の機能設計と実装，マルチメディア，分散協調とモバイルシンポジウム 2013 論文集, pp.1953-1957 (2013)

[岩佐 18] 岩佐太路，早矢仕晃章，大澤幸生: Web 版 Innovators Marketplace on Data Jackets を用いたデータ利活用法に関するコミュニケーション支援，信学技報，人工知能と知識処理研究会, Vol.117, No.440, pp.55-60 (2018)

[Ellram 16] Ellram, M.L., and Tate, L.W.: The Use of Secondary Data in Purchasing and Supply Management (P/SM) Research, Journal of Purchasing and Supply Management, Vol.22, No.4, pp.250-254 (2016)

[Ohsawa 13] Ohsawa, Y., Kido, H., Hayashi, T., and Liu, C.: Data Jackets for Synthesizing Values in the Market of Data, 17th International Conference in Knowledge Based and Intelligent Information and Engineering Systems, Procedia Computer Science, Vol.22, pp.709-716 (2013)

[大澤 17] 大澤幸生, 早矢仕晃章, 秋元正博, 久代紀之, 中村潤: データ市場, 近代科学社（2017）

[狩野 18] 狩野英司, 大西浩史: 官民データ活用による行政課題解決サイクルの仕組み化に向けて~「官民データ活用シナリオ創 発プラットフォーム事業」の取組み~, 信学技報，人工知能と 知識処理研究会，Vol.117, No.440, pp.67-72 (2018)

[佐々木 18] 佐々木泰芳, 池田栄次:「ブロックチェーン×データジャケット」によるデータ流通・利活用社会への加速，信学技報， 人工知能と知識処理研究会，Vol.117, No.440, pp.43-47 (2018)

[Berners-Lee 06] Berners-Lee, T.: Linked Data – Design Issues, 2006. https://www.w3.org/DesignIssues/LinkedData.html, [最終アクセス 2018 年 3 月 9 日]

[早矢仕 18a] 早矢仕晃章, 大澤幸生: データ市場におけるデータのネットワークと関係性の分析―データの属性と繋がりからの考察―, 信学技報，人工知能と知識処理研究会, Vol.117, No.440, pp.49-54 (2018)

[早矢仕 18b] 早矢仕晃章，大澤幸生：データジャケットを用いた異分野データ連携，人工知能学会誌，AI とデータ-データに基づく意思決定と社会イノベーション創出-特集，Vol.33, No.2, pp.140-148 (2018)

[Hayashi 17a] Hayashi, T., and Ohsawa, Y.: Matrix-based Method for Inferring Variable Labels Using Outlines of Data in Data Jackets, The Pacific-Asia Conference on Knowledge Discovery and Data Mining（2017）

[Hayashi 17b] Hayashi, T., and Ohsawa, Y.: Preliminary Case Study on Value Determination of Datasets and Cross-disciplinary Data Collaboration Using Data Jackets, 21st International Conference on Knowledge Based and Intelligent Information and Engineering System, Vol.112, pp.2175–2184 (2017)

[砂原 14] 砂原秀樹, 山内正人, 金杉洋, 柴崎亮介:「情報銀行」構想とその技術的課題，マルチメディア，分散協調とモバイルシンポジウム 2014 論文集, pp.1024-1026 (2014)

Oral presentation | Organized Session | [Organized Session] OS-8

[1C3-OS-8b] [Organized Session] OS-8

Tue. Jun 5, 2018 5:20 PM - 6:20 PM Room C (4F Orchid)

[1C3-OS-8b-01] An Approach of Defining, Generating and Utilizing Metadata for Sensing Data Trading Market

○Toshihiko Oda[1], Hiroshi Imai[1], Takeshi Naito[1], Hajime Takebayashi[1] （1. OMRON Corporation）

5:20 PM - 5:40 PM

[1C3-OS-8b-02] Detecting Team Behaviors of Pedestrians in Redevelopment Areas on Acceleration Similarity

○Yukio Ohsawa[1], Sae Kondo[1], Teruaki Hayashi[1], Atsushi Sugawa[2], Takahisa Yoshida[3] （1. The University of Tokyo, 2. Crosshack, Inc., 3. Arnest one Corp.）

5:40 PM - 6:00 PM

[1C3-OS-8b-03] Blockchain x Data Jackets accelerates data exchange and utilization

○Eiji Ikeda[1], Hiromichi Sasaki[1] （1. FUJITSU LIMITED）

6:00 PM - 6:20 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

センシングデータ流通市場におけるメタデータの定義・生成・活用の一方式

An Approach of Defining, Generating and Utilizing Metadata for Sensing Data Trading Market

小田利彦[*1] 今井紘[*1] 内藤丈嗣[*1] 竹林一[*1]
Toshihiko Oda Hiroshi Imai Takeshi Naito Hajime Takebayashi

[*1] オムロン(株) 技術・知財本部 SDTM 推進室
OMRON Corporation, Center for Sensing Data Trading Market, Technology and Intellectual Property H.Q.

Demand for sensing data trading market (SDTM) is increasing as becoming more important of application developers who use sensing data gathered from various IoT devices. For them, metadata of sensing data is crucial information to analyze it especially with AI technology. This paper discusses metadata definition, generation and utilizing technology with implementation on prototype.

1. はじめに

さまざまな場所に存在する IoT デバイスがネットワークに接続され、そこで生成されたセンシングデータを中心とするデータがクラウド上にビッグデータとして収集・蓄積されつつある。こうしたセンシングデータの多様な組み合わせによって、画期的なサービスが数多く生まれる期待がある。そのためには、センシングデータを使ったサービスを開発・提供するデータ利用者が、安全かつ容易にデータを入手できる流通市場の重要性が高まっている(図 1 参照)。

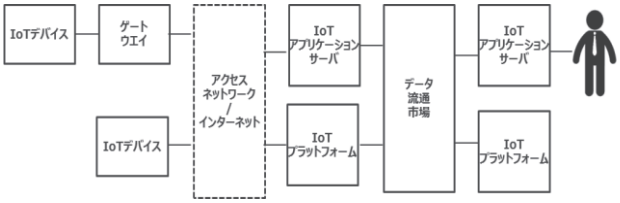


図 1 IoT システムとデータ流通市場

著者等は、センシングデータデータ流通市場(SDTM: Sensing Data Trading Market)の確立を推進しているが、SDTM を介してデータ利用者がセンシングデータを検索・マッチング・活用するためには、センシングデータだけでなくそのメタデータも流通させることが重要であると考える。本論文では、データ流通市場の展開を背景にして、メタデータの形式表現の定義、メタデータの生成・配信、メタデータを活用する方式について、課題とその対策、そしてプロトタイプによる評価を述べる。

2. センシングデータのメタデータ

メタデータとは、「データに関するデータ」のことである。センシングデータを分析し処理するために有用とされるメタデータの種類を以下に示す。

- センサの識別情報:
  製品名、モデル型式、ロット番号、FW バージョン等
- センサの性能仕様に関する情報:
  計測精度、分解能、計測限界範囲、時刻精度 等
- センサから出力されるデータ仕様:
  データ単位系、小数表現、区切り文字 等
- センサの設置条件に関する情報:
  センサの設置位置、高さ、治具、設置者、補正有無 等
- 観測対象情報に関する情報:
  センサが観測する対象についての属性情報で、
  血圧計の例では、測定者の年齢、性別、病歴、運動量等

連絡先:小田利彦、オムロン株式会社 技術・知財本部 SDTM 推進室、〒619-0283 京都府木津川市木津川台 9 丁目 1 番、toshihiko_oda@oss-g.omron.co.jp

3. メタデータの定義

センシングデータのメタデータは、SDTM を介してリアルタイムに配信される場合がある。そのため人が読むのではなく、コンピュータで処理できる形式とする必要がある。さらに、データ利用者が複数のデータ提供者からデータを入手しても統一的にデータ解釈するためには、入手先が異なっても共通の構文や語彙を用いて記述されていることが課題となる。

そこでセンシングデータのメタデータを記述する構文や語彙として、国際的な技術標準化団体である Open Geospatial Consortium の技術規格(以降 OGC 規格と呼ぶ)に基づくこととした。この OGC 規格には、センサによる計測に関する情報や機器の仕様に関するデータモデル及び XML 実装が公開されている[OGC 2011,2012,2014]。

また、2 章で示したメタデータの種類を、OGC 規格のデータモデルで表現したが、そこに含まれない観測対象に関する情報やセンサの設置条件情報などは、OGC 規格で定義された Physical Component クラスをサブクラス化して追加することにした (図 2 参照)。

メタデータの語彙は、できる限り公開された共通語彙を参照することが望ましく、単位系の公開共通語彙や、DBpedia に登録されている語彙を用いた。一方、特殊な語彙として、センサ製品に固有の出力データ項目や性能項目などの語彙に対して、その意味、表記名、ユニークコードとなる URL を語彙辞書に登録した。この語彙辞書を公開することで、データ利用者はセンシングデータのメタデータにアクセスできる。

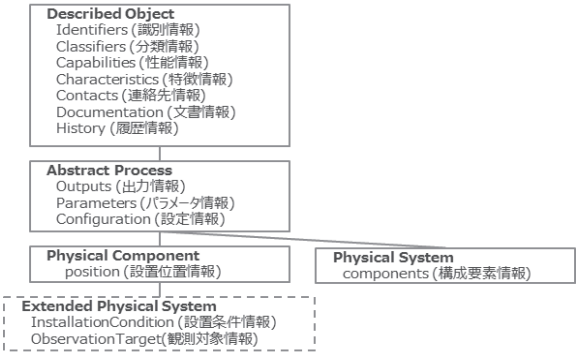


図 2 OGC 規格に基づくメタデータのデータモデル

他方、センシングデータのメタデータの表現として、概念の意味ネットワークを構成する RDF を用いた研究が多くある[Qanbari2015]。今回は、実用性を考えることで、クラウド上でスケールできる RDF リポジトリサービスが無かったことや、SPARQL でアクセスする技術普及が乏しいことから、メタデータ表現は XML 形式を評価することとした。

4. メタデータの生成・配信

2 章で示したメタデータは、センサの製品情報のような変化しない静的メタデータと、設置環境やデバイスの状態等の時系列変化する動的メタデータとに分けられる。

静的メタデータは、センサメーカーやデータ提供者が作成してダウンロードサイトに登録しておくことで、利用者がアクセスして入手できる。一方、動的メタデータは、センサやゲートウエイ(GW)、IoT サーバ等において生成され、データ利用者に送信される(図 3 参照)。

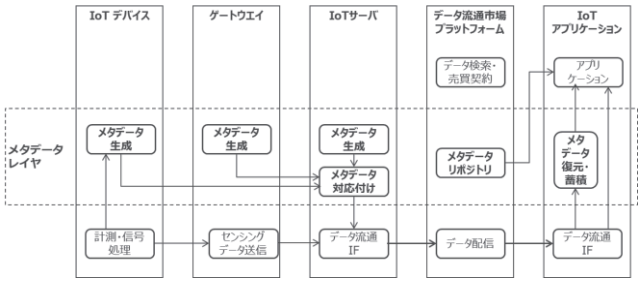


図 3 メタデータの生成・配信の流れ

しかし、計算リソースが少ないセンサや GW から、OGC 規格の冗長性がある XML 形式のメタデータを生成配信することには、リソース上の課題がある。

そこで、メタデータを XML データではなく圧縮した形式で生成・配信を行い、データ利用者に渡す直前で復元する方式とした。

また、データ提供者が定義したメタデータを、自身がプログラムを作成しなくともメタデータ生成が実行できる仕組みが課題となる。

そこで、データ提供者がメタデータをエクセル上で記述することで、その情報に基づきメタデータ生成モジュールの入力となる変換定義やテンプレートが自動生成される。これによりノンプログラミングで、メタデータ生成がカスタマイズされて実行できる。

5. メタデータの活用

センシングデータを利用したアプリケーションサービスの開発では、センシングデータの AI 分析や統計解析が行われる。その際、データ分析者は、第 3 者から入手したデータをデータクレンジングする前処理作業に労力がかかっており、その軽減が課題となる。

そこで、メタデータの活用の 1 つとして、この前処理の作業を支援するツールによって自動化することが有効と考え、次の 3 種の前処理を取り上げて、ツール化を行う。

①データ検証: データの異常値や抜け・重複を、除去や補間
②データ変換: データの単位系、日時表現、カテゴリの統一化
③データ結合: 異なる入手先から得たデータ同士を結合

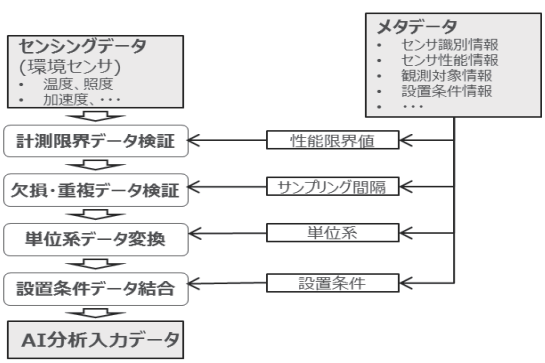


図 4 メタデータ活用の前処理の例

6. 実験評価

評価実験として、複数の住居内に環境センサを設置して、計測されたセンシングデータを収集する IoT システムを構築した。このシステム上に、メタデータの生成・配信・活用までのプロトタイプを実装して評価を行った。

メタデータの定義では、本実験において洗い出されたメタデータを、OGC 規格を拡張した構文と語彙辞書に基づき、全てを記述できた。

メタデータ対象	メタデータ項目	内容	タイプ
IoTサーバ	識別情報	正式名称	静的
	識別情報	正式名称、略称、製造者、モデル型式等	静的
ゲートウエイ	識別情報	機器識別番号	動的
	位置情報	経度、緯度	
環境センサ	識別情報	正式名称、略称、製造者、モデル番号等	静的
	分類情報	センサータイプ、利用用途	
	連絡先情報	組織名称、連絡先等	
	文書情報	マニュアル、製品仕様書	
	性能情報	精度、分解能、計測限界、計測間隔等	
	出力情報	出力値の名前、単位、定義小数桁数等	
	パラメータ情報	イベント閾値、パラメータ名等	動的
	識別情報	機器識別番号、FWバージョン	
	パラメータ設定情報	最大閾値、最小閾値、平均最大閾値 等	
	設置条件情報	住居タイプ、世帯人数、設置場所 等	
	観測対象情報	性別、年齢、使用機器種類 等	
	データ欠損情報	開始番号,終了番号等	
	センサ時刻設定情報	センサ時刻設定日時情報	
	センサ状態情報	温度センサ異常、CPU異常 等	

図 5 IoT 実験におけるメタデーター覧

メタデータ生成・配信では、センサ自体でメタデータ生成は困難であったため GW で肩代わりする対応を行い、さらにメタデータの XML 記述を断片化して送信することで通信量を許容レベルまで縮小できた。

メタデータの活用では、IoT システムで収集した環境センサのデータから人の行動判別する AI 学習の前処理において、メタデータと連携してデータ検証、データ変換、データ結合を行う処理を作成し、Jupyter notebook 上で評価した。

評価結果として、データ分析者は、前処理する際に、メタデータを使うことは必須ではあるが、入手できれば簡単なスクリプトを作成して対応できる。従ってデータ分析者には、メタデータを取得する IF を整備するニーズの方が高いといえる。しかし、IT スキルが不足する分析者には、逆に、前処理をノンプログラミングで行えるレベルまでツール化することが必要となると判った。

7. 今後の課題

データ流通において、メタデータも重要な流通対象と考えて定義や生成・配信、活用の課題と解決策を示した。

メタデータの定義に関しては、民間主導の協議会等においてメタデータ記述方式の標準化を議論していく予定である。

また、複数のセンシング分野に適用範囲を広げ、メタデータ活用の改善効果を高めるトライアルしていきたい。

参考文献

[OGC2014] SensorML: Model and XML Encoding Standard https://portal.opengeospatial.org/files/?artifact_id=55939

[OGC2012]Sensor Observation Service Interface Standard: http://portal.opengeospatial.org/files/?artifact_id=38476

[Qanbari2015]S. Qanbari et.al: Linked Sensed Data Enrichment and Analytics Middleware for IoT Gateways, FiCloud 2015 、August 2015

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

再開発エリアにおける歩行者の加速度類似性に基づくチーム行動検出

Detecting Team Behaviors of Pedestrians in Redevelopment Areas on Acceleration Similarity

大澤 幸生[*1]
Yukio Ohsawa

近藤 早映[*1]
Sae Kondo

早矢仕 晃章[*1]
Teruaki Hayashi

[*1] 東京大学工学系研究科
School of Engineering, The University of Tokyo

須川 敦史[*2]
Atsushi Sugawa

吉田 隆久[*3]
Takahisa Yoshida

[*2] クロスハック株式会社
Crosshack, Inc.

[*3] 株式会社アーネストワン
Arnest one Corp.

Abstract: Team behaviors are regarded here as an essential component of cultures and lifestyles of people engaged in businesses, sports, etc. In order to detect team behaviors, pedestrians' similarity of the acceleration time-series is proposed as the temporal evaluation index. Here, a redevelopment area is taken as the space for experiments with acceleration sensors, and the correspondence of acceleration similarity and the pedestrians' mutual feeling of co-walking is evaluated.

1. はじめに

新開発あるいは再開発エリアにおいては，人々の新しい行動パターンが発生しうる．しかし，その行動を事前にデータ化して予測することができないため，どのような店舗やサービスをそのエリアで展開するのが良いかを事前分析によって検討することは難しい．本研究では，ある地域で歩行する人々におけるチーム行動の分析を行うことによって，およそどのような目的の人々が行動しているかを捉える基礎的な方法を開発したい．同様の考え方は，スポーツにおけるチーム行動の分析にも転用できると考えられる．例えば，サッカーにおいてはおよそ横一線に並ぶプレイヤーがサブチームをなし，守備および攻撃を効率化している．これらのチームあるいはサブチームを，どのように抽出することができるだろうか．本論文では DJ ストアの出力を元にこの問いに答える準備として基礎仮説を設け，検証を試みる．

2. サブチーム行動に関する評価実験

DJ ストア[早矢仕, 大澤 2017]から，"ナビタイムの地図・交通データ"（時間，信号，混雑など）と"GPS による位置情報"（時間，緯度，経度）のデータの結合利用案として，"人がどんな移動で何をしているかわかるサービス"というソリューションが見いだされた．また，加速度，心拍数を持つ"ウェアラブル機器のログ情報"から，"同じ歩行スピードの人との差を見る（個人差）"というソリューションが見いだされた．これらを契機として，以下の仮説を設定しで検証することを初期目的とした．すなわち，各時点で

仮説① タスクを共有する人の位置は接近する
仮説② 空間での移動経験を共有する人の速度は接近する
仮説③ 興味を共有する人の加速度は接近する

例えば，複数人の同行者があるエリアを歩いている（タスクの共有：例えば実験に向かう研究室のメンバーら）とき，もし彼らが同じくらいそのエリアを歩きなれているならば（スキルの共有：例えば上記のメンバーのうち数年在学している大学院生たち），同じくらいスムーズに歩くので同じ地点を歩く時の速度は近いであろう．また，彼らが新しい建造物に興味を持っているなら（興味の共有：例えば，近い問題を研究している研究室メンバー），同じ建造物に接近したところで歩行速度を緩めるであろう．

しかしながら，ここで疑問を呈したい．このような歩行速度の変化は，坂道や信号機，あるいは人だかりに遭遇することによる速度減衰に比較して十分に大きいであろうか？実際，建物やオブジェに興味を持った人が歩調を緩めるのは1秒前後である．一方，信号機では[管技協 2002]にあるように交通量による数十秒の長さの歩行停止を余儀なくされ，坂道では数 10%というオーダーで速度が増減する．よって本論文では，短時間で発生する正負の加速度に注目し，仮説③に基づいて興味を共有する人々（正しくは similar interest group であるが SIG と略すと special interest group と混同するため，ここではチームと呼ぶ）を検出するための基礎的な手法を検討する．この仮説③は，歩きなれた人にとっても新しい事物が提示される環境でなければ任意の被験者に対して検証しづらい．そこで対象地域を図1の再開発地域とし，以下のそれぞれの被験者チームで会話を行いつつ加速度センサを携行して約7キロを歩いた（図1）．それぞれの人物のルートにおける以下の情報を同時に収集するため，前半と後半のそれぞれについてエブリセンス社の SmartRider 0.2.117-2（30Hz）を用い，同時にスタートボタンを押下してデータを収集した．なお後述の通り，今回は4名という少人数の被験者による予備実験と位置付けている．

前半（1時間）：A,B からなるチーム a と,C,D からなるチーム b は互いの距離を約 5m 以内に保って歩いたため，速度に大きな差はない．途中で急に足を遅くするなどがあっても，すぐに4人の行動に追随した．

（チーム a） 都市再開発に関する共同研究者２名（A,B）

（チーム b） 上記共同研究に属さない知人２名（C,D）

後半（１時間）：A,B からなるチーム a と D が合流して同じチームとし，C は不参加とした．

（チーム c） 上記の A, B, D からなる３名．

連絡先：大澤幸生，東京大学工学系研究科 大澤研究室（文京区本郷 7-3-1），秘書：info@panda.sys.t.u-tokyo.ac.jp



図1　実験対象とした横浜駅周辺エリアと地点①～⑤の位置

3.　実験の結果

以下の2つの指標の一致する度合いを評価した.

指標 1　加速度類似性：歩行者 P について，各時点 t の前後 0.3 秒に，評価時区間における上位 10 位までの加速度絶対値が存在するかどうかを acc(P, t)として，式(1)により歩行者 P, Q の加速度類似性 sim(P,Q)を求める． t は，30Hz でサンプリングし，ΔT は 10sec とした.

$$\mathrm{sim}(P,Q) = \text{Average}_{T \le t \le T+\Delta T}\ \mathrm{acc}(P,\ t)\ \ \mathrm{acc}(Q,\ t) \qquad (1)$$

指標 2　同行感覚：アンケートにより，
Q1:誰と歩いていたか，　Q2:誰と興味を共有していたか
Q3:誰と目的を共有していたか
を質問した. このうち，すべてに回答できた被験者は1名のみであった. このことからも，加速度類似性という物理量によって間接的に興味の共有度合いを調べる意義はあるといえよう. ここではQ1の回答結果(一緒に歩いていたと思う人)と，指標1の加速度類似性の近い人が一致するのかとうかを検証することより，先述の仮説③を間接的に証することとする.

表1　地点①～⑤の 10 秒間における加速度類似性/アンケート結果(加速度類似性：%, アンケート結果 X_1X_2: $X_1(X_2)$は各行（列）の被験者が各列（行）の被験者が一緒に歩いていたと思う場合に Y, さもなくば N とした). 下線は，加速度類似性の上位2ペア.

		B	C	D
地点①	A	2.65 (YY)	2.40 (YY)	0　(NY)
	B		0　(NY)	0　(NN)
	C			2.52 (YY)
地点②	A	9.46 (YY)	0 (NN)	0 (NN)
	B		0 (NN)	0 (NN)
	C			9.03 (YY)
地点③	A	1.67 (NN)	1.77 (YN)	2.78 (NN)
	B		6.86 (NN)	21.9 (YY)
	C			9.09 (YN)
地点④	A	0(NN)	1.85 (YY)	0(NN)
	B		0(NN)	6.1 (YY)
	C			0(NN)
地点⑤	A	15.0 (YY)	0 (NN)	21.3 (YY)
	B		0(NN)	5.3 (YY)
	C			0 (NN)

表1のとおり，歩行者間の加速度類似性とアンケートによって収集した「一緒に歩いている相手」という意識的な近さはおおむね一致する. 一方，速度の時系列について類似性を求めても，このような一致はみられない. この理由は，速度の変化は先述のように坂道や信号機，周囲の混雑や交通状況などによって影響を受ける度合いが多いためである. 例えば通行人が一瞬ショーウィンドウに立ち寄る際，多くは数秒だけ速度が減衰するが購買するほどの関心を持たず元の歩調に戻るため，前後の平均速度は上り坂の場合ほど大きな減衰を起こさない. しかし，その一瞬で生じる加速度は，速度変化が一瞬で起きる故に十分に大きな値を示す. したがって，興味の対象が発生したことを示す量としては，速度よりも加速度が適切と考えられる. 本実験で評価した加速度類似性は，このような理由で興味の共有度合いを表す適切な指標であると筆者らは考えている.

加速度の時系列については，DTW によってジェスチャーや個人を学習済みテンプレートとの一致から識別するなどの用いられ方をしている[村尾，寺田 2011; 山野井，沼尾 2011]が，DTW に比較すると本論文の加速度類似性は時系列の長さに対し線形(DWT は二乗)の計算時間で済むため取り扱いは簡便である. しかし，本論文の骨子はこの計算時間の差ではなく，加速度時系列の類似性のをチーム分析に適用することである.

都市計画の観点からは，都市空間およびその諸要素が人の移動や消費行動とその効率や期待効用に与える影響に関する離散構造モデルおよび連続数値モデルが開発されてきた[Hillier 2007, 荒木他 2015]. 一方，本論文では，所与の空間における人の運動分析によりチーム行動の構造を求める基礎モデルの一要素に関する基礎研究であり，都市計画におけるモデルと相補的に用いることが期待できる. 例えば，Hillier らのSS理論においては都市空間のグラフ構造において統合機能を有する成分(例えば広場)が，そこに繋がる両地域における集団の行動様式にどのように影響するかについて，本手法と組みわせることによって解析することが期待できる.

謝辞　本研究は，JST CREST JPMJCR1304, JSPS 科研費 JP 16H01836, JP 16K1242. により助成を受けた.

参考文献

[早矢仕,大澤 2016]　早矢仕 晃章，大澤 幸生: Data Jacket Store: データ利活用知識構造化と検索システム,. 人工知能学会論文誌　31 巻 (2016) 5 号 p. A-G15_1-9　(2016)

[管技協 2002]　(公)日本交通管理技術協会　交通整理AB https://www.tmt.or.jp/research/img/signal/s-02.html (2002)

[森本 2004] 森本安夫 : 坂道における歩行の理論的考察と基礎的な実験, 明治鍼灸医学 34(2004) 29-38

[Hillier 2007] Hillier, B. Space is the machine: a configurational theory of architecture. Space Syntax: London. (2007)

[荒木他 2015]荒木 雅弘，溝上 章志，円山 琢也:まちなか回遊行動の詳細分析と政策シミュレーションのための予測モデル，土木学会論文集 D3, Vol.71, No.5, I_323-I_335 (2015)

[村尾，寺田 2011]村尾和哉,寺田努: 加速度センサの定常性判定による動作認識手法，情処論文誌 52(6) 1968-79 (2011)

[山野井，沼尾 2011] 山野井祐介，沼尾雅之: 一般動作の加速度データによるユーザ識別システムの提案，情処学会 73,4W-6, 3-295,296 (2011)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

「ブロックチェーン×データジャケット」で実現するデータ流通・利活用社会 ～ 異業種共創を加速するコンソーシアムの効用～

池田栄次[*1]
Eiji Ikeda

佐々木泰芳[*2]
Hiromichi Sasaki

[*1、*2] 富士通株式会社 〒212-0031 神奈川県川崎市幸区新小倉1−1

1. はじめに

近年のビッグデータ解析や人口知能技術の急速な進展によって、膨大なデータをより精緻かつ高度に分析できるようになってきた。従来から存在する企業情報システム内のデータや、web サービスシステムに蓄積されるデータ（会員情報、検索履歴、購買情報など）、SNS（Social Network Service）の会話情報などに加え、IoT 技術の進展に伴い、現実世界の情報をより詳細にデジタルデータとして蓄積できるようになってきた。

こうした膨大なデータと最新の分析技術を、人々が持つ多様な発想のもとで組み合わせることで、これまでに無かった画期的なサービスや製品が多数生み出され、一層豊かな社会が実現されるとともに、デジタル化時代における日本の国際競争力強化につながることが期待される。

そのために、社会が保有するデータが業種・業界を超えて流通・利活用され、持続的な価値創出が行われる仕組みを社会実装していくことが不可欠である。本稿では、データ流通・利活用社会の実現に向けた富士通のソリューション開発の取り組みを紹介し、特に、価値創出に重要な役割を果たす「コンソーシアム」の効果に関して考察を行う。

2. データ流通・利活用社会実現への課題

これまで筆者らは、技術展示会への出展や様々な業界の企業とのデータ活用に関するディスカッションを通して、データ流通・利活用拡大に向けた課題やニーズを調査・検討してきた。

多くの企業は、自社内に大量に保有しているデータを活用した新たなビジネス創出を指向しているものの、自社だけではデータの活用方法が見出せないなどの課題に直面している。こうした企業は、市場競争優位を築くために異業種の知見を取り込むことに意欲的であり、「異業種共創が生き残りの鍵」との危機意識を持っている。

しかしながら、データを活用した異業種共創には多くの課題が存在する。企業が保有するデータには、企業機密や個人情報などが多く含まれることから不特定多数に対して共有することは事実上不可能と言っても過言ではない。従って、信頼できるパートナーを探し出し、データ共有条件等に関する慎重な協議が欠かせない。データ共有の合意が得られたとしても、企業や組織を超えて、安全にデータを受け渡すのは、情報セキュリティ面、通信ネットワーク環境面なども含め簡単ではない。

こうした、データの取扱いに関する様々な非効率性を解消し、多様な企業・組織・人が安心安全にデータを流通させ、利活用方法を検討できる環境の整備が不可欠である。

連絡先：池田栄次、富士通株式会社、ikeda.eiji@jp.fujitsu.com

3. データ流通・利活用サービス基盤

我々は、安心安全なデータ流通・利活用環境の実現のために、「ブロックチェーン」と「データジャケット（東京大学・大澤研究室により提唱された、データの中身を秘匿したままデータが持つ価値を共有する手法）[1]」をベースとしたサービス基盤に関する技術開発を進めている。

ブロックチェーンをネットワーク制御に応用した「富士通 VPX™ テクノロジー[2]」によって、クローズドな共創空間を創り出し、この空間を「コンソーシアム（詳細後述）」を形成するメンバーが共有する。コンソーシアムメンバーは、自身が保有するデータに関するデータジャケットをブロックチェーンの分散台帳を媒介に他メンバーに共有する。共有されたデータジャケットはサービス基盤機能によって、データジャケット間のつながりが可視化され、思いもよらないデータの組合せや新たな気づきなどを誘発する。サービス基盤にはコミュニケーション機能も統合しており、データのつながりを起点として、コンソーシアムメンバーが知見を交換しながらイノベーションを生み出していく（図 1、2 参照）。[3]

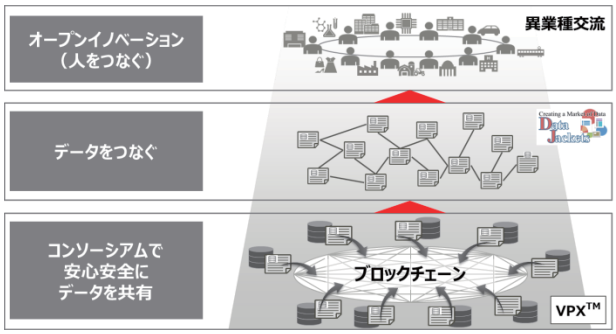


図1 データ流通・利活用のコンセプト



図2 データ流通・利活用ソリューションのサービスイメージ

4. コンソーシアムの有効性に関する考察

4.1 コンソーシアムの概要

前述の VPX が作り出すクローズドな共創空間に参加するメンバーは互いに共通の目的を持ち、組織や業種・業界を超えて信頼でつながる共創コミュニティであり、これをブロックチェーンのアーキテクチャ名になぞらえ「コンソーシアム」と呼ぶ。

コンソーシアムの立ち上げには、データ利活用を積極的に自社ビジネスに取り込もうとする先進的な企業が牽引することが多い。こうした企業は、ビジョンや課題設定を行い、共感する関連企業・組織を引き込むことにより、コンソーシアムを形成する。コンソーシアムの参画メンバーとして、データ提供、データ分析、アイデア創出、ビジネス実行など、データ利活用に必要な役割を担うメンバーが加わることで、単一の企業・組織だけでは困難であった、データ利活用に必要な多様なリソースやスキルセットが備わったコンソーシアムが形成できる。さらに、コンソーシアムの運営円滑化のために、コンソーシアム設立趣旨、参画メンバーリストの他、データの取り扱いや、各種権利関係（コンソーシアム活動で生まれたアイデア等）を明文化した運用規約を策定することも重要である。

コンソーシアムメンバーは、コンソーシアム形成の過程で相互に信頼関係を築き、透明化された運用規約のもと、3 章に記載したサービス基盤の各種機能を効果的に活用しながら、データ流通・利活用による価値創出活動を安心安全に進めることが可能となる（図 3 参照）。

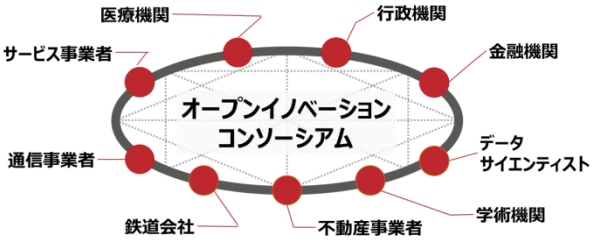


図3 コンソーシアムのイメージ

4.2 コンソーシアムが生み出す効用

コンソーシアムは、共通の目的と信頼でつながった「顔の見える」クローズドな共創コミュニティである。これによって、データ共有や他者とのアイデア創出に関する様々な不安や非効率性（情報管理に関する組織内の承認手続きなど）を低減することができ、不特定多数が参加するオープンな環境では実現困難な、以下のような効果が期待できる。

- 企業が保有する希少で価値のあるデータが共有される
- 新たなサービスやビジネスのアイデアの議論が活性化する
- アイデアの具体化に必要なリソース・スキルセットが備わっているため、データ活用の具体化が迅速に行える。

一方、近年のデータ利活用ニーズの拡大に応えるべく、データや API（Application Programming Interface）を集約したオープンなマーケットプレイスが立ち上がりつつある。こうしたオープンな環境は、既にデータ活用アイデアが具体化している場合には、必要なデータやサービスを容易に発見・入手し、アイデアを迅速に実現できる点において極めて有効である。

しかしながら、多くの場合には、「データを活用して何らかの新たなビジネスを創出したい」という曖昧な状態であることを鑑みると、コンソーシアムという安心安全なクローズド環境の中でデータを起点としたアイデア創出を行い、その上でオープンなマーケットプレイスも適宜活用しながら必要なリソースを補完し、アイデアを実現していくというプロセスが有効であると考える。

4.3 コンソーシアムを超えたデータ流通・利活用の拡大

コンソーシアム活動の経験値が蓄積されることにより、当初は慎重であったデータの取扱いに関する知見も深まるとともに、データの価値を明確に認識できるようになると考えられる。この結果、コンソーシアム内に閉じて流通していたデータが、他のコンソーシアムに共有されたり、パブリックな空間に共有されたりするケースが増加していくことが想定される。このような段階を経て、社会のデータがオープンに流通し合う「データ市場」が形成されていくと考える。

こうしたデータ流通・利活用の拡大を見据えて、我々は、前述の VPX テクノロジーを拡張し、データジャケットを、コンソーシアムを超えて共有可能とする技術開発も進めている。

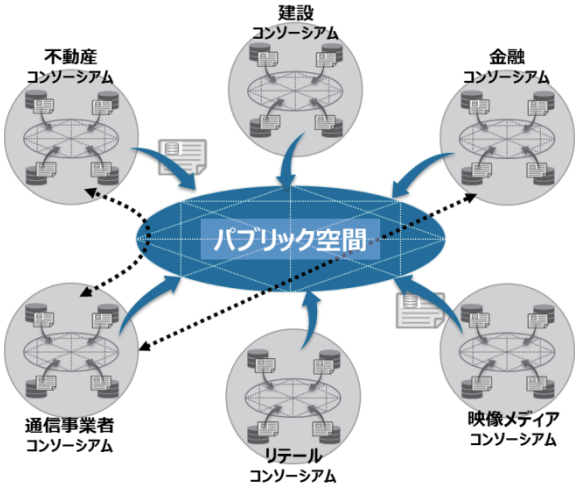


図4 コンソーシアムからパブリックへの拡大

5. まとめ

多様なデータが社会全体で安心安全かつ適正に流通し合い、オープンイノベーション加速の源泉となるデータ流通市場形成が望まれることに異論の余地は無い。しかしながら、その実現に向けては、多くの企業が抱えるデータ活用に関する課題を丁寧に解決しながら段階を踏んでいくことが極めて重要である。コンソーシアムというクローズドな環境特性を活かして、データ活用に対する経験値を蓄積しながら、異なるコンソーシアム間、そして、オープン市場へと順次データ流通・利活用の領域を拡大していくことが重要であり、今後もこうした社会の実現に向けて検討を進めていきたい。

文　献

[1] 大澤 幸生, 早矢仕 晃章, 秋元 正博, 久代 紀之, 中村 潤, 寺本 正彦, “データ市場:データを活かすイノベーションゲーム,” 大澤 幸生（編）,近代科学社, 2017 年 3 月発行.

[2] 富士通株式会社, “プレスリリース：ブロックチェーンの応用による安心・安全なデータ流通ネットワークを実現するソフトウェアを開発”, 2017 年 6 月 5 日

[3] 池田栄次,佐々木泰芳, “「ブロックチェーン×データジャケット」によるデータ流通・利活用社会への加速”, 信学技報, vol. 117, no. 440, AI2017-25, pp. 43-47, 2018 年 2 月.

Oral presentation | General Session | [General Session] 13. AI Application

[1D1] [General Session] 13. AI Application

座長:肥田 剛典（東京大学）

Tue. Jun 5, 2018 1:20 PM - 3:00 PM Room D (4F Cattleya)

[1D1-01] Comparison between Tsunami Height Prediction Methods Using Ocean-Bottom Pressure Values

○Kenjiro Kashiwabara[1], Masashi Yoshikawa[1], Yasuhiko Igarashi[1,2], Toshitaka Baba[3], Takane Hori[4], Masato Okada[1] （1. The University of Tokyo, 2. Japan Science and Technology Agency PRESTO, 3. The University of Tokushima, 4. Japan Agency for Marine-Earth Science and Technology）

1:20 PM - 1:40 PM

[1D1-02] Landslide Detection Using CNN with SAR Images before/after the Disaster and DEM

○Daisuke Ueda[1], Shingo Mabu[1], Takashi Kuremoto[1] （1. Yamaguchi University ）

1:40 PM - 2:00 PM

[1D1-03] Applicability of the deep learning flood forecast model against the flood exceeding the training events

○Masayuki HITOKOTO[1], Masaaki SAKURABA[1] （1. NIPPON KOEI CO., LTD）

2:00 PM - 2:20 PM

[1D1-04] A Route Search System Considering Urgency and Efficient Coverage under the Condition of Uncertain Information

Nakamura Yuta[1], ○Masaki Matsubara[1], Nobutaka Suzuki[1], Munenari Inoguchi[2], Atsuyuki Morishima[1] （1. University of Tsukuba, 2. university of Shizuoka）

2:20 PM - 2:40 PM

[1D1-05] Mobile Network Failure Detection and Forecasting with Multiple User Bahavior

○Motoyuki OKI[1], Koh Takeuchi[2], Yukio Uematsu[1], Naonori Ueda[2] （1. NTT Communications Corporation, 2. NTT Communication Science Laboratories）

2:40 PM - 3:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

海底水圧データを用いた津波高予測手法の比較

Comparison between Tsunami Height Prediction Methods Using Ocean-Bottom Pressure Values

柏原 健之朗 *1 Kenjiro Kashiwabara
吉川 真史 *1 Masashi Yoshikawa
五十嵐 康彦 *1*2 Yasuhiko Igarashi
馬場 俊孝 *3 Toshitaka Baba
堀 高峰 *4 Takane Hori
岡田 真人 *1 Masato Okada

*1東京大学大学院新領域創成科学研究科 Graduate School of Frontier Sciences, The University of Tokyo
*2科学技術振興機構 さきがけ Japan Science and Technology Agency PRESTO
*3徳島大学大学院ソシオテクノサイエンス研究部 Institute of Technology and Science, The University of Tokushima
*4海洋研究開発機構地球津波海域観測研究開発センター Research and Development Center for Earthquake and Tsunami, Japan Agency for Marine-Earth Science and Technology

There are two frameworks to predict the tsunami height from the change of the ocean-bottom pressure. One is the 2-step approach which estimates the earthquake scenario from the ocean-bottom pressure and then forecasts the tsunami height from the estimated earthquake scenario. The other is the direct approach which directly forecast the tsunami height from the ocean-bottom pressure. When constructing the prediction system, it is necessary to select which of these prediction frameworks adopted. We carried out the verification to forecast the tsunami height from the pressure gauge data of Dense Ocean-floor Network for Earthquakes Tsunamis (DONET) with the two prediction frameworks. We found that the direct approach has lower prediction error and higher immediacy than the 2-step approach.

1. はじめに

大規模な地震に伴う津波による被害を抑えるためには津波高即時予測システムが必要である．東北地方太平洋沖に展開されている日本海溝海底地震津波観測網 (S-net) や和歌山県沖合で運用されている地震・津波観測監視システム (DONET) では，沖合の海底に水圧センサーが設置され，水圧データをリアルタイムで取得することができる．また，地震が発生した際，海底水圧センサーで観測される水圧データと沿岸部に到達する津波高が取得できるシミュレーション手法も開発された．

シミュレーションにより構築された水圧センサー値と沿岸津波高のデータベースを利用して，海底水圧変化から沿岸部に到達する津波高を予測する手法が提案されている．その手法は二つの枠組みに分けることができる．一つは，観測した水圧センサー値から地震のシナリオを推定し，そのシナリオに基づいて津波高を予測する二段階のアプローチである．この枠組みでは，Multi-index 法 [Yamamoto et al., 2016] が提案されている．もう一つの枠組みは，水圧センサー値から直接津波高を予測するアプローチである．この枠組みでは，線形回帰による予測 [Baba et al., 2014] やガウス過程回帰による予測 [Igarashi et al., 2016]，非線形パラメトリックモデル [Yoshikawa et al., 2017] が提案されている．実際に予測システムを構築する際，これらの予測の枠組みのうち, どちらを採用すべきか選定する必要がある．

本研究では，二段階予測のアプローチと直接予測のアプローチを予測誤差の観点で比較する．南海トラフ地震を想定し，Multi-index 法とガウス過程回帰，非線形パラメトリックモデルを用いて，DONET の水圧センサー値から三重県尾鷲市に到達する津波高の予測性能を検証する．

連絡先: 岡田真人， 東京大学大学院新領域創成科学研究科, okada@k.u-tokyo.ac.jp

2. データセット

本研究では，スーパーコンピュータによる津波シミュレーションから取得されたデータを用いる．津波シミュレーションは津波計算コード JAGURS[Baba et al., 2016] を用いて，断層の位置やマグニチュードなど 10 個のパラメータを持つ地震シナリオ $\boldsymbol{\theta}$ をさまざな値に設定して 1506 通りのシミュレーションを行う．図 1 のように，津波シミュレーションにより DONET の i 番目 ($i = 1, 2, ..., 20$) の水圧センサーで観測された水圧値と尾鷲検潮所に到達する津波高が 1 秒ごと 180 分間の時系列データとして記録される．

全時間予測の検証では，180 分間の水圧データが全て手元にあると仮定し，説明変数は水圧センサー値 $p_i(t)$ の最大絶対値 $s_i = \max_t |p_i(t)|$ とする．また，リアルタイム予測の検証では，時刻 $\tau \leq 180$ 分までの水圧センサー値が観測された状況を想定し，$p_i(t)$ の時刻 τ までの最大絶対値 $s_{i,\tau} = \max_{t \leq \tau} |p_i(t)|$ を説明変数とする．目的変数はいずれの検証も尾鷲検潮所での津波高時系列データの最大値 d として検証を行う．

3. 手法

3.1 Multi-index 法

Multi-index 法 [Yamamoto et al., 2016] は，観測された水圧センサー値 $\mathbf{s}(n)$ から地震シナリオを推定し，推定された地震シナリオ $\hat{\boldsymbol{\theta}}$ から津波高 d を予測する手法である．データベースから観測値 $\mathbf{s}(n)$ に最も近い水圧センサー値 $\mathbf{s}(m)$ を検索し，それに対応する地震シナリオ $\boldsymbol{\theta}(m)$ を推定値とする．このとき，データベースから一つの距離尺度で観測値に最も近い $\mathbf{s}(m)$ を検索するのではなく，(1) 式で示される相関係数，(2) 式，(3)

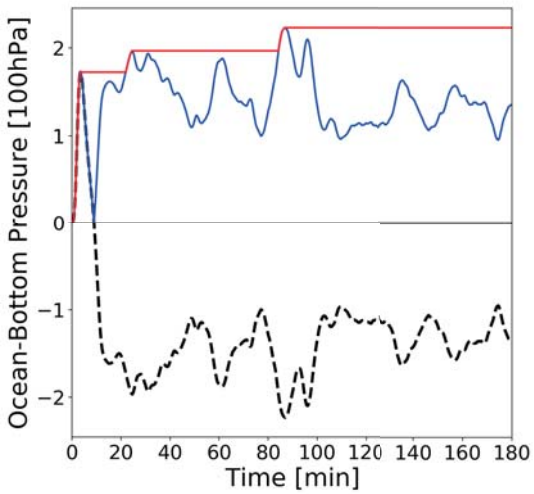


図 1: 水圧センサー値．黒色の破線は水圧センサーで観測された値．青色の実線は絶対値．赤色の実線は時刻 τ までの最大絶対値．予測誤差の検証では青線の最大値，即時性の検証ではある時刻における赤線の値を用いる．

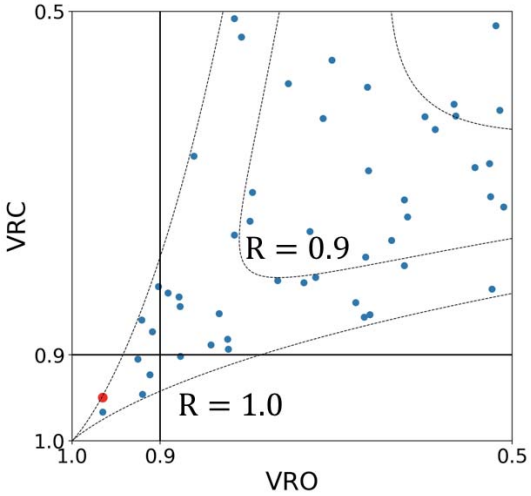


図 2: R と VRO，VRC の関係．横軸が VRO，縦軸が VRC，破線が R を表す．青色の点は観測された水圧センサー値に対するデータベース中の水圧センサー値のシナリオ．赤色の点は閾値を満たした中で最も R が大きいデータベース中の水圧センサー値のシナリオ．

式で示される分散低減の三つの指標を用いてシナリオを検索する．

$$\mathrm{R}(m) = \frac{\sum_{i=1}^{20} s_i(n)s_i(m)}{\sqrt{\sum_{i=1}^{20} s_i(n)^2}\sqrt{\sum_{i=1}^{20} s_i(m)^2}} \quad (1)$$

$$\mathrm{VRO}(m) = 1 - \frac{\sum_{i=1}^{20} (s_i(n) - s_i(m))^2}{\sqrt{\sum_{i=1}^{20} s_i(n)^2}} \quad (2)$$

$$\mathrm{VRC}(m) = 1 - \frac{\sum_{i=1}^{20} (s_i(n) - s_i(m))^2}{\sqrt{\sum_{i=1}^{20} s_i(m)^2}} \quad (3)$$

ただし，$s_i(n)$ は i 番目の水圧センサーで観測される水圧データの最大絶対値，$s_i(m)$ はデータベースに登録されている m 番目 $(m = 1, 2, ..., N_\mathrm{T})$ の水圧データの最大絶対値である．$\mathrm{R}(m)$ は水圧センサー値の空間分布の近さを意味し，1 に近いほど津波発生源の場所が近いと言える．$\mathrm{VRO}(m)$ と $\mathrm{VRC}(m)$ の値域は $-\infty < \mathrm{VRO}(m) \leq 1, -\infty < \mathrm{VRC}(m) \leq 1$ である．$|\mathbf{s}(m)|$ が $|\mathbf{s}(n)|$ より大きいとき $\mathrm{VRO}(m)$ は小さい値となり，過大評価に敏感である．また，$|\mathbf{s}(m)|$ が $|\mathbf{s}(n)|$ より小さいとき $\mathrm{VRC}(m)$ は小さい値となり，過小評価に敏感である．$\mathrm{VRO}(m)$ と $\mathrm{VRC}(m)$ が両方ともある閾値を超えた $\mathbf{s}(m)$ のうち，$\mathrm{R}(m)$ が最大となる $\hat{m} = \mathrm{argmax}_m \mathrm{R}(m)$ を選ぶことにより，過大評価と過小評価を防ぎつつ津波発生源の近いシナリオを検索することができる．本研究ではこの閾値を 0.9 と設定する．図 2 に観測された水圧センサー値に対するデータベース中水圧センサー値の R と VRO，VRC を計算した結果の一例を示す．VRO と VRC が閾値 0.9 を超えているシナリオの中で R が最も大きいシナリオ (図中の赤点) が選ばれる．このようにして選ばれた地震シナリオ $\boldsymbol{\theta}(\hat{m})$ に対応する津波高 $d(\hat{m})$ を予測津波高 $\hat{d}_\mathrm{MI}$ とする．

3.2 ガウス過程回帰

水圧センサー値と沿岸津波高の間の相関を利用した線形回帰による予測 [Baba et al., 2014] を発展させた手法として，非線形な関数を近似できるノンパラメトリック手法であるガウス過程 (Gaussian Process, GP)[Rasmussen and Williams 2006] による予測が提案されている [Igarashi et al., 2016]．ガウス過程を用いて複雑な応答関数を近似することによって，水圧センサー値 $\mathbf{s}$ から尾鷲検潮所における波形の高さ d を回帰し，高精度の津波高即時予測ができる．

ガウス過程は，多変量ガウス分布を一般化した確率過程であり，ある水圧センサー値 $\mathbf{s}(n)$ が与えられた時，津波高の予測分布がガウス分布として得られる．予測分布の確率が最大となる予測値 $\hat{d}_\mathrm{GP}$ は，(4) 式の共分散関数と事前分布に σ^2 の分散を持つガウス分布を設定することによって (5) 式のように記述される．

$$k(\mathbf{s}(m), \mathbf{s}(n)) = \exp\left(-\beta|\mathbf{s}(m) - \mathbf{s}(n)|^2\right) \quad (4)$$

$$\hat{d}_\mathrm{GP} = \mathbf{k}(n)^\mathrm{T}(\mathbf{K} + \sigma^2\mathbf{I})^{-1}\mathbf{d} \quad (5)$$

このとき，パラメータ β はガウス関数の幅の逆数を表す．また，$\mathbf{k}(n) = [k(\mathbf{s}(1), \mathbf{s}(n)), ..., k(\mathbf{s}(N_\mathrm{T}), \mathbf{s}(n))]^\mathrm{T}$ は $\mathbf{s}(n)$ と訓練データの共分散ベクトルを表し，$\mathbf{K}$ は $\mathbf{s}(1), \mathbf{s}(2), ..., \mathbf{s}(N_\mathrm{T})$ の共分散関数を用いた共分散行列，$\mathbf{I}$ は $N_\mathrm{T} \times N_\mathrm{T}$ の単位行列を表す．

ガウス過程による津波高の予測モデル構築において重要なのは，N_T ケースの訓練データを回帰することではなく，予測誤差の小さい予測モデルを構築することである．そこで，N_T ケースの訓練データに対する過学習を避けつつ，予測モデルを構築するために，ガウス過程におけるパラメータ β, σ を交差検証 (Cross Validation, CV) を行い，汎化誤差が最小になるように設定する．

3.3 非線形パラメトリックモデル

水圧センサー値と津波高の間にべき法則を見いだすことにより，(6) 式で表現される非線形パラメトリックモデルが提案

された [Yoshikawa et al., 2017].

$$\hat{d}_{\mathrm{NP}} = \sum_{i=1}^{20} a_i s_i(n)^{b_i} \tag{6}$$

ガウス過程回帰には外挿が難しいという問題があったが，非線形パラメトリックモデルは外挿でも高い予測精度を持つ．

パラメータ a_i, b_i は，平均二乗誤差 $E(a_i, b_i) = \frac{1}{N_{\mathrm{T}}} \sum_n |d_{\mathrm{NP}}(n) - d(n)|^2$ が最小になるように最適化する．パラメータの更新は (7) 式のように最急降下法を用いる．

$$a_i \leftarrow a_i - \varepsilon \frac{\partial}{\partial a_i} E(a_i, b_i), \ b_i \leftarrow b_i - \varepsilon \frac{\partial}{\partial b_i} E(a_i, b_i) \tag{7}$$

ただし，学習率は $\varepsilon = 0.01$，パラメータの初期値は $a_i = 0, b_i = 1 (i = 1, 2, ..., 20)$ とする．

4. 検証結果

4.1 全時間予測

シミュレーションにより生成された全 180 分間の水圧センサー値の最大絶対値 $\mathbf{s} = \{s_i\}_{i=1}^{20}$ を説明変数として，最大津波高 d を予測する検証を行なった．予測誤差は，(6) 式で表される平方根平均二乗誤差 (Root Mean Square Error, RMSE) を用いる．

$$\mathrm{RMSE} = \sqrt{\frac{1}{N} \sum_{n=1}^{N} [d(n) - \hat{d}(n)]^2} \tag{8}$$

全 1506 個のデータのうちランダムに選出した 1004 個のデータを訓練データとし津波高予測モデルの生成に用い，残りの 502 個のデータをテストデータとして津波高予測性能の検証に用いた．実際の津波高 d に対するテストデータで予測した津波高 $\hat{d}$ のプロットを図 3 に示す．直線 $\hat{d} = d$ に近いほど誤差が小さいことを表す．Multi-index 法に比べて非線形パラメトリックモデル，ガウス過程回帰の予測値は直線 $\hat{d} = d$ に近く，より正確に予測できていることが見て取れる．特に，津波高が大きい範囲 ($d \geq 12$[m]) では Multi-index 法の予測結果は真値から大きく外れているが，ガウス過程回帰や非線形パラメトリックモデルでは津波高が小さい範囲と同程度に正確な予測ができている．

また，データの分け方をランダムに変えながら 100 回試行した平均予測誤差を図 4 に示す．Multi-index 法の予測誤差は 1.05[m]，ガウス過程回帰の予測誤差は 0.75[m]，非線形パラメトリックモデルの予測誤差は 0.85[m] となった．この結果から，水圧センサー値と津波高の相関を利用した直接予測のアプローチの予測誤差は，地震シナリオの推定を経由する二段階予測のアプローチに比べて 28.6% 小さいということが分かった．さらに，予測誤差の標準偏差は，Multi-index 法では 9.88×10^{-2}[m]，ガウス過程回帰では 4.29×10^{-2}[m]，非線形パラメトリックモデルでは 4.28×10^{-2}[m] となった．予測誤差のばらつきも直接予測のアプローチは二段階予測のアプローチに比べて 56.7% 小さいということが分かった．

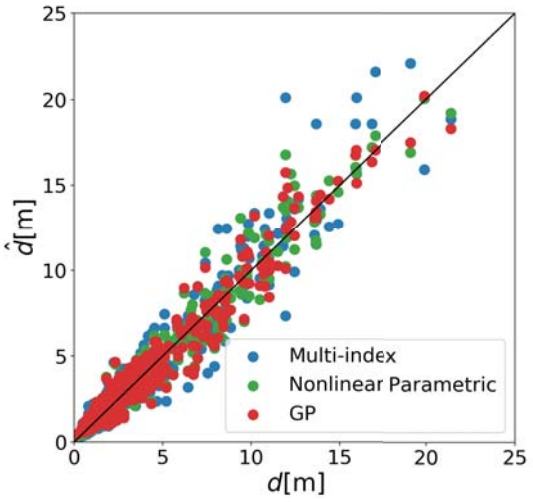


図 3: 真の津波高 d に対する各予測手法によって予測した津波高 $\hat{d}$．青色は Multi-index 法，赤色はガウス過程回帰，緑色は非線形パラメトリックモデル．

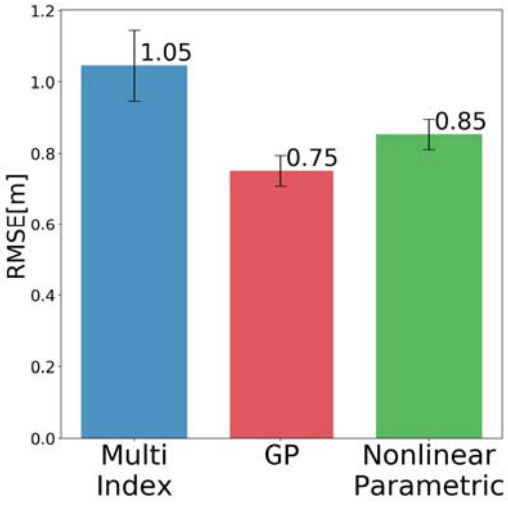


図 4: 各予測手法の予測誤差 RMSE．エラーバーは標準偏差を表す．青色は Multi-index 法，赤色はガウス過程回帰，緑色は非線形パラメトリックモデル．

4.2 リアルタイム予測

実際の予測システムでは，地震発生後 180 分間の水圧データを収集するのではなく，より短時間での正確な予測を行うことが求められる．そこで，時刻 $\tau \leq 180$ 分までの水圧センサー値の最大絶対値 $\mathbf{s}_\tau = \{s_{i,\tau}\}_{i=1}^{20}$ を説明変数として，最大津波高 d を予測する検証を行なった．時刻 $\tau = 1, 2, ..., 180$ 分において訓練データをテストデータの分け方をランダムに変えながら予測を行い，時刻 τ における平均予測誤差を算出した．

地震発生後の時刻に対する各予測手法での予測誤差の変化を図 5 に示す．いずれの手法も地震発生後 10 分程度で予測誤差は急激に小さくなり，50 分以降でほぼ一定となった．また，予測誤差が 1.00[m] を下回るのに要した時間は，Multi-index 法は 20 分であった一方で，ガウス過程回帰では 9 分，非線形パラメトリックモデルでは 13 分となった．この結果から，直

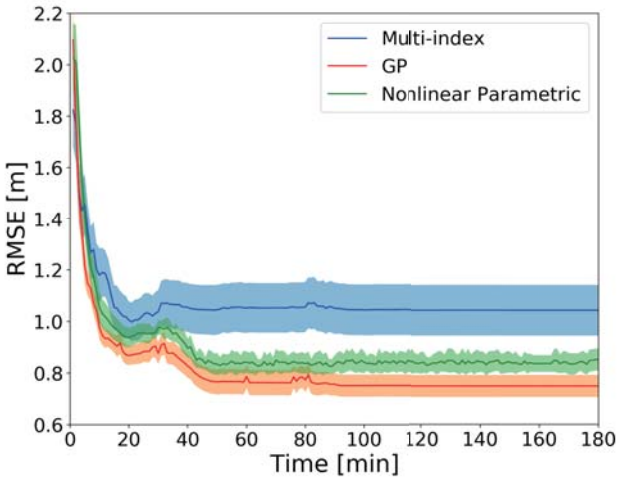


図 5: 地震発生後の時刻に対する各予測手法の予測誤差 RMSE. 青色の線は Multi-index 法，赤色の線はガウス過程回帰，緑色の線は非線形パラメトリックモデル．区間は標準偏差を表す．

接予測のアプローチは二段階予測のアプローチが必要とする 45.0% の時間で正確な予測を行うことができると分かった．

また，地震発生後 10 分のガウス過程回帰，非線形パラメトリックモデルの予測誤差はそれぞれ Multi-index 法より 17.2%, 10.6% 低いことが分かった，さらに，地震発生後 10 分の予測誤差の標準誤差もガウス過程回帰，非線形パラメトリックモデルはそれぞれ Multi-index 法より 55.2%, 39.8% 低いことが分かった，

また，図 6 に，$\tau = 10, 20, 30, 40$ 分での，テストデータで予測した津波高 $\hat{d}$ を実際の津波高 d に対してプロットした図を示す．地震発生から短時間の予測でもガウス過程回帰と非線形パラメトリックモデルは Multi-index 法よりも真値に近い予測値を取っていることが分かる．

5. 結論

海底水圧計のデータから沿岸津波高を予測する手法には，観測した水圧センサー値から地震のシナリオを推定し，そのシナリオに基づいて津波高を予測する二段階のアプローチと，水圧センサー値から直接津波高を予測するアプローチがあった．本研究では，これらのアプローチを全時間予測とリアルタイム予測の検証を行うことで比較を行なった．二段階アプローチの代表的手法として Multi-index 法，直接予測の代表的手法としてガウス過程回帰と非線形パラメトリックモデルを取り上げた．これらの手法を用いて DONET の水圧センサー値から津波高を予測する検証を行なった結果，直接予測の手法であるガウス過程回帰は，二段階アプローチの Multi-index 法と比べて，予測誤差は 28.6% 低く，予測誤差が十分小さくなるまでに要する地震発生後からの時間も 55.0% 短かった．さらに，地震発生 10 分以降での予測誤差の標準偏差も，ガウス過程回帰と非線形パラメトリックモデルは Multi-index 法に比べて約 50.0% 小さいということが分かった．以上から，水圧センサー値から沿岸津波高を予測する際は，直接予測のアプローチが有効であると分かった．

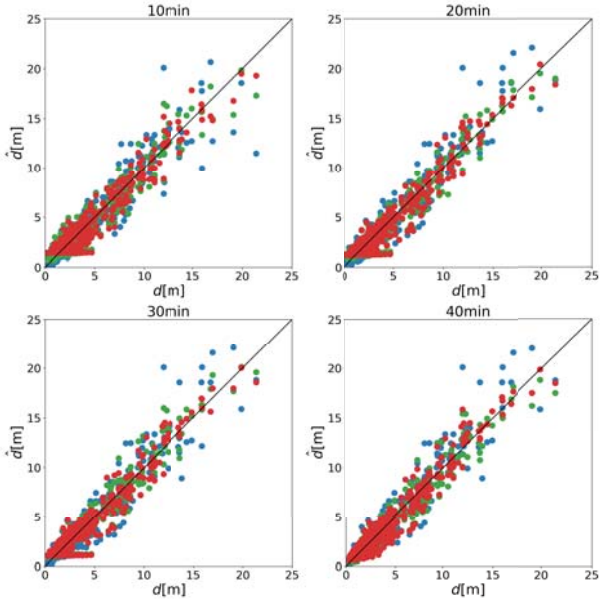


図 6: 真の津波高 d に対する各予測手法によって予測した津波高 $\hat{d}$. 左上は地震発生後 10 分，右上は 20 分，左下は 30 分，右下は 40 分の予測結果．青色は Multi-index 法，赤色はガウス過程回帰，緑色は非線形パラメトリックモデル．

参考文献

[Yamamoto et al., 2016] Yamamoto N, Aoi S, Hirata K, Suzuki W, Kunugi T, and Nakamura H: Multi-index method using offshore ocean-bottom pressure data for real-time tsunami forecast. Earth, Planets and Space, 68(1), 128(2016).

[Baba et al., 2014] Baba T, Takahashi N, Kaneda Y: Near-field tsunami amplification factors in the kii peninsula, japan for dense oceanfloor network for earthquakes and tsunamis (donet). Marine Geophysical Research 35(3):319325(2014).

[Igarashi et al., 2016] Igarashi Y, Hori T, Murata S, Sato K, Baba T, Okada M: Maximum tsunami height prediction using pressure gauge data by a gaussian process at owase in the kii peninsula, japan. Marine Geophysical Research 37(4):361370(2016).

[Yoshikawa et al., 2017] 吉川 真史，五十嵐 康彦，村田 伸，馬場 俊孝，堀 高峰，岡田 真人: べき乗則をもとにした津波高予測のための非線形パラメトリックモデル，第 20 回情報論的学習理論ワークショップ, 東京 (2017).

[Baba et al., 2016] Baba T, Ando K, Matsuoka D, Hyodo M, Hori T, Takahashi N, Obayashi R, Imato Y, Kitamura D, Uehara H, et al. : Large-scale, high-speed tsunami prediction for the great nankai trough earthquake on the k computer. The In- ternational Journal of High Performance Computing Ap- plications 30(1):7184(2016).

[Rasmussen and Williams 2006] C.E. Rasmussen and C.K.I. Williams: Gaussian Processes for Machine Learning. the MIT Press(2006)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

災害前後 SAR 画像と DEM データを用いた CNN による土砂災害検出

Landslide Detection Using CNN with SAR Images before/after the Disaster and DEM

植田　大介[*1]
Daisuke Ueda

間普　真吾[*1]
Shingo Mabu

呉本　尭[*1]
Takashi Kuremoto

[*1] 山口大学大学院創成科学研究科
Graduate School of Sciences and Technology for Innovation, Yamaguchi University

Remote sensing using synthetic aperture radar (SAR) images has attracted attention as a method of disaster area detection. However, there is a problem that a lot of experts and time are required for wide-area SAR image interpretation. Therefore, in this research, we propose a method that automatically detects landslide disaster areas using convolutional neural network (CNN). The proposed method uses not only the SAR images after disaster occurs, but also the images before the disaster and altitude data (DEM). In the experiments, the accuracy of classification as disaster area and non-disaster area in the testing areas was 75.56%, and intersection over union (IoU) was 21.86% that showed the ratio of the areas classified as disaster to the actual disaster areas. From these results, it was clarified that the landslide disaster areas could be classified by CNN considering the features of SAR images and DEM data before and after the disaster.

1. 背景と目的

台風や記録的な豪雨により土砂災害が発生した場合、その被害把握の方法として航空機を用いた調査が行われている。しかし、その方法では悪天候では調査が困難であるということや、時間を要してしまうという問題がある。そこで、土砂災害が発生した際に，広範囲な被害状況を悪天候下でも一度に観測する方法として衛星画像を用いたリモートセンシングが注目されている。衛星画像は昼夜、天候の影響を受けず広域観測が可能な合成開口レーダ(Synthetic Aperture Radar, SAR)によって得られた SAR 画像が用いられる。

これまでの多くの手法では災害前後の SAR 画像から算出される NDVI（正規化植生指数）の変化量から土砂災害の検出を行っている[三浦 07]。判読は機械的には行われておらず、人の知識や経験が必要となる。また、広範囲にわたる判読には多くの人員と、時間が必要となる。

そこで本研究では、災害前、災害後の SAR 画像に加え、標高データ(Digital Elevation Model, DEM)を用いた機械学習によって土砂災害の検出を試みた。DEM を用いた理由は、土砂災害の要因の一つとして標高が関係していると考えたためである。

2. 対象データ

本研究で対象とした土砂災害事例は平成 29 年 7 月に発生した九州北部豪雨である。この豪雨により福岡県朝倉市では最多雨量 586.0 ミリを記録し、死者 37 人、行方不明者 4 人となった。

この災害直後に観測された SAR 画像(After)、災害前に観測された SAR 画像(Before)、および標高データ(DEM)を機械学習の訓練データ、テストデータとして用いた。さらに国土地理院によって公開されている土砂災害マスク(True Mask)を実際に災害が発生した場所のラベル付け、評価のために用いた。対象領域の SAR 画像全体のサイズは 6648（横）×4360(縦)である。この画像の 1pixel 当たりの実際の解像度は約 $3m^2$ である。

連絡先：間普真吾，山口大学大学院創成科学研究科
〒755-8611 山口県宇部市常盤台 2-16-1
Tel/Fax：0836-85-9519　Email：mabu@yamaguchi-u.ac.jp

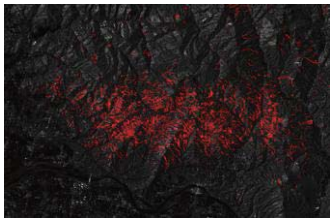


図 1. SAR 画像全体

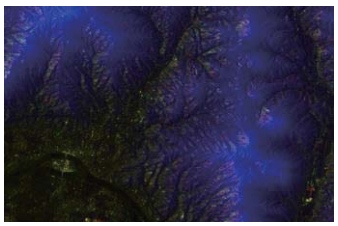


図 2. 学習に用いたデータを画像化したもの(南東部)

After に True Mask をオーバーレイしたものを図 1 に示す。対象領域の南東部の Before, After, DEM のデータがそれぞれ RGB に対応するように合成した画像を図 2 に示す。

3. 提案手法

本研究では、広域な災害前後 SAR 画像と DEM データ(以下、広域画像と呼ぶ)から土砂災害発生地域の検出を目的とする。検出の手順は、まず広域画像をパッチ分割して災害領域(Abnormal, ABN)、非災害領域(Normal, NOR)に分類して、識別器が学習するためのデータセットを作成する。ABN と NOR の分類基準は後述する。次に識別器にデータセットを用いて学習させる。識別器としては画像の識別で高い性能を示す畳込みニューラルネットワーク(Convolutional Neural Network, CNN)[岡谷 15]を用いる。そして学習後の CNN を用いて土砂災害発生地域を検出する。

3.1 データセット作成方法

広域画像を北西部、北東部、南西部、南東部（NE、NE、SW、SE）に分割して、いずれかを 2 つの領域を訓練画像領域、1 つ

の領域をバリデーション画像領域、残った 1 つの領域をテスト画像領域(未知領域)とする。

これらの領域からランダムに画像を切取るが、ABN、NOR の画像枚数は同じになるようにする。この理由は、広域画像には ABN の占める割合よりも NOR の占める割合の方が多いため、各クラスに所属する画像枚数を同程度としない場合、学習に偏りが生じてしまうためである。

3.2 ABN、NOR に分類する条件

データセットを作成する際に、パッチ画像を NOR、ABN に分類する必要がある。そのためにパッチ画像の中央部に注目する。Ture Mask データを参照してその注目領域(4×4pixel)における災害マスク含有率が 100%であるならば ABN。含有率が 0%であるならば NOR。含有率が 1%～99%であるならば棄却する。

3.3 転移学習

識別器は VGG16[Simonyan 14] を用いる。VGG16 は 2014 年の ILSVRC(ImageNet Large Scale Visual Recognition Challenge)で提案された畳込み 13 層と全結合 3 層の計 16 層から成る高い識別精度を示す CNN である。本研究では ImageNet と呼ばれる大規模な画像データセットで訓練済みの VGG16 モデルを用い、SAR 画像識別に転移させて学習を行う。

3.4 検出方法

未知領域に対して検出を行い、結果を予測土砂災害マスク(Predicted Mask)として表示させる。手法の流れは以下のとおりで、ABN、NOR の識別をピクセル単位で行う。

Step 1　未知領域と同じサイズの 2 次元配列をすべてカウンター値 0 にして用意する

Step 2　未知領域においてストライド 1pixel で生成したパッチ画像をモデルに識別させる

Step 3

- NOR と識別された場合
  →パッチ画像の注目領域に対応する座標の配列のカウンター値を +0 する
- ABN と識別された場合
  →パッチ画像の注目領域に対応する座標の配列のカウンター値を +1 する

Step 4　配列の各カウンター値を参照していく。カウンター値が閾値*未満であるならば、NOR ピクセルとする。カウンター値が閾値以上であるならば、ABN ピクセルとする
*本研究では閾値を 8 とした

例として、未知領域が 4×4pixel、注目領域が 2×2pixel、閾値が 3 であるときの Predicted Mask の生成例を図 3 に示す。

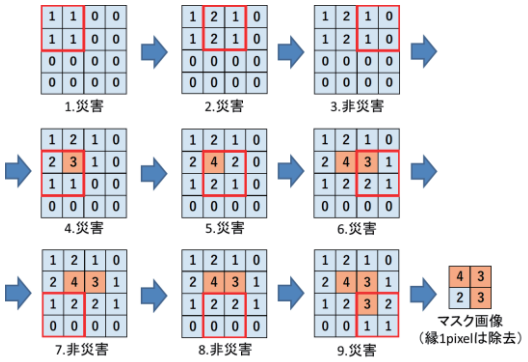


図 3. Predicted Mask 生成例

表 1. テスト画像に対する結果の混同行列

		Predicted label	
		NOR	ABN
True label	NOR	4342	658
	ABN	1786	3214

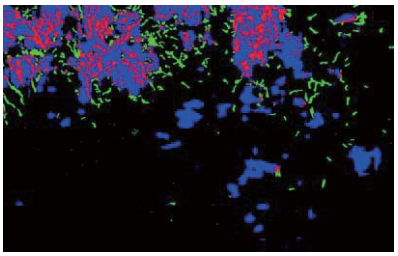


図 4. 予測災害地マスク画像

4. 実験結果

4.1 データセットの内容

3.1 節で述べた方法で、広域画像の分割領域 NW、NE から訓練画像、SW からバリデーション画像、SE から性能評価用のテスト画像となるパッチ画像を切り取った。以下に各枚数を示す。またパッチ画像サイズは 224×224 である。

- 訓練画像:10000 枚(NOR:5000 枚　ABN:5000 枚)
- バリデーション画像: 2000 枚(NOR:1000 枚　ABN:1000 枚)
- テスト画像:　10000 枚(NOR:5000 枚　ABN:5000 枚)

4.2 テスト画像の識別結果

テスト画像を転移学習後の VGG16 によって識別させた結果(混同行列)を表 1 に示す。識別精度は **75.56%**であった。

4.3 予測災害土砂マスク(Predicted Mask)

予測土砂災害マスク(Predicted Mask)と実際の土砂災害マスク(True Mask)を重ねたものを図 4 に示す。青が Predicted Mask (P)、緑が True Mask(T)、赤が Predicted Mask に含まれている True Mask (P∧T)である。検出の性能を評価する指標である IoU は **21.86%**であった。IoU は次式で導出できる。

$$IoU(Intersection\ over\ Union) = \frac{area(P \cap T)}{area(P \cup T)}$$

5. まとめと考察

本研究では土砂災害検出に対するリモートセンシングを CNN(VGG16)によって機械的に行う手法を提案した。入力するデータとして災害前後の SAR 画像と、標高データ(DEM)を用いた。その結果、未知領域における災害地域、非災害地域の識別精度は **75.56%**であった。また、災害と識別した地域と、実際の災害地域の合致割合は(IoU)は **21.86%**であった。生成された予測災害域マスクから、1 種類の情報、たとえば標高データ(DEM)のみ依存して識別することはなく、災害前後 SAR 画像も含めた 3 種類の情報から識別を行っていると考えられる。

参考文献

[三浦 07] 三浦弘之, 翠川三郎: 高分解能衛星画像と数値標高モデルを用いた 2004 年新潟県中越地震での斜面崩落地の検出,日本地震工学学会論文集, 第 7 巻, 第 5 号, 2007.

[岡谷 15] 岡谷貴之: 深層学習, 講談社, 2015.

[Simonyan 14] Karen Simonyan and Andrew Zisserman: Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv:1409.1556*, 2014.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

学習事例を上回る大洪水に対する深層学習水位予測モデルの検証

Applicability of the deep learning flood forecast model against the flood exceeding the training events

一言正之[*1]
Masayuki HITOKOTO

桜庭雅明[*1]
Masaaki SAKURABA

[*1] 日本工営株式会社 中央研究所
Nippon Koei Co., Ltd. R&D Center

Although artificial neural networks (ANN) is widely used for real-time flood prediction model, it is pointed out that the weak point of the model is poor applicability for the inexperienced magnitude of flood. In this study, the ANN models were applied to Abashiri River catchment. The training period of the ANN models were 1998-2015. The validation data was the 2016's largest flood since the river-stage observation had started. The main component of the model was the four-layer feed-forward network. As a network training method, the deep learning based on the denoising autoencoder was applied. The river-stage prediction up to 6 hours showed very good accuracy, and proved it can nicely predict the such a large flood.

1. はじめに

全国の一級河川で洪水予測システムが稼働しているが，住民の適切な避難判断に役立てるためには，予測精度が不十分な場合も多い．河川の水位予測には様々な手法が提案されており，その一つにニューラルネットワーク（Aritificial Neural Network；ANN）を用いた予測手法がある．これまでの研究で，様々な河川において ANN モデルの適用性が報告されている[Dawson 2001, Maier 2010]．近年では，深層学習を適用した洪水予測モデルも開発されており，高い予測精度が報告されている[一言 2015, Hitokoto 2017]．

しかしながら，ANN をはじめとする機械学習モデルの一般的な弱点として，学習事例を上回るような事例に対しては予測性能が担保されない，という点が挙げられる．洪水予測においては，学習事例を上回るような大規模洪水への対応こそが重要である．そのため，ANNによる洪水予測モデルは十分な信頼性を得られておらず，防災現場への実用化が進んでいない．

こうした課題への対応として，本検討では 2016 年の台風 10 号で生じた網走川における過去最大の洪水事例を対象として，ANN 洪水予測モデルの適用検討を行った．学習事例を上回るような高い水位の洪水に対しても，「水位変化」に着目して学習を行うことで，予測モデルの適用性が保たれることを示した．

2. 対象流域と対象洪水

2016 年の台風 10 号は，北海道に記録的な大雨をもたらし，27 名の死者・行方不明者が生じた．網走川においては，下流の観測所（川尻漁場）において過去最大の水位を観測した．

網走川流域の流域図と観測所の位置を図 1 に示す．流域面積は 1319km^2，水位観測所が 5 地点，雨量観測所が 8 地点である．対象洪水として，水文・水質データベースで主な地点のデータが入手できる期間（1998～2016 年）のなかから，はん濫注意水位を超過した 17 洪水を抽出した．そのうち，1998～2015 年までの 16 洪水を学習データ，2016 年の 1 洪水を検証データとした．学習データについては，ピークの 72 時間前から 48 時間後までを 1 洪水と定義した．したがって，16 洪水×121 時間=1936 データを学習データとした．

連絡先：一言正之，日本工営株式会社，茨城県つくば市稲荷原 2304，029-871-2034，hitokoto-ms@n-koei.jp

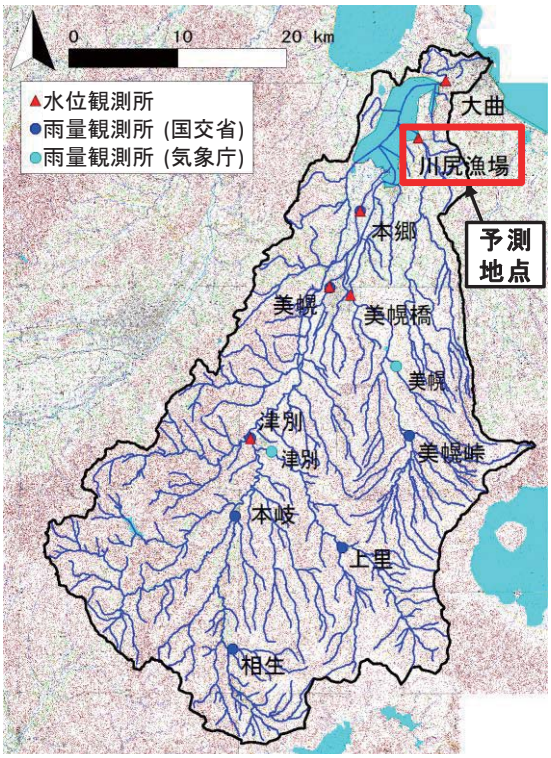


図1: 対象流域（網走川）と観測地点の位置

3. ニューラルネットワーク水位予測モデル

階層型の 4 層 ANN モデル（図 2）を構築した．モデルの出力データは，予測地点（川尻漁場）の 6 時間あたりの水位変化とした．入力データは，予測地点や上流域や雨量・水位および水位変化のデータとした．これらの観測データはオンラインでリアルタイムに入手可能である．各観測地点からの洪水到達時間の検討より，水位予測に影響を及ぼしうる時系列のデータをできる限り包含するように設定した．入出力データの一覧を表 1 に示す．

1998～2015 年の洪水により学習を行い，2016 年の洪水で検証計算を行った．学習には確率的勾配降下法を用い，学習係数の設定は AdaGrad を適用した．誤差関数の勾配の算出には誤差逆伝搬法を用い，過学習による精度低下を避けるため，ドロップアウトを適用した．主な設定内容を表 2 に示す．

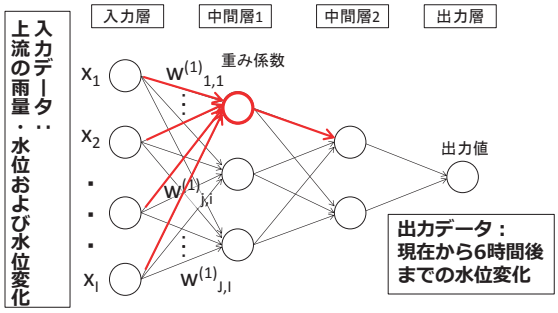


図2: ＡＮＮ水位予測モデルの概念図

表 1: ANN モデルの入出力の組合せ

出力	入力データ数（時系列数×地点数）				
	時間雨量	上流 ΔH	自己 ΔH	自己水位	合計
川尻漁場 ΔH	7×6	9×3	9×1	2×1	80

表 2: ANN モデルの主な設定

種別	設定内容
学習データ期間	過去 19 年間の洪水データ
学習データ種類	水位，水位変化，時間雨量
ミニバッチのサイズ	100
モーメンタム	0.5
学習率の設定方法	AdaGrad（初期値 0.1）

4. 計算結果と考察

4.1 計算結果

2016 年洪水における 6 時間後の水位予測結果を図 3 に示す．計算は 1 時間ごとに行っており，毎回の予測結果を連続的につないだものが図 3 である．図の黒丸が実績水位，赤線が予測水位である．予測と実績はほぼ一致しており，予測精度は十分に高かったことを表している．なお，ANN の出力は 6 時間先までの水位変化であるが，出力結果に現時刻水位を足し合わせることで水位に変換している．

図 4 には，学習データの実績値と，検証データの実績値・計算値を時刻ごとにプロットしたものを示す．図の横軸が水位，縦軸が直近 6 時間における水位変化である．学習データは 1998～2015 年の 16 洪水分(1936 データ)，検証データは 2016 年の洪水(1003 データ)である．検証事例の計算結果(◇)は，実績値(●)をよく再現している．図 4 の水位(横軸)について見ると，検証洪水の実績(●)は過去最大であるため，学習洪水(×)を上回る最大水位を示している．一方で 6 時間あたりの水位変化(縦軸)について見ると，検証洪水よりも，学習洪水の方が大きな水位変化を記録している．

4.2 考察とまとめ

ANN を始めとする機械学習を用いた洪水予測モデルの欠点として，学習事例を上回るような大洪水に対する信頼性の欠如が指摘される場合が多い．言いかえると，ANN は学習事例の内挿となるような問題に対しては適切なアウトプットを出すことができるが，外挿は適用性が無いと言われている．

しかしながら，本事例では学習事例を上回るような大洪水に対しても，十分な水位予測精度を示すことができた．ANN の出力層を，水位そのものではなく「水位変化」とすることにより，過去最大の洪水についても内挿に近い問題に落とし込むことができた．このように，入出力応答の工夫を行うことで，ANN による洪水予測モデルの適用性を拡張することができると考えられる．

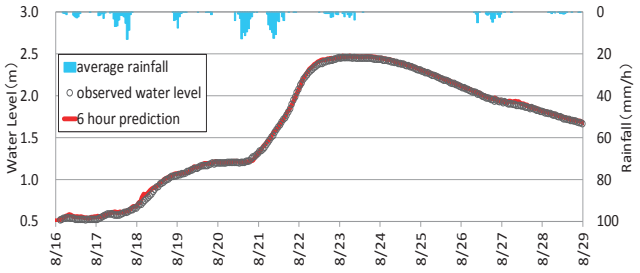


図3: 6 時間予測の結果

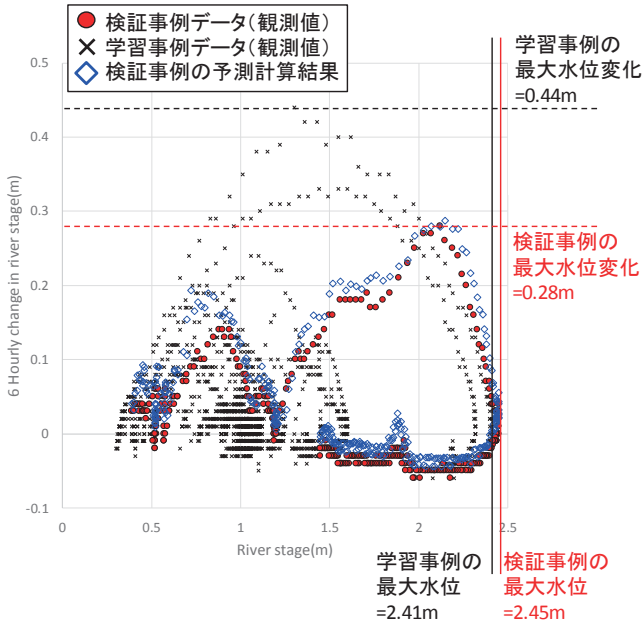


図4: 対象流域（網走川）と観測地点の位置

参考文献

[Dawson 2001] C. W. Dawson, R. L. Wilby: Hydrological modelling using artificial neural networks, Progress in Physical Geography, Vol.25, No.1, pp.80-108, 2001.

[Maier 2010] H. R. Maier, A. Jain, G. C. Dandy, K. P. Sudheer: Methods used for the development of neural networks for the prediction of water resource variables in river systems: Current status and future directions, Environmental Modelling & Software, Vol.25, pp.891-909, 2010.

[Hinton 2006] G. E. Hinton, S. Osindero, Y. Teh , A fast learning algorithm for deep belief nets, Neural Computation, Vol.18, pp.1527-1544, 2006.

[Hitokoto 2017] M. Hitokoto, M. Sakuraba, Y. Sei, Development of the Rearl-time river stage prediction method using deep learning, Journal of JSCE, Vol.5, No.1, pp. 422-429, 2017.

[一言 2015] 一言正之，櫻庭雅明，清雄一，深層学習を用いた河川水位予測手法の開発，土木学会論文集 B1(水工学) 72(4)，pp.187-192， 2015.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

不十分な情報下での緊急度と効率的な網羅を考慮した経路探索システム

A Route Search System Considering Urgency and Efficient Coverage under the Condition of Uncertain Information

中村 優太 *1 Yuta Nakamura
松原 正樹 *2 Masaki Matsubara
鈴木 伸崇 *2 Nobutaka Suzuki
井ノ口 宗成 *3 Munenari Inoguchi
森嶋 厚行 *2 Atsuyuki Morishima

*2筑波大学大学院 図書館情報メディア研究科
Graduate School of Library, Information and Media Studies, University of Tsukuba, Japan

*1筑波大学 図書館情報メディア系
Faculty of Library, Information and Media Science, University of Tsukuba, Japan

*2静岡大学 情報学部
Faculty of Informatics, Shizuoka University, Japan

The covered route search problem for graphs with deadline time has applications such as aerial photographing route search problem at natural disaster. However, information on the deadline time of a node is not necessarily fully known in advance, and it is not realistic to calculate the optimum route in advance. In this paper, we propose a method to calculate a route as efficient as possible while giving priority to nodes with efficient covering under these conditions. The feature of this method is to prevent extreme deterioration of performance against dynamic change of information by using heuristics that makes the remaining nodes as one unit as possible.

As a result of experiment using 100 patterns graph randomly allocated urgency, this method was able to reduce flight time of average 36.52% compared with simple method. And, in many graphs, the proposed method reduces the case that does not meet the deadline.

1. はじめに

近年，自然災害時対応において，空撮で得られる情報の有効活用に注目が集まっている．例えば，ドローンやヘリなどの航空機の利用により，被害状況を調査するといった利用方法が考えられる．その際，飛行経路を決める必要があるが，飛行経路を決めるための情報が完全に揃わない時点で飛行を開始し，徐々に参考となる情報が入手可能になるという事が一般的である．例えば，ツイッター等で，ある地点は緊急事態であるといった参考情報が入ってくる可能性がある．

本論文では，そのような状況を扱うためのシステムを提案する (図 1)．本システムでは，対象となる地域の地図をセル分割し，テレビ報道，ツイッターなどの情報を参考に，災害対策本部が各セルに向かわなければならない締め切り時刻を決定する．デフォルトの締め切り時刻は∞である．航空機は，情報が不完全な状態で飛行を開始し，締め切り時刻の最新情報に従い経路を動的に決定する．報道やツイッターでは完全に情報を把握することはできない事が予想されるため，飛行機は最終的には地域全体を網羅するように飛行を行なう．

ここでの問題は，経路決定における緊急性と効率的な網羅の両立である．本論文では，飛行機が上下左右とナナメの 8 方向に飛ぶことを仮定し，地図のマトリクスをファンアウト 8 のノード隣接したセルをつないだグラフで表現する．緊急度優先経路探索では，できるだけ多くの時間制約を満たす最短の経路を見つける．

連絡先: 松原正樹，筑波大学図書館情報メディア系，〒 305-8550 茨城県つくば市春日 1-2，masaki@slis.tsukuba.ac.jp

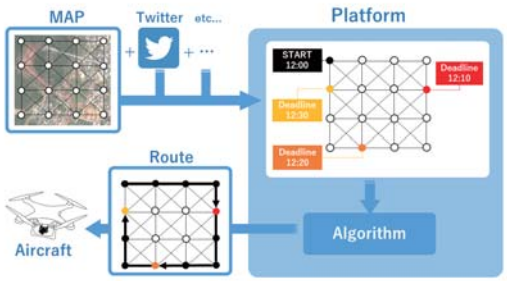


図 1: 提案システム

一方，このような探索は効率的な網羅とは必ずしも両立しない．効率的な網羅の経路は，常に残りのノード (セル) を一カ所に固めるものであり，ジグザグやらせん状の経路がそれらの例となる．この戦略では，重複して訪れる必要があるセルがないため，効率的な網羅が可能となる．同時に，このように残りを一カ所に固める戦略は，新たな情報が来て，新たに緊急で訪れなければいけない箇所が出現した場合に対応するためにも良い戦略となる．

提案システムでは，これらの 2 つの戦略を組み合わせたハイブリッド戦略アルゴリズムを導入する．例

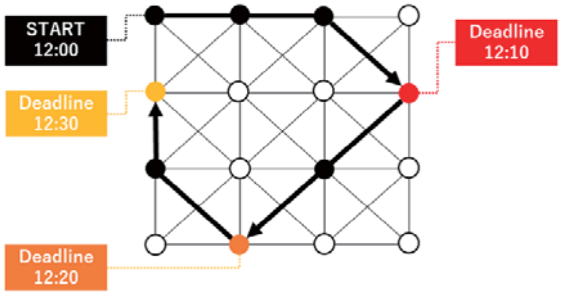


図 2: 単純に緊急度が高い順番に通過する経路

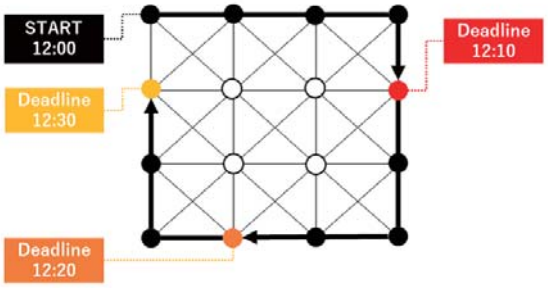


図 3: 重複を減らすために多少の遠回りをした経路

えば，図 2 に対して，図 3 のように回れば，緊急性に対応しながら，重複無く網羅ができるため，効率的だといえる．

本論文では，不十分な情報下でスタートし，徐々に情報が明らかになるような状況において，緊急性と効率的な網羅撮影を行なう経路を探索するシステムを提案し，アルゴリズムをシミュレーションにより評価する．本システムで扱う問題は，これまでの航空機の経路生成手法 [Liu 14][Liu 12][Sujit 04] と設定が異なる．アルゴリズムが扱う対象は，配送計画問題の一種と考えられるが，状況が時間とともに変化するため，最初に全体最適を考えることはできない．動的な状況を考慮した経路探索問題の研究も存在するが [Golden 08][Dorigo 10]，変更の予測が効かない状況を対象としており，既存の手法の適用が難しい．

2. 問題定義

情報収集を行う領域として矩形セルで構成された多角形領域を想定する．この領域の各セルには，どれくらいまでに撮影しなければならないという締切時刻が秒単位で設定されるものとする．このとき，セルの中央に格子点として頂点がある三角メッシュ状の無向グラフ G を考える．

本問題で扱うグラフは，$G = (N, E)$ の形で表される．頂点集合 $N = \{n_1, n_2, ..., n_m\}$ は要素ごとに，セルに対応した締切時刻と高度を持つ．各頂点に対し締切時刻を与える関数を $Deadline : N \to Time$ とする．この締切時刻は，後から追加される被災情報によって，動的に変更される可能性がある．頂点に高度を与える関数を $Height : N \to \mathbb{R}$，座標を与える関数を $Position : N \to \mathbb{R}^2$ とする．

辺集合 $E = \{e_1, e_2, ..., e_k\}$ は要素ごとに長さを持つ．各辺に対し長さを与える関数を $Length : Edge \to \mathbb{R}_+$ とする．

被災地を空撮する航空機の飛行経路は，グラフ理論における歩道の形で表す．本問題では，入力としてグラフ $G = (N, E)$，関数 $Deadline$，$Height$，$Length$，飛行開始地点 n_{start} 飛行開始時間 t_{start} が与えられたき，締切時刻が短い箇所を優先して訪れながらも，早く網羅することのできる長さ k の歩道 $W_{output} = [n_{start}, n_{i1}, n_{i2}, ..., n_{k-1}, n_k]$ を求めたい．そこで，締切時刻内に訪れることができたかを評価する関数 E_u と，早く網羅することができたかどうかを評価する関数 E_c の二つの評価関数を用意する．

評価関数 E_u では締切時刻内に訪れることができたかどうかを評価する．もし，締切時刻内に訪れることができなかった場合は，ペナルティが課される．ここで，歩道 W_{output} 内において，ある頂点 n_i を初めて訪れた時刻を返す関数を $FirstVisitTime(n_i, W)$ としたとき，頂点 n_i に対するペナルティ関数 $Penalty(n_i, W)$ を次のように定義する．

$$Penalty(n_i, W) = \begin{cases} 0 & (FirstVisitTime(n_i, W) \leq Deadline(n_i)) \\ FirstVisitTime(n_i, W) - Deadline(n_i) & (\text{otherwise}) \end{cases} \quad (1)$$

ペナルティ関数 $Penalty(n_i, W)$ を用いて，評価関数 $E_u(W)$ は次のように定義する．

$$E_u(W) = \sum_{i=start}^{k} Penalty(n_i, W) \quad (2)$$

評価関数 E_c では網羅までの時刻を評価する．ここで，飛行経路から航空時間を算出する関数を $FlightTime(W)$ として，評価関数 $E_c(W)$ は次のように定義する．

$$E_c(W) = FlightTime(W) \quad (3)$$

よって，本問題は，グラフ $G = (N, E)$，関数 $Deadline$，$Position$，$Height$，$Length$，飛行開始 t 地点 n_{start}，飛行開始時間 t_{start} が入力として与えられたとき，V 中の頂点を全て含み，第一に評価関数 E_u がより小さく，第二に評価関数 E_c が小さくなるような長さ k の歩道 $W_{output} = [n_{start}, n_{i1}, n_{i2}, ..., n_{ik-1}, n_{ik}]$ を求めるものである．

3. 提案手法

本手法では，緊急度として与えられた締切時刻を可能な限り遵守しつつ，網羅するまでの時間が短くなるような経路を生成する．本手法の主な流れは次の通りである．まず，最も締切時刻が近い箇所を目標地点として，現在地点からの経路探索を改変 A*探索を用いて行う．そして，次に締切時刻が近い箇所

を目標地点として，先ほどの目標地点からの経路探索を行う．この 2 つの手順を通過していない箇所がなくなるまで繰り返す．以下，目標地点決定方法，および，探索アルゴリズムについて説明する．

3.1 目標地点決定方法

本手法では，緊急度が高く，現在地点から早く訪れることができ，可能であれば他の緊急度が高い箇所を通過できる経路が存在する地点を次の目標地点に決定する．具体的な手順を以下の通りである．以下で目標地点が一意に決定できない場合，ランダムに決定する．

1. 締切時刻が最も近い地点を目標地点とする．
2. 同じ締切時刻の地点が複数存在した場合，現在地点からの最短距離をとるときの飛行時間が最も短い箇所を目標地点とする．
3. 2 の飛行時間が同じ地点が複数存在した場合，それぞれの歩道 ΔW を計算し，余裕度 $Q(\Delta W)$ が最も小さい箇所を目標地点とする．ここで，開始ノードを n_c，終了ノードを n_{target} としたとき，余裕度 $Q(\Delta W)$ は次のように定義される．

$$Q(\Delta W) = \sum_{i=c}^{target} \{Deadline(n_i) - FirstTime(n_i, \Delta W)\} \quad (4)$$

3.2 経路探索手法

本手法で用いる改変 A*探索アルゴリズム，および，改変 A*探索アルゴリズムで用いるヒューリスティックス関数について述べる．

3.2.1 改変 A*探索アルゴリズム

本手法で用いる改変 A*探索アルゴリズムは，残余領域ができるだけひとまとまりになるように，目標地点に向かう経路探索を行う．そのため，このアルゴリズムによって生成される経路は，必ずしも最短経路をとるとは限らない．このような経路を生成するために，改変 A*探索アルゴリズムは残余領域の形を評価するヒューリスティクスを持つ．このヒューリスティクスは，残余領域ができるだけひとまとまりになるような経路をとるために関数 $h^*(n_c)$ に c_{group} として組み込まれている．

改変 A*探索アルゴリズムの考え方は，次の通りである．まず，地点 n_c に対して開始地点 n_s からの時間を $g(n_c)$，目標地点までの時間を $h(n_c)$，これらの和を総時間 $f(n_c)$ とする．

$$f(n_c) = g(n_c) + h(n_c) \quad (5)$$

ここで時間をコストとして扱えば，最短経路を求める際には総コスト $f(n_c)$ が最小となり続けるような経路を選択すればよい．

しかし，開始地点からのコスト $g(n_c)$ とは違い，目標地点までのコスト $h(n_c)$ は既知ではない．そのため，目標地点までのコストの推定値 $h^*(n_c)$ を与えるものとする．この推定値 $h^*(n_c)$ は後述のヒューリスティック関数として定義される．総コストは $f^*(n_c)$ として次のように与えられる．

$$f^*(n_c) = g(n_c) + h^*(n_c) \quad (6)$$

この $f^*(n_c)$ の比較を繰り返すことでコストが最小となるような経路を探索するアルゴリズムが改変 A*探索アルゴリズムである．

3.2.2 ヒューリスティック関数

ヒューリスティック関数 $h^*(n_c)$ を次のように定義する．

$$h^*(n_c) = t_{target} + t_{covering} \quad (7)$$

ここで，t_{target} は現在地点から目標地点までの見積もり時間，$t_{covering}$ は残余領域を網羅する際の見積もり時間である．

目標地点までの見積もり時間 t_{target}

航空機の最高速度を v_{max} とする．現在地 n_c から目標地点 n_t までの見積もり時間 t_{target} を次のように定義する．

$$t_{target} = \frac{\|Position(n_t) - Position(n_c)\|}{v_{max}} \quad (8)$$

残余領域の見積もり時間 $t_{covering}$

$t_{covering}$ は，残余領域を網羅することを考えたときの見積もり時間である．網羅を考えたとき，残余領域は可能な限りまとまって存在することが望ましい．これは残余領域が分断されている場合，網羅するときに必ず 1 度は既に通った箇所をもう一度通ることになり，非効率であるためである．

グラフ G の頂点のうち，経路 W に含まれていない頂点からなる集合を $N' \subset N$ とする．また，経路 W に含まれる頂点に接続する辺を除いた辺の集合を $E' \subset E$ とする．N' と E' から，残余領域 $G' = (N', E')$ から l 個の要素を持つ完全グラフ $K_l = (N_k, E_k)$ を作成する．頂点集合 $N_k \subset N$ は，N' 中の 1-連結している頂点集合 C を 1 つの要素とする集合である．辺集合 E_k の各要素はコストとして距離を持つ．各辺が持つ距離には，1-連結グラフ C 同士を結ぶ最短距離を近似値として用いる．このグラフ K_l を用いて，残余領域の見積もり時間 $t_{covering}$ を次のように定義する．

$$t_{covering} = \frac{total\_distance + n\_distance \times |N_k| + (\delta(G') - \lambda(G'))}{v_{max}}$$

ここで，$total\_distance$ は「残余領域同士の距離の総和」，すなわち，グラフ K_l の頂点集合 N_k を網羅する際の辺のコストの総和を表す．$n\_distance$ は隣り合う頂点間の最短距離である．また，$\delta(G')$ は G' の最小次数，$\lambda(G')$ は辺カットの重み和の最小値であり，$\delta(G') - \lambda(G')$ は残余領域の分断のし易さを表す．

3.3 アルゴリズム

提案手法の疑似コードを Algorithm1 に示す．1,2 行目では初期化として，現在地点 v_c に開始時点 v_s を，未探索ノードの集合 U に $G.node$ を代入する．5 行目では，$target$ に優先順位が最大の頂点を代入する．6 行目において，現在地点 v_c から $target$ までの経路探索を改変 A*探索アルゴリズムを用いて行い，経路 $path$ を得る．7 行目で，R に $path$ を追加する．8,9 行目で，経路にもとづいて移動を行い，v_c を $target$ に更新する．10 行目で，未探索ノードの集合 U から通過したノードを削除する．未探索ノードがなくなるまで，5〜10 行目までの処理を繰り返す．

Algorithm 1 Efficient Route Search Algorithm

Require: v_s, G
Ensure: W

```
v_c ← v_s
U ← G.node
R ← φ
while U ≠ empty do
    target ← U.priority.max
    path ← Mod-A_star(v_c, target, R)
    R ← R + path
    Move(R)
    v_c ← target
    U ← U \ R.all
end while
```

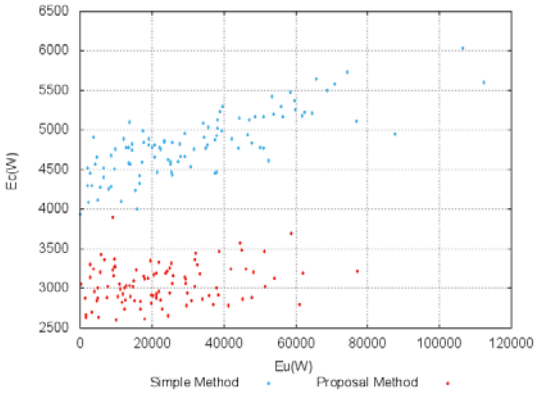


図 4: $E_u(W)$，$E_c(W)$ の散布図による手法の比較

4. シミュレーション

シミュレーションでは $3km^2$ の矩形領域を撮影視野で分割し，16 × 16 のノードを持つグラフを対象とした．単純に網羅する場合の航空時間を min_flight_time としたとき，締切時間を，$\mu = 1.0 \times min\_flight\_time$，$\delta = 0.25 \times min\_flight\_time$ の正規分布でランダムに設定したグラフ 100 個を用意した．これらのグラフ 1 つ 1 つに対して，提案手法を用いた時の経路 $W_{proposal}$，単純手法を用いた時の経路 W_{simple} を求める．単純手法は締切時間が短いノードを次の目標地点に設定し，そのノードまでの最短経路探索を繰り返す手法とする．

単純手法と提案手法のシミュレーション結果を示し，その性能を比較した．比較には，締切時間をどれだけ遵守できたかを評価するための評価関数 $E_u(W)$ と，どれだけ短い航空時間で網羅できたかを評価する関数 $E_u(W)$ を用いる．

各グラフの $E_u(W)$ と $E_c(W)$ の散布図を図 4 に、平均と標準偏差を表 1 に示す．図 4 から提案手法の優位性がわかり、表 1 から，単純な手法に比べて，提案手法では $E_c(W)$ に対して平均 29.42%，$E_c(W)$ に対して平均 36.52% の効率化が確認できた．

表 1: $E_u(W)$ と $E_c(W)$ の平均と標準偏差の比較

	単純手法	提案手法
$E_u(W)$ の平均	31928.77	22532.92
$E_u(W)$ の標準偏差	22960.94	15980.40
$E_c(W)$ の平均	4820.21	3059.85
$E_c(W)$ の標準偏差	393.22	246.85

5. まとめ

本論文では，不十分な情報下での緊急度と効率的に網羅を考慮した経路探索システムを提案し，そのためのアルゴリズムをシミュレーションにより評価した．提案手法の特徴は，残余領域をできるだけひとかたまりになるように経路を決定することで，徐々に情報が明らかになるような状況においても極端な性能劣化を防ぐことにある．シミュレーションの結果，本手法は単純に緊急度の高いノードから回る単純な手法と比べて，全経路の航空時間を平均 36.52% 削減することができた．今後はアルゴリズムの効率化を行い，災害現場での実用に向け被災地のデータを用いて有効性の検証を行う予定である．

謝辞

本研究の一部は JST CREST，科研費 (#25240012)，科学技術振興機構 SIP「レジリエントな防災・減災機能の強化」，および文部科学省「実社会ビックデータ利活用のためのデータ統合・解析技術の研究開発」の支援による．

参考文献

[Dorigo 10] Dorigo, M. and Stützle, T.: Ant colony optimization: overview and recent advances, in *Handbook of metaheuristics*, pp. 227–263, Springer (2010)

[Golden 08] Golden, B. L., Raghavan, S., and Wasil, E. A.: *The vehicle routing problem: latest advances and new challenges*, Vol. 43, Springer Science & Business Media (2008)

[Liu 12] Liu, Q., Pang, X., Wang, Y., Pan, Y., and Li, L.: An Improved Path Management Policy for the Ferry in Opportunistic Networks., *JNW*, Vol. 7, No. 10, pp. 1568–1575 (2012)

[Liu 14] Liu, Z., Chen, Y., Liu, B., Cao, C., and Fu, X.: HAWK: an unmanned mini-helicopter-based aerial wireless kit for localization, *IEEE Transactions on Mobile Computing*, Vol. 13, No. 2, pp. 287–298 (2014)

[Sujit 04] Sujit, P. and Ghose, D.: Search using multiple UAVs with flight time constraints, *IEEE Transactions on Aerospace and Electronic Systems*, Vol. 40, No. 2, pp. 491–509 (2004)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

ユーザ行動に基づくモバイルネットワーク故障検知と予測

Mobile Network Failure Detection and Forecasting with Multiple User Behavior

大木　基至 *1　竹内　孝 *2　植松　幸生 *1　上田 修功 *2
Motoyuki Oki　Koh Takeuchi　Yukio Uematsu　Naonori Ueda

*1NTT コミュニケーションズ株式会社　*2NTT コミュニケーション科学基礎研究所
NTT Communications Corporation　NTT Communication Science Laboratories

Providing stable and high-quality service is a critical issue for mobile network service providers. However, due to an unexpectedly huge amount of data traffic exceeding network capacity of a provider, a mobile network service experiences severe failures such as network troubles, performance deterioration, and slow throughput. Then, the service users often detect service outages before the service provider detects them. They can immediately publish their impressions on the service through social media and search for failure information on the web. In this paper, we propose a machine learning approach that incorporates multiple user behavior data into detecting and forecasting failure events. The approach is based on novel feature extraction methods and a model ensemble method that combines outputs of supervised and unsupervised learning models from multiple user behavior datasets. We demonstrate the effectiveness of the approach by extensive experiments with real-world failure events.

1. はじめに

モバイルネットワークのサービス提供者にとって，ネットワーク故障の早期検知あるいは予測は，高品質サービスの安定提供を実現するための重要な課題となっている．これはトラフィックの急増 [Cisco 17] によるスループット低下が引き起こすサービス品質の劣化や，通信設備の経年劣化等による深刻なネットワーク故障を予め知ることができれば，事前の対策措置の実行や迅速な復旧が可能となるためである．

サービス提供者では，ネットワーク故障を発見するためトラフィックやシステムログの監視が常時行われている [Gill 11]．ただ，このような監視は膨大なデータの確認が必要なため，故障発見までに遅延が生じる場合がある．また，コールセンターでの受付情報を用いた故障発見も行われているが，通話応対に時間がかかるため，常時監視と同様に遅延する可能性が高い．

一方，モバイルネットワークのサービス利用者（以下，ユーザ）は，サービスの使用不能や品質劣化についての SNS へ投稿しており，Twitter での故障への反応はコールセンターへの連絡数よりも早いと報告されている [Qiu 10]．Tweet データからネットワーク故障を検知するための研究やシステムの提案が行われているが，Tweet データのみを利用しており実用可能な性能は得られていない [Takeshita 15, Maru 16]．

ユーザの故障への反応は Twitter のみならず，Web 上のアクセス数や検索ログ数に反映されていると考えられる．そのため，これらの複数種類データの同時解析が実現できれば，より精度の高い早期の故障検知の実現が期待される．複数のユーザ行動データを用いた解析は，実社会上のイベント検知 (暴動など) [Kallus 14, Zhao 16] で行われているが，現在までネットワーク故障検知の分野では行われていない．

そこで本研究では，複数のユーザ行動データから特徴抽出を行い，アンサンブル教師あり機械学習モデルを用いて故障検知と予測を行うための方法を提案する．本研究の全体像を図 1 に示す．ユーザ行動データにはソーシャルデータ（Twitter，ニュース記事，RSS）やテレコムデータ（Web アクセスログ，検索ログ，コールセンター受付情報）などの様々な候補が挙げられるが，本研究ではサービスに関する Tweet データ，サービスの公式ページへの Web アクセスログ，サービス名を含む検索クエリ数を用いて，現実のネットワーク故障の検知・予測を行う．本研究で使用するデータの例として，あるサービス故障発生前後 4 日間間に観測された 1 時間ごとの総頻度を図 2 に示す．赤枠は故障発生期間を表す．故障発生時に頻繁に観測される典型的な単語やユーザにアクセスされる URL を示す．故障発生時にはそれぞれのユーザ行動データで通常時とは異なる振る舞いや変化が確認できる．

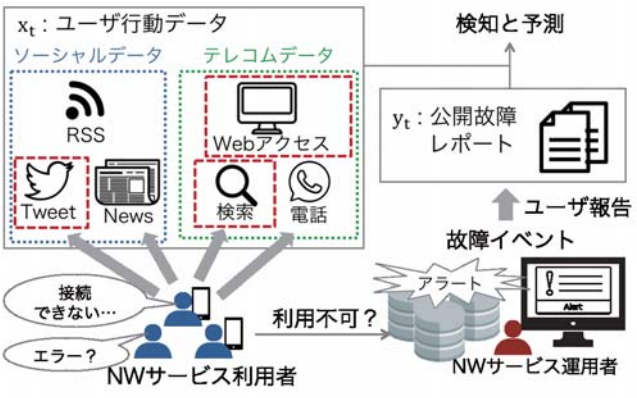


図 1: ユーザ行動に基づく故障検知と予測の全体像．本研究では赤の点線で囲まれたデータを使用する．

提案法では，複数のユーザ行動データを入力データとし，故障発生の予測スコアを毎分ごとに出力する．入力データは毎分単位で集計されるため，非常にスパースとなり，さらに故障の発生数は非常に少数であるため，故障に対応するラベルが非常に少ない不均衡となる．またユーザ行動データによって，スコアの予測に適した機械学習モデルは異なると考えられる．そこで提案法では，データのスパースネスとラベル不均衡の問題に適した特徴量変換を行い，複数のモデルの出力を組み合わせて予測スコアを出力するモデルアンサンブル法を行う．現実

連絡先: 大木基至，NTT コミュニケーションズ株式会社，東京都港区芝浦 3-4-1 グランパークタワー 16F，m.ooki@ntt.com

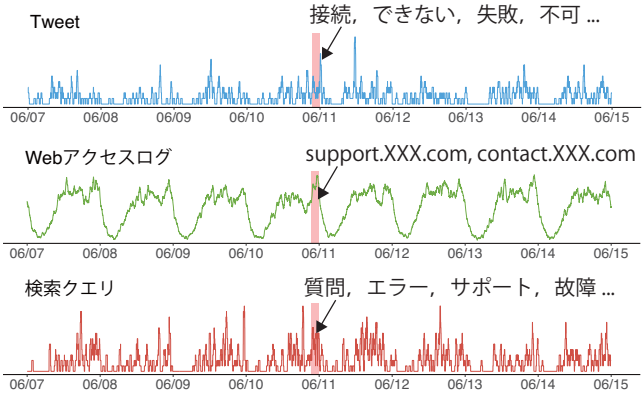


図 2: あるモバイルネットワークサービスに関する Tweet 数，公式ページへ Web アクセス数，検索クエリ数．赤枠は故障の発生期間を表す．

表 1: 九つの公開された故障情報

故障 ID	発生期間 (分)	日付と時刻
1	188	2016/11/13, 08:22 a.m.
2	60	2016/2/04, 06:00 a.m.
3	60	2016/2/13, 10:52 p.m.
4	60	2016/3/24, 02:00 a.m.
5	150	2016/6/10, 09:20 p.m.
6	512	2016/6/15, 09:20 p.m.
7	100	2016/7/06, 08:50 a.m.
8	950	2016/7/27, 10:00 p.m.
9	1554	2016/12/25, 01:46 a.m.

のモバイルネットワークサービスの故障データを用いた故障検知および予測の実験を行い，既存の単一のデータを用いた場合と比較し，提案法による大幅な精度向上を示す．

2. データセット

本章では，本論文で使用する故障情報と三つのユーザ行動データについて説明する．

2.1 故障情報

インターネット上で公開されているモバイルネットワークサービスで発生した 2015 年 11 月から 2016 年 12 月の九つの故障情報を収集した．表 1 に収集した故障 ID，故障の発生期間（分），日付と時刻を示す．発生期間が 60 から 1554 分まで変化するのは，サービスの故障はそれぞれ異なる原因で発生し，復旧に要する時間も異なるためである．

2.2 ユーザ行動データ

本研究では，Tweet と Web アクセスログと検索クエリの三つのデータをユーザ行動データとして使用する．故障データと同期間でそれらを収集した．Tweet データは，Twitter API を通じて，サービス名の略称を含む合計 72,070 ツイートを収集した．各 Tweet に対して，形態素解析を行い，名詞，動詞，形容詞の単語集合を作成した．そのうち，頻度が 2 以下の単語やストップワードを削除し，合計 5750 単語を使用した．Web アクセスログデータとは，モバイルネットワークサービスに関するトップページ，購入ページ，サポートページを含む合計 29,520,772 件の Web ページへのアクセスログである．アクセスログは (アクセス時刻 = “2016-03-20 11:54:12”, URL = “http://contact.XXX.com”, ページタイトル = “Contact Form”) の組で表現される．その中から，アクセス数が 2 以下のユニークページを削除し，合計 6,378 件のページを使用した．検索クエリデータとは，検索エンジンの運用ログから，モバイルネットワークサービス名の略称を含む合計 82,136 件の検索データである．検索数が 2 以下のユニークな検索クエリを削除し，合計 1209 個のユニークな検索クエリを収集した．

表 2: 訓練とテストデータの評価データセット

テスト ID	訓練 ID	ラベル比率 [%]	スパース率 [%] $\mathcal{T}$	$\mathcal{W}$	$\mathcal{Q}$
5	1 - 4	0.12	99.55	99.06	99.85
6	2 - 5	0.10	99.56	99.06	99.85
7	2 - 6	0.27	99.57	99.42	99.85
8	2 - 7	0.31	99.58	99.42	99.85
9	4 - 8	0.57	99.58	99.58	99.84

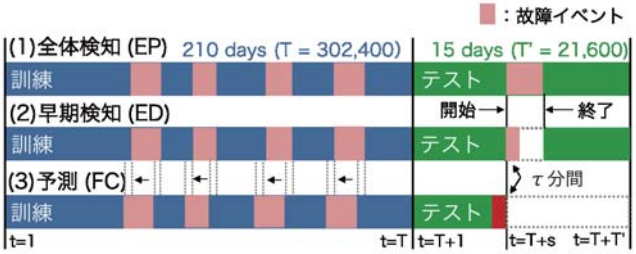


図 3: 全期間 (EP)，早期検知 (ED)，将来予測 (FC) の三つの問題設定

3. 問題設定

ある時刻 t のユーザ行動データの特徴ベクトルを $\boldsymbol{x}_t \in \mathbb{R}^M$，各時刻 t の故障の発生有無を表すラベルを $y_t \in \{-1, 1\}$ で表し，訓練データとテストデータを $\{(\boldsymbol{x}_t, y_t)\}_{t=1}^{T}$ と $\{\boldsymbol{x}_t\}_{t=T+1}^{T+T'}$ とする．テスト期間として，ある一つの故障発生時の前後 1 週間を使用する．訓練データはテストデータより過去に発生した故障 ID を複数含む 210 日間のデータとする．表 1 にある故障情報から，後半の故障 5 件をそれぞれ 1 件ずつテストデータに含む評価データセットを作成した．それらを表 2 に示す．訓練データに含まれる故障 ID を訓練 ID，訓練データ内の故障発生（つまり，$y_t = 1$）比率をラベル比率，訓練データ内の特徴ベクトルの 0 の比率をスパース率とする．ラベル比率が非常に小さいのは，故障発生頻度は正常時（つまり，$y_t = -1$）と比べ，非常に少ないためである．

本研究では，三つの問題設定を定義する．それらを図 3 に示す．それらは，テストデータの全範囲の故障を検知する問題（全体検知 : EP），テストデータの故障開始時刻から τ 分間の故障を検知する問題（早期検知 : ED），テストデータの τ 分後の故障発生を予測する問題（予測 : FC）の三つである．本研究では，各問題設定において訓練データの特徴ベクトル $\boldsymbol{x}_t$ から予測スコアを求める機械学習モデルを訓練し，テストデータを用いて学習モデルを評価する．

4. 故障検知と予測

本章では，故障検知と予測を行うための機械学習モデルを比較し，複数のユーザ行動データと機械学習モデルを組み合わ

せるモデルアンサンブル法を提案する．故障検知と予測性能の評価実験を通じて，提案法の有用性を検証する．

4.1 検知性能のモデル比較

はじめに，各ユーザ行動データの時系列性を用いてスパース比率を改善するために，各特徴ごとに単純移動平均による特徴変換を行った [Botezatu 16]．次に，不均衡データの分類性能の向上が確認されている Bi-Normal Separation (BNS) [Forman 03] による特徴変換を行った．特徴変換されたデータを用いて，最適な機械学習モデルを選択するために，四つの教師あり分類モデル：ロジスティック回帰（LR），決定株のアダブースト（ADA），ランダムフォレスト（RF），三層パーセプトロン（NN）と二つの教師なし異常検知モデル：1 クラス SVM（OCS），オートエンコーダー（AE）の計六つのモデルを比較する．実装は scikit-learn と Keras を使用した．各モデルのパラメータは，5 交差検証法を用いて，訓練データを 5 分割し，検証データでの AUC の平均値が最も高いパラメータとした．

三つのユーザ行動データと六つの機械学習モデルを用いて，五つの故障 ID に対する早期検知（ED）と全体検知（EP）の AUC の結果を表 3 に示す．便宜上，Tweet データを $\mathcal{T}$，Web アクセスログデータを $\mathcal{W}$，検索クエリデータを $\mathcal{Q}$ と表記する．“All” は五つの故障 ID の平均値と標準偏差を表す．ED では Tweet データを用いたオートエンコーダー，EP では Web アクセスログデータを用いた LR が最も高い性能を示した．また，Tweet データでは EP より ED のほうが平均的に性能が高く，Web アクセスログデータでは，ED より EP のほうが平均的に性能が高いことを確認した．この結果から，ユーザは最初に Twitter から故障に関する情報を発信し，その後，故障情報を手に入れるため，Web ページへのアクセスを行う一連の行動がある可能性が示唆される．また，故障 ID : 5 では，Web アクセスログデータを用いた RF，故障 ID : 6 の ED では，検索クエリデータを用いた RF が最も高い性能を示した．この結果から，各故障 ID で故障の種類や発生時間が異なるため，機械学習モデルとユーザ行動データの最適な組み合わせはそれぞれの故障で異なることが考えられる．

4.2 モデルアンサンブル法

複数のユーザ行動データと機械学習モデルを活用するために，2 段階のモデルアンサンブル法を行う．前節の実験から一つ以上の故障で最も性能が高かったモデル LR，RF，AE を用いる．モデルアンサンブル法は，以下で定義される．

$$\text{(Level 1)}\quad \boldsymbol{z}_t = (f^{\mathcal{D}_1}_{\mathrm{M}_1}(\boldsymbol{x}_t), f^{\mathcal{D}_2}_{\mathrm{M}_1}(\boldsymbol{x}_t), \ldots, f^{\mathcal{D}_q}_{\mathrm{M}_3}(\boldsymbol{x}_t)) \tag{1}$$

$$\text{(Level 2)}\quad \hat{p}_t = \mathrm{sig}(\boldsymbol{w}^T \boldsymbol{z}_t + b) \tag{2}$$

sig はシグモイド関数 $\mathrm{sig}(a) = \frac{1}{1+exp(-a)}$，$\boldsymbol{w} \in \mathbb{R}^{3\times q}$ は 2 段目のモデル係数，b はバイアス項である．$f^{\mathcal{D}}_{\mathrm{M}}(\boldsymbol{x}_t)$ は，時刻 t のユーザ行動データ $\mathcal{D}_j, j = (1, \ldots, q)$ の三つのモデル M_1（=LR）と M_2（=RF）と M_3（=AE）の出力結果である．この定義から，最終予測スコア $\hat{p}_t$ は各ユーザ行動データと機械学習モデルの出力結果の線形結合で算出される．準ニュートン法を用いてモデル係数 $\boldsymbol{w}$ とバイアス項 b を推定するための損失関数を以下で定義する．

$$L(\boldsymbol{w}, b) = -\sum_{t=1}^{T} \{(1-y_t)\log(1-p_t) + y_t \log p_t\} + \psi(\boldsymbol{w}, b, C) \tag{3}$$

$\psi(\boldsymbol{w}, b, C)$ は正則化項を表す．実験では，リッジ正則化 $\psi(\boldsymbol{w}, b, C) = \frac{C}{2}(||\boldsymbol{w}||^2 + b^2)$ を用いる．

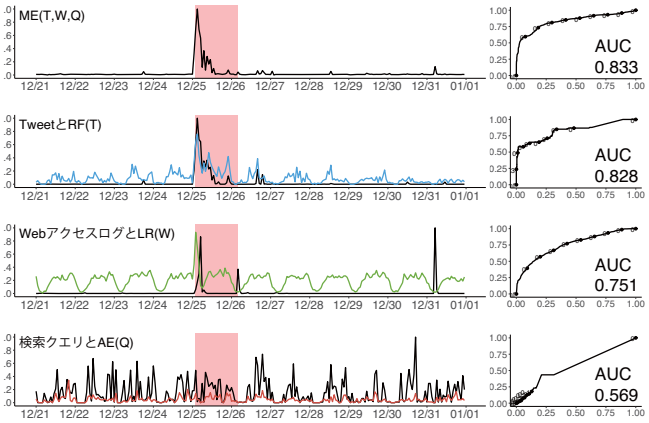


図 4: 故障 ID : 9 のユーザ行動データの推移と各モデルの予測スコア

比較手法として，三つのユーザ行動データを連結させて一つの特徴ベクトルからリッジ正則化付きのロジスティック回帰を学習させるデータアンサンブル法（DE）を用いる．EP と ED に関して，すべての故障 ID の平均値と標準偏差の結果を表 4 に示す．ED では Tweet と Web アクセスログのモデルアンサンブル法，EP では三つのユーザ行動データのモデルアンサンブル法が最も高い性能を示した．また，単一のユーザ行動データを用いたモデルアンサンブル法より，複数のユーザ行動データを用いたモデルアンサンブル法が高い結果を示した．一方，データアンサンブル法では性能改善が確認されなかった．これは，特徴次元数が増大し，過学習を引き起こした可能性が考えられる．

故障 ID : 9 の予測スコアと AUC の値を図 4 に示す．1 行目はモデルアンサンブル法，2 から 4 行目は各ユーザ行動データの推移と最も性能が高かった機械学習モデルの結果を表す．赤枠は故障発生期間を表す．モデルアンサンブル法の結果から，故障発生前後の偽陽性（2016/12/27 の Tweet や 2016/12/31 の Web アクセスログなど）を減らす効果を確認した．また，モデルアンサンブル法は Tweet データと Web アクセスログデータの故障時の予測スコアを活用した効果で，急増でかつロングテールな予測スコアを表現し，AUC が向上したと考えられる．

4.3 予測性能のモデル比較

本節では，三つ目の問題設定である τ 分後の故障予測に関する性能を比較する．故障ラベル y_t を τ 分先にずらした訓練データ $\{(\boldsymbol{x}_t, y_{t+\tau})\}_{t=1}^{T-\tau}$ を使用して機械学習モデルの訓練を行う．テストデータは図 3 の (3) のとおり $\{\boldsymbol{x}_t\}_{t=T-\tau+1}^{T+s}$ を使用する．機械学習モデルとして，Tweet データと Web アクセスログデータを用いたモデルアンサンブル法（ME($\mathcal{T}$,$\mathcal{W}$)，ME($\mathcal{T}$)，ME($\mathcal{W}$)），データアンサンブル法 DE($\mathcal{T}$,$\mathcal{W}$)，LR($\mathcal{T}$)，LR($\mathcal{W}$）の六つを比較する．予測のための時間幅は $\tau \in \{10, 30, 50\}$ とする．

各時間幅 τ ごとの AUC の平均値と標準偏差を表 5 に示す．太字は各時間ごとで最も高いスコアを表す．$\tau = 10$ と 30 では ME($\mathcal{T}$,$\mathcal{W}$)，$\tau = 50$ で ME($\mathcal{T}$) が最も高い性能を示した．これらの高い性能から，故障発生前からユーザがサービスの品質劣化を体感していた可能性が考えられる．複数，または一つのユーザ行動データを用いたモデルアンサンブル法は予測問題においても効果的であることが確認できた．

表 3: 各ユーザ行動データと機械学習モデルの AUC の結果．ED は $\tau = 60$ の早期検知の結果を表す．

データ	モデル	ID:5		ID:6		ID:7		ID:8		ID:9		All	
		ED	EP	ED	EP	ED	EP	ED	EP	ED	EP	ED	EP
$\mathcal{T}$	LR	0.92	0.94	0.82	0.60	0.62	0.74	0.99	0.76	**1.00**	0.82	$0.87_{\pm 0.16}$	$0.77_{\pm 0.12}$
	ADA	0.78	0.63	0.02	0.35	0.42	0.45	0.49	0.58	**1.00**	0.51	$0.54_{\pm 0.37}$	$0.50_{\pm 0.11}$
	RF	0.83	0.79	0.72	0.76	0.95	0.96	0.99	0.83	**1.00**	**0.83**	$0.90_{\pm 0.12}$	$0.83_{\pm 0.08}$
	NN	0.79	0.65	0.18	0.34	0.29	0.27	0.86	0.58	0.99	0.47	$0.62_{\pm 0.36}$	$0.46_{\pm 0.16}$
	OCS	0.88	0.69	0.72	0.56	0.50	0.50	0.50	0.56	**1.00**	0.70	$0.72_{\pm 0.22}$	$0.60_{\pm 0.09}$
	AE	**0.94**	0.82	0.86	0.73	0.93	0.90	0.90	0.70	**1.00**	0.73	$\mathbf{0.93}_{\pm 0.05}$	$0.78_{\pm 0.08}$
$\mathcal{W}$	LR	0.78	0.90	0.76	**0.86**	**0.99**	**0.99**	**1.00**	**0.99**	0.98	0.75	$0.90_{\pm 0.12}$	$\mathbf{0.90}_{\pm 0.10}$
	ADA	0.62	0.80	0.86	0.70	0.82	0.89	0.82	0.93	0.94	0.80	$0.81_{\pm 0.12}$	$0.82_{\pm 0.09}$
	RF	**0.94**	**0.97**	0.82	0.75	0.68	0.73	0.93	0.95	**1.00**	0.71	$0.87_{\pm 0.13}$	$0.82_{\pm 0.13}$
	NN	0.57	0.82	0.51	0.71	0.88	0.89	0.98	0.97	0.99	0.75	$0.79_{\pm 0.23}$	$0.83_{\pm 0.11}$
	OCS	0.60	0.50	0.40	0.68	0.79	0.78	0.04	0.51	0.82	0.52	$0.53_{\pm 0.32}$	$0.60_{\pm 0.13}$
	AE	0.41	0.50	0.38	0.69	0.81	0.81	0.03	0.50	0.82	0.47	$0.49_{\pm 0.33}$	$0.59_{\pm 0.15}$
$\mathcal{Q}$	LR	0.53	0.39	0.86	0.58	0.78	0.74	0.45	0.61	0.60	0.55	$0.65_{\pm 0.17}$	$0.57_{\pm 0.13}$
	ADA	0.26	0.33	0.16	0.56	0.61	0.62	0.45	0.53	0.27	0.50	$0.35_{\pm 0.18}$	$0.51_{\pm 0.11}$
	RF	0.73	0.55	**0.87**	0.70	0.62	0.52	0.36	0.64	0.42	0.48	$0.60_{\pm 0.21}$	$0.58_{\pm 0.09}$
	NN	0.25	0.32	0.20	0.51	0.30	0.47	0.54	0.52	0.50	0.52	$0.36_{\pm 0.15}$	$0.47_{\pm 0.09}$
	OCS	0.77	0.68	0.70	0.56	0.66	0.60	0.47	0.57	0.88	0.58	$0.70_{\pm 0.15}$	$0.60_{\pm 0.05}$
	AE	0.78	0.67	0.85	0.62	0.50	0.62	0.37	0.66	0.71	0.57	$0.64_{\pm 0.20}$	$0.63_{\pm 0.04}$

表 4: モデルアンサンブル（ME）とデータアンサンブル（DE）の AUC の結果．ED は $\tau = 60$ の早期検知の結果を表す．

データ	ME		DE	
	ED	EP	ED	EP
$\mathcal{T}$	$0.94_{\pm 0.09}$	$0.87_{\pm 0.08}$	-	-
$\mathcal{W}$	$0.90_{\pm 0.13}$	$0.88_{\pm 0.11}$	-	-
$\mathcal{Q}$	$0.62_{\pm 0.16}$	$0.60_{\pm 0.08}$	-	-
$(\mathcal{T}, \mathcal{W})$	$\mathbf{0.95}_{\pm 0.10}$	$0.90_{\pm 0.09}$	$0.88_{\pm 0.15}$	$0.88_{\pm 0.09}$
$(\mathcal{T}, \mathcal{Q})$	$0.94_{\pm 0.08}$	$0.87_{\pm 0.08}$	$0.88_{\pm 0.13}$	$0.73_{\pm 0.13}$
$(\mathcal{W}, \mathcal{Q})$	$0.90_{\pm 0.13}$	$0.88_{\pm 0.11}$	$0.90_{\pm 0.13}$	$0.89_{\pm 0.10}$
$(\mathcal{T}, \mathcal{W}, \mathcal{Q})$	$0.94_{\pm 0.09}$	$\mathbf{0.91}_{\pm 0.09}$	$0.88_{\pm 0.14}$	$0.88_{\pm 0.10}$

表 5: τ 分後の予測性能（FC）の比較

モデル	$\tau = 10$	$\tau = 30$	$\tau = 50$
ME$(\mathcal{T}, \mathcal{W})$	$\mathbf{0.81}_{\pm 0.27}$	$\mathbf{0.78}_{\pm 0.21}$	$0.69_{\pm 0.18}$
ME$(\mathcal{T})$	$0.72_{\pm 0.35}$	$0.71_{\pm 0.34}$	$0.72_{\pm 0.20}$
ME$(\mathcal{W})$	$0.76_{\pm 0.25}$	$0.77_{\pm 0.17}$	$\mathbf{0.77}_{\pm 0.09}$
DE$(\mathcal{T}, \mathcal{W})$	$0.72_{\pm 0.35}$	$0.66_{\pm 0.26}$	$0.69_{\pm 0.08}$
LR$(\mathcal{T})$	$0.79_{\pm 0.27}$	$0.60_{\pm 0.29}$	$0.48_{\pm 0.23}$
LR$(\mathcal{W})$	$0.70_{\pm 0.25}$	$0.71_{\pm 0.25}$	$0.73_{\pm 0.20}$

5. おわりに

三つのユーザ行動データからモバイルネットワークサービスの故障を検知および予測する機械学習アプローチを提案した．提案法により，過去の故障ラベルとユーザ行動データから特徴抽出を行い，モデルアンサンブル法に基づいて故障検知および予測を行った．モバイルネットワークサービスの実世界の複数のデータを用いた複数の実験を通じて，提案法は全体検知，早期検知，予測の三つの問題において高い性能を示した．

今後は，さらなる他のユーザ行動データの活用，高い検知性能を達成した要因の分析，本手法に基づいたリアルタイム検知システムの開発とその運用が考えられる．

参考文献

[Botezatu 16] Botezatu, M.; Giurgiu, I.; Bogojeska, J.; and Wiesmann, D.: Predicting disk replacement towards reliable data centers, In *SIGKDD* (2016).

[Cisco 17] Cisco Systems Inc.: Cisco visual networking Index: Global mobile data traffic forecast update 2016 - 2021 (2017).

[Forman 03] Forman, G.: An extensive empirical study of feature selection metrics for text classification, *Journal of Machine Learning Research*, 3, 1289–1305 (2003).

[Gill 11] Gill, P.; Jain, N.; and Nagappan, N.: Understanding network failures in data centers: measurement, analysis, and implications, In *SIGCOM* (2011).

[Kallus 14] Kallus, N.: Predicting crowd behavior with big public data, In *WWW* (2014).

[Maru 16] Maru, C.; Enoki, M.; Nakao, A.; Yamamoto, S.; Yamaguchi, S.; and Oguchi, M.: Development of failure detection system for network control using collective intelligence of social networking service in large-scale disasters, In *HT* (2016).

[Qiu 10] Qiu, T.; Feng, J.; Ge, Z.; Wang, J.; Xu, J.; and Yates, J.: Listen to me if you can : Tracking user experience of mobile network social media, In *IMC* (2010).

[Takeshita 15] Takeshita, K.; Yokota, M.; and Nishimatsu, K.: Early network failure detection system by analyzing twitter data, In *IM* (2015).

[Zhao 16] Zhao, L.; Ye, J.; Chen, F.; Lu, C. T.; and Ramakrishnan, N.: Hierarchical incomplete multi-source feature learning for spatiotemporal event forecasting, In *SIGKDD* (2016).

Oral presentation | Organized Session | [Organized Session] OS-28

[1D2-OS-28a] [Organized Session] OS-28

Tue. Jun 5, 2018 3:20 PM - 5:00 PM Room D (4F Cattleya)

[1D2-OS-28a-a] OS invited talk

○Naoaki Okazaki[1] （1. Tokyo Institute of Technology）

3:20 PM - 4:00 PM

[1D2-OS-28a-01] A policy decision making with multiple stepwise citizen participation program: A case study of revising the basic environmental plan Sapporo

○Susumu Ohnuma[1], Miki Yokoyama[1] （1. Hokkaido University）

4:00 PM - 4:20 PM

[1D2-OS-28a-02] Verification of consensus building support system on large-scale social experiment

○Tomohiro Nishida[1], Takanori Ito[1], Akihisa Sengoku[1], Takayuki Ito[1] （1. Nagoya Institute of Technology）

4:20 PM - 4:40 PM

[1D2-OS-28a-03] A Consideration of Modeling Understanding of Discussion Context with Content and Process for Developing Autonomous Facilitator Agents

○Shun Shiramatsu[1], Yuto Ikeda[1], Ko Kitagawa[1], Hiroaki Koura[1], Takayuki Ito[1] （1. Nagoya Institute of Technology）

4:40 PM - 5:00 PM

©The Japanese Society for Artificial Intelligence

3:20 PM - 4:00 PM (Tue. Jun 5, 2018 3:20 PM - 5:00 PM Room D)

[1D2-OS-28a-a] OS invited talk

○Naoaki Okazaki[1] (1. Tokyo Institute of Technology)

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

多段階市民参加プロセスによる政策決定:札幌市環境基本計画策定事例

A policy decision making with multiple stepwise citizen participation program: A case study of revising the basic environmental plan Sapporo

大沼進[*1]
Susumu Ohnuma

横山実紀[*1]
Miki Yokoyama

[*1] 北海道大学
Hokkaido University

This paper demonstrated a significance of policy decision making with multiple stepwise citizen participation programs with introducing a case of revising the basic environmental plan Sapporo. Sapporo city implemented participatory programs involving both applicants who were willing to join the discussion and residents who were randomly chosen. The participation programs were designed from the beginning stage to final stage of the planning. Back Cast Scenario Workshops (BCSW) were conducted in the participation program, in which participants begin with the discussion mapping out an ideal future and consider backward to present situation. We discussed the different role of participants in each step of the participatory program. Furthermore, we stated the advantages and points to note as for installing BCSW. Finally, we mentioned the limitations of our approach and remarked expectations to AI.

1. はじめに

社会全体で一つの決定が求められるとき，集団浅慮などを回避しながら多様な意見を集約し，多元的価値を反映させた合意形成を実現し，かつ，その決定に加わらなかった人も納得できるためには，その決定に至るまでのプロセスが公正であるかという手続き手的公正を考慮したプロセスデザインが重要である．その手続き的公正を高める手法の一つとして，計画づくりへの市民参加がある．ただし，市民参加の場をどう設計・運用するか，また決定プロセス全体の中で市民参加をどのように位置付けるかなど様々な留意事項がある．市民参加による意見集約の運用支援には AI の応用が可能であり，部分的には実用可能となっている（例えば，COLLAGREE [伊藤 15]）．だが，これを決定過程全体の中にどう位置付けて用いるかは今のところ人間の判断に委ねるしかない．

本稿では，多段階による市民参加を経て計画策定を行った実際の政策決定の事例紹介を通じて，複雑化社会における意思決定・合意形成のための AI 技術のあり方についての検討材料を提供する．具体的には，札幌市における第 2 次環境基本計画策定の事例を紹介する．

2. 札幌市における第 2 次環境基本計画策定のプロセス

2.1 第 2 次札幌市環境基本計画策定の背景

札幌市環境基本計画は 1998 年に策定され，2017 年度に計画期間を終える．この間，札幌市では，温暖化対策推進計画，エネルギービジョン，生物多様性ビジョンなど，個別計画が整い，2008 年には市民が取り組むべき行動を掲げた「環境首都・札幌」宣言をした．そのため，それらの上位計画としての環境基本計画の位置付けを見直し，個別計画の達成目標との棲み分けと整合性を明確化する必要が生じてきた．

そこで札幌市環境審議会では，2030 年の達成目標と 2050 年のあるべき未来像を描き，そこから現在に向かって逆算的に取り組むべきことを議論するというバックキャスティング手法で検討を進めていく方針とした．その達成目標とあるべき未来像に，次に述べる市民参加により市民の意見を反映させていった．

連絡先：大沼進，北海道大学，札幌市北区北 10 条西 7 丁目，ohnuma@let.hokudai.ac.jp

2.2 市民参加の流れと位置付け

この計画策定に際し，札幌市が取り組んだ市民参加には 2 点の特徴がある．第一に，関心の高い市民が議論する場（ステークホルダー会議）と，無作為抽出で選ばれた市民が議論する場（ミニ・パブリックス）の両方が行われたことである．一方で，誰もが意見を言える機会が提供されるべきという発言機会を満たすためにステークホルダー会議が必要であること，他方で，特定の意見や価値を有する人ばかりに偏らないよう代表性の高い参加者を確保するために無作為で選ばれた市民による議論も必要であることの両方を満たす設計となっている．

第二に，計画策定初期段階，中間段階，最終段階と 3 段階にわたりワークショップを開催したことである．その全体の流れを図 1 に示す．

まず，初期段階では，環境活動に取り組んでいる市民や事業者等によるワークショップと札幌市在住外国人インタビューが行われ，それを受けて無作為で選ばれた参加者による第 1 回市民ワークショップ(WS)が開催された．この WS では，未来像をつくり共有していくためにバックキャストシナリオワークショップ(Back Cast Scenario Workshop: 以下 BCSW)という方式で行われた．参加者はいくつかのテーマに分かれ，テーマごとに未来像を議論した．それを受けて審議会は計画の骨子案を策定し，その骨子案を元に第 2 回市民 WS が開催された．第 2 回 WS では，第 1 回に引き続いて BCSW 方式で行い，付け加えるべき事項がないかなどを点検すると共に，将来像に向けて必要なことについて議論した．そしてパブリックコメントの直前に，第 3 回市民 WS を開催した．ここでは「現在できていないことがどうすればできるようになるか」と，この計画を多くの市民に知ってもらうために必要な取り組みについて議論した．さらに，希望者による意見交換会も開催された．

以上のように，第 2 次環境基本計画策定にあたり，多段階で多様な層を含んだ市民参加プログラムが執り行われた．

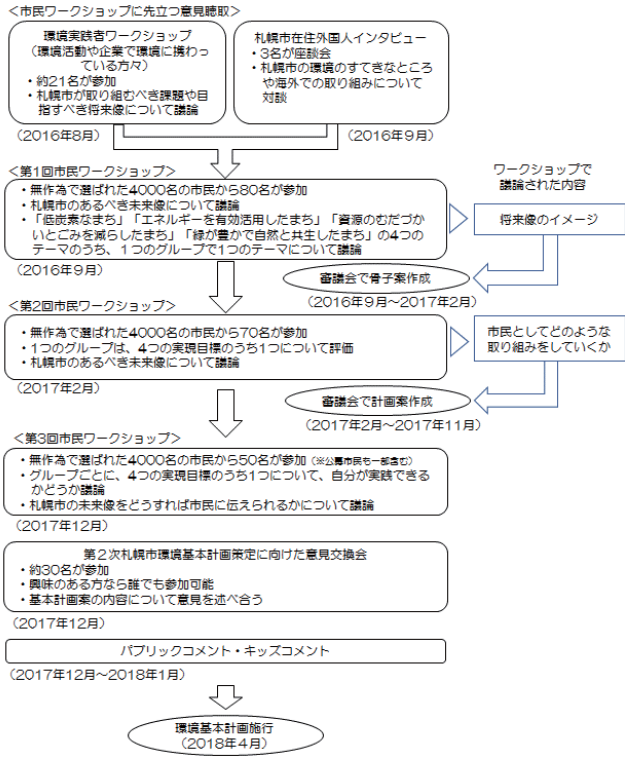


図 1　計画策定にかかる市民参加の流れ

3.　札幌市における市民参加プロセスの意義

3.1　多段階参加プロセスの意義

一般に，計画づくりへの市民参加は，内容が固まった最終段階よりも早い時期からの関与が望ましいとされる．それは，多様な意見・価値を反映させる余地が広いためである．計画が決まってからでは多元的価値が反映されないと批判されることもある．合意形成とは，ある価値を採択して別の価値を排除するという問題にしてはならない．今回の事例の場合，理想の未来像は一人ひとり異なるが，その最大公約数を集約する上で，初期からの市民参加は重要な鍵であった．また，関心の高い市民と無作為抽出による市民と両方による議論の場が別々に設けられたことも注目に値する．集団意思決定研究では，カスケードや集団極化などを起こさないために独立した議論の場が必要であるとされているが[亀田 97]，本事例はこれに沿った形でデザインされている．

一方，最終段階では提案された計画について評価をすることができる．無作為で選ばれた市民には“価値の診断士”としての役割がある [Dienel 89]．多くの市民にとって受け入れられるか，実現可能かといった側面について評価することで計画の実効性を高めることにつながる．どれほど優れた計画も市民が納得でき，実行できなければ絵に描いた餅になる．とくに環境問題は行政だけで解決できるものではなく，多くの市民の協力が必要とされ，そのための行政と市民の協働の取り組みも重要視される．その実効性を高める一手段としての市民による評価という形式に意味がある．

以上のように，同じ市民参加といっても初期段階と最終段階ではその機能が異なる．ただ闇雲に市民参加の回数が多ければよいというわけではなく，時間軸の中で適した役割を明確にし，その役割に沿って参加の場をデザインしていく必要がある．この点で，札幌市の市民参加プロセスは参考になるだろう．

3.2　バックキャストシナリオワークショップの意義

BCSW はあるべき未来像を設定し，そこから逆算して現在取り組むべき課題を考えるという思考法を参加型ワークショップに持ち込んだものである．BCSW は，地球規模の環境問題のように長期的な問題を扱うのに向いている．ただし，望ましい未来を出発点に考えるため，理念を整理する上ではよいが，具体性に欠けるという問題が指摘されている．実際，今回の札幌市における事例でも，参加者からは実感がわかない，抽象的でわかりにくいなどの意見があった．今回の札幌市の場合には，既に個別計画で個別の達成目標が存在している中で，その上位の理念を体系的に整理する上では意義があった．これら具体的な達成目標がなかったときに，BCSW を用いて達成目標を具体化する作業をする際の運用方法や効果について今後さらに精緻化していく必要があるだろう．

また，社会全体の決定としてだけでなく，個人の観点からも BCSW の意味を検討する必要があるだろう．人は一般に，“今・ここ”に反応し，将来の利益や損失を割り引いて考えてしまう傾向がある．しかし，未来に焦点をおくことで，将来価値の割引が軽減される可能性がある．BCSW の参加者がより未来志向的になることができたか，その効果は現在検証作業中である．

4.　今後の課題と AI への期待

本事例における 3 回にわたる無作為抽出による参加率は 2～4%に過ぎなかった．日本における無作為抽出による市民参加では 5%前後といわれており，残念ながら今回もその例に漏れなかった．低参加率の下では代表性が担保されない．そこで，参加のハードルを下げる仕掛けが必要である．Web 上でのオンライン参加は参加のハードルを下げるツールの一つと期待される．だが，web による議論は対面に比べて，議論の熟度，異質な意見への傾聴などに懸念事項が多い．AI によるファシリテーションがこれらを改善する方向で発展することが期待される．

また，ステークホルダー会議と無作為で選ばれた参加者それぞれについて，web 参加と対面参加の違いを比較する必要もある．こうした社会実験を通じて，社会心理学など社会科学の知見と AI 技術の疎通を相互に図っていくことで，より豊かな社会的意思決定・合意形成の支援に繋がると期待される．

謝辞

本研究は，課題設定による先導的人文学・社会科学研究推進事業（実社会対応プログラム）「私益と共益が錯綜する公共的意思決定のプロセスデザインに関する研究」により助成を受けた．札幌市環境局をはじめ，市民参加プログラムの運用に取り組んでくださったみなさまへ御礼申し上げます．

参考文献

[Dienel 89] Dienel, P. C.: Contributing to social decision methodology: citizen reports on technological projects, In C. Vlek & G. Cvetkovich (Eds.) Social decision methodology for technological projects, Kluwer Academic Publishers, 1989.

[伊藤 15] 伊藤孝行，奥村命，伊藤孝紀，秀島栄三: 多人数ワークショップのための意見集約支援システム Collagree の試作と評価実験～議論プロセスの弱い構造化による意見集約支援～，日本経営工学会論文誌，Vol.66, No.2, (2015)

[亀田 97] 亀田達也: 合議の知を求めて グループの意思決定，共立出版 (1997)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

大規模社会実験における合意形成支援システムの検証

Verification of consensus building support system on large-scale social experiment

西田智裕[*1] Tomohiro Nishida　伊藤孝紀[*1] Takanori Ito　仙石晃久[*1] Akihisa Sengoku　伊藤孝行[*1] Takayuki Ito

[*1] 名古屋工業大学
Nagoya Institute of Technology

Conducting workshop for consensus building is restricted by human, time and spatial. So, it is difficult for many citizens to participate. We have developed a consensus building support system that supports discussion. However, since it is difficult to conduct a large-scale social experiment exceeding 500 people, the support system on that scale has not been verified. Therefore, in this study, we conduct a large-scale social experiment using support system for Place Branding in Nagoya city and examine effect and problem. Through this verification, the discussion using the support system proved effective for satisfying the participants.

1. はじめに

1.1 研究の背景と目的

近年の web 技術の発達により，SNS などによる時間的，空間的に離れたユーザーが情報を共有できる web システムが生まれてきた．筆者らは，2012 年から現在にかけて，web 技術を活用し，議論を支援する合意形成支援システム COLLAGREE（以下，支援システム）の開発および検証実験をおこなってきた[伊美 15, 伊藤 17, 西田 18]．しかし，500 人を超える大規模社会実験の実施は困難であるため，その規模における支援システムの検証はされていない．

一方，都市や地域の魅力を高めるために，固有の資源を活用したプレイス・ブランディングが注目されている[内木 11]．プレイス・ブランディングでは，都市や地域が対象となるため，様々なステークホルダーが関わる．そのため，ステークホルダー間の合意形成ができるかどうかが重要である[佐々木 08]．合意形成の場として，ワークショップが有効と明らかにされている[錦澤 00]．しかし，ワークショップの実施には，人的，時間的，空間的な制約があるため，多数の市民が参加することは困難である．

そこで，本研究では名古屋市におけるプレイス・ブランディングに支援システムを用いた大規模社会実験をおこなう．この実験により，実社会の大規模議論における支援システムの効果と課題について検証することを，本研究の目的とする．

1.2 本研究の位置付け

市民の参加による支援システムを用いた研究として，インターネット上のタウンミーティングを実施した既報がある[伊美 15]．この研究では，支援システムを用いたことにより，様々な年代の市民を集めることができた．プレイス・ブランディングについての研究として，名古屋駅周辺地区を対象とした空間資源の評価と構造を明らかにした既報がある[内木 11]．この研究では，来訪者の評価から既存の空間資源を活かすことの重要性を明らかにした．これらを踏まえ，本研究では様々な年代の市民が参加できる支援システムと都市固有の資源に着目し，研究を深めていく．

Web ベースのシステムを用いて市民が議論に参加する研究がある[Mahmoud 11]．この研究では，バーチャルリアリティを用いて意見を提供し，参加者同士の情報共有をおこなっている．しかし，評価実験の参加者が 20 人であるため，本研究が目指す大規模議論を対象としていない．

連絡先：西田智裕，名古屋工業大学コレクティブインテリジェンス研究所，名古屋市昭和区御器所町，052-735-7269，nishida.tomohiro@nitech.ac.jp



図 1　支援システムにおける画面の一部

以上より，本研究の意義は，議論の把握と参加者の心理評価から検証をおこなうことにより，実社会の大規模社会実験における支援システムの効果と課題を明らかにすることである．

2. 合意形成支援システムの概要

本研究で扱った支援システムにおける画面の一部を図 1 に示す．画面上部に投稿欄，画面左側に参加者が投稿されたコメント一覧が時系列に表示され，投稿には返信コメントをつけることができる．また，画面右側には議論を支援する「議論ポイント機能」と「キーワード表示機能」が配置されている．さらに，投稿の並び替えや絞り込みにより議論把握を支援する機能として「論点タグ」がある．支援システムに搭載した機能の詳細を表 1 に示す．

議論を円滑に進行し，合意形成に向けて深い議論がなされるよう調整する役割としてファシリテータが 1 名参加する．ファシリテータは，議論に対して中立的な立場を保ちながら議論を進行する役割を果たす．また，議論は「発散フェイズ」「収束フェイ

表 1　支援システムに搭載した機能

システム機能	内容
(1)画像の添付機能	投稿するときに，画像を添付することができる機能．
(2)論点タグ機能	投稿するときに，論点タグをつけることで，投稿一覧の並び替えや絞り込みがおこなえる機能．
(3)賛同ボタン機能	投稿されたコメントに対して，賛同を示すことができる機能．
(4)議論ポイント機能	議論の貢献度に応じて参加者がポイントを獲得できる機能．投稿数や他参加者からの返信コメント数、賛同数によってポイントが得られる．獲得したポイントのランキングを表示することで，議論の活性化を目指す．
(5)キーワード提示機能	議論中に，頻繁に出現したキーワードを表示する機能．
(6)賛成/反対表示機能	返信コメントをつけるときに，賛成/反対を表示できる機能
(7)議論ツリー機能	議論の返信関係をもとに，議論流れを自動で可視化する機能．参加者は，議論の全体像や論点が把握でき，議論内容の把握を支援することができる．ファシリテータの利点として，議論構造を共有することで，参加者の認識を統一することができる点がある．
(8)リマインドメール機能	自分の投稿に対する返信があった場合にメールにて通知する機能．

表 2　年代・性別毎の参加者一覧

性別	男		女	
年代	登録数	構成比	登録数	構成比
未入力	14	2.2%	3	1.5%
10代以下	15	2.4%	19	9.5%
20代	90	14.4%	42	21.1%
30代	145	23.3%	55	27.6%
40代	176	28.3%	46	23.1%
50代	131	21.0%	30	15.1%
60代	42	6.7%	4	2.0%
70代以上	10	1.6%	0	0.0%
合計	623	100%	199	100%

ズ」「評価フェイズ」に分かれており，ファシリテータが切り替え，議論を進める．「発散フェイズ」では，議論テーマに対して幅広く意見を集め，様々な可能性について検討をおこなう．「収束フェイズ」では，「発散フェイズ」で挙げられた意見について検討を重ねて絞り込んでいく．「評価フェイズ」では，これまでの議論を評価し，それらを集約させて合意案を決定する．

3. 調査概要

提案手法を検証するために，名古屋市のプレイス・ブランディングに向けて，web 上における大規模議論の社会実験を支援システムにより行った．プレイス・ブランディングには，地域や都市固有の資源を活用するため，議論テーマを「名古屋の魅力について」と設定した．議論へ様々なステークホルダーが参加できるように，参加者は公募により募った．また，議論途中からの参加も可能とした．議論期間は 2016 年 12 月 12 日から 2017 年 1 月 9 日まで行った．

参加者らは，「発散フェイズ」において，名古屋の魅力について，建物やイベントなど様々な意見を挙げた．「収束フェイズ」において，それら意見について地域内外へ展開する方法について議論した．「評価フェイズ」において，魅力と展開方法の意見について，参加者らが 1000 ポイントを 100 ポイント刻みで投資することにより評価し，その結果に基づいて合意案を決定した．

支援システムへの登録者数は 822 人，議論への投稿数は 1,327 件，閲覧数は 19,599 件であった．年代・性別毎の参加者一覧を表 2 に示す．

「論点タグ」は，名古屋市固有の資源など想定した 10 個を設定した．しかし，議論開始後すぐ住環境に関する投稿が「まちの魅力その他」として多く投稿された．そのため「都市環境」の論点タグを開始 5 時間後に追加した．開始 8 日後の議論において

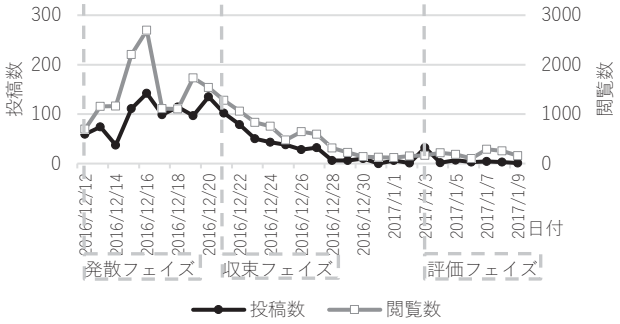


図 2　議論期間における投稿数と閲覧数

表 3　参加者毎の投稿数と閲覧数

	投稿数		閲覧数	
回数	人数	構成比	人数	構成比
0	619	75.3%	63	7.7%
1	86	10.5%	126	15.3%
2-10	89	10.8%	364	44.3%
11以上	28	3.4%	269	32.7%
合計	822	100%	822	100%

も「まちの魅力その他」を付与した投稿が多かったため，支援システムによるファシリテータ経験者 3 人で討論を行い，12 月 20 日に「観光，イベント，交通・インフラ，暮らし，情報発信」を追加した．

4. 調査結果

4.1 議論期間における投稿数と閲覧数

議論期間における投稿数と閲覧数を図 2 に示す．図 2 より，投稿数と閲覧数は「発散フェイズ」が多く，「収束フェイズ」では徐々に減少し，「評価フェイズ」では低い状態で推移したとわかる．

「発散フェイズ」では，各自が考えた魅力を自由に述べる段階であったので，投稿数と閲覧数が多くなったと推察される．「収束フェイズ」では，「発散フェイズ」において出された魅力の展開方法について議論する段階であった．そのため，ある程度の展開方法について意見が出ると議論することが無くなり，投稿数と閲覧数が時間経過と共に減っていったと考えられる．「評価フェイズ」では，評価結果が日々変動した．そのため，合意案の投稿が難しくなり，投稿数が少なくなったと推察される．

以上より，今回の実験では「発散フェイズ」は投稿しやすく，「収束フェイズ」では，議論することが無くなっていくとわかった．また「評価フェイズ」において，合意案を投稿することが難しいと明らかになった．

4.2 投稿数と閲覧数毎の分布

参加者毎の議論への参加傾向を検証するために，投稿数と閲覧数を分析する(表 3)．

表 3 より，投稿数の構成比 0 回が 75.3%である．これより，積極的に意見の投稿する参加者が少ないといえる．

投稿数の構成比 1 回が 10.5%，2-10 回が 10.8%，11 回以上が 3.4%である．これらより，参加者の 10.5%は 1 回，14.2%は複数回投稿する程度，議論へ興味があったといえる．また参加者の 3.4%は 11 回以上投稿している程度，議論へ興味があるといえる．

表 4　論点タグ毎の投稿数

設定日	論点タグ	新規投稿 出現数	新規投稿 構成比	返信投稿 出現数	返信投稿 構成比	合計 出現数	合計 構成比
2016/12/12	歴史・文化	176	20.5%	443	20.2%	619	20.3%
	ものづくり	46	5.4%	141	6.4%	187	6.1%
	デザイン都市なごや	45	5.2%	127	5.8%	172	5.6%
	環境首都なごや	12	1.4%	42	1.9%	54	1.8%
	なごやめし	48	5.6%	100	4.6%	148	4.9%
	まちの魅力その他	223	26.0%	579	26.5%	802	26.3%
	栄	27	3.1%	69	3.2%	96	3.1%
	名駅	33	3.8%	69	3.2%	102	3.3%
	名古屋港	14	1.6%	41	1.9%	55	1.8%
	エリアその他	60	7.0%	165	7.5%	225	7.4%
	都市環境	38	4.4%	106	4.8%	144	4.7%
2016/12/20	観光	47	5.5%	106	4.8%	153	5.0%
	イベント	29	3.4%	72	3.3%	101	3.3%
	交通・インフラ	11	1.3%	3	0.1%	14	0.5%
	暮らし	12	1.4%	41	1.9%	53	1.7%
	情報発信	38	4.4%	85	3.9%	123	4.0%
	合計	859	100%	2189	100%	3048	100%

閲覧数の構成比 1 回が 15.3%, 2-10 回が 44.3%, 11 回以上が 32.7%であった. これらより, 参加者の 77.0%は, 複数回閲覧する程度, 議論へ興味があったといえる. また 32.7%の参加者は 11 回以上閲覧している程度, 議論へ興味があるといえる.

以上より, 今回の実験では参加者の 77.0%が議論を複数回閲覧する興味があることがわかった. しかし, 参加者の 24.7%しか投稿しない課題があった.

4.3 論点タグ毎の投稿数

参加者が盛んに議論した論点を把握するために, 投稿を論点タグごとに集計する. 論点タグは, 新規スレッドを立てる際に複数選択できる. そのため, 返信投稿は, 親投稿に付いている論点タグを引き継ぐものとする. 論点タグ毎の投稿数を表 4 に示す.

表 4 より, 論点タグ構成比は「まちの魅力その他」が 26.3%と最も高い. これより, 投稿は予め設定した「歴史・文化」「ものづくり」などでない魅力についての議論が多いとわかる.

「歴史・文化」が 20.3%と高い. この論点タグが付与された議論内容は「名古屋城, 熱田神宮, 神社仏閣」などについてであった. これらより, 参加者らは「歴史・文化」を名古屋の魅力として多く議論していたといえる.

以上より, 今回の実験において予め設定した論点タグは「まちの魅力その他」の付与が多くなる課題が明らかとなった. しかし, 盛んに議論する対象であれば多く付与されることがわかった.

4.4 投資結果

投資機能は, 意見の重み付けを可視化することによる合意形成の支援を目的としている. そのため, 「評価フェイズ」において投資された結果を見ていく. 投資対象となる意見は, 以下の手順により決定した.

(1) 評価フェイズ前までの 2017 年 1 月 2 日 23 時 59 分 59 秒までの投稿を対象とした.

(2) 活発な議論を選ぶために, 全投稿から返信数の平均+標準偏差より返信数が多い(6 件以上)の意見を選択した.

(3) 議論方法に沿った意見を対象とするために, 魅力の展開に至っていない意見を取り除いた.

(4) 似た意見を統合するために, 内容が似ている意見を賛同数の高い方へ合流させた.

(5) 賛同が多い意見を対象とするために, 賛同数の上位 30 件を対象とした.

評価フェイズにおける投資結果と, 投資額合計との相関係数を表 5 に示す.

表 5 の投資額合計について, 帰無仮説を意見毎の投資額に差がないとして, カイ二乗検定を行ったところ 5%水準で有意であった. これより, 投資額に有意な差があり, 投資結果は, 参加者の意見を反映したものといえる.

表 5　評価フェイズにおける投資結果（投資人数：70 人）

順位	投資対象	投資額 合計	投資額毎の件数 100	200	300	400	500	600	700	800	900	1000	投資者 人数	投資者 割合	順位以上の投資者 人数	順位以上の投資者 割合
1	堀川をきれいにする	7,000	6	5	5	2	1	0	0	2	0	1	22	31.4%	22	31.4%
2	あおなみ線の電車・駅舎をレゴデザイン	5,400	8	4	3	1	3	0	0	0	0	1	20	28.6%	36	51.4%
3	熱田大山祭を再現	4,600	4	6	1	3	1	0	0	0	0	1	16	22.9%	43	61.4%
4	熱田神宮界隈に土産物屋を誘致	4,100	6	3	1	0	2	1	0	0	0	1	14	20.0%	50	71.4%
5	「サムライシティ名古屋」と名付ける	3,800	8	3	4	0	1	0	1	0	0	0	17	24.3%	57	81.4%
6	ピクトグラムを使った統一感のある案内看板	3,100	7	6	1	1	1	0	0	0	0	0	16	22.9%	58	82.9%
7	アニメ系のライブイベントを名古屋城で開催	2,900	12	2	1	0	0	0	0	0	0	1	16	22.9%	65	93%
7	工芸品のアンテナショップを名古屋駅に作る	2,900	12	0	2	0	1	1	0	0	0	0	16	22.9%		
9	「食・観光・歴史」マップとアプリの作成	2,700	10	3	2	0	1	0	0	0	0	0	16	22.9%	65	93%
10	フェアトレードを給食・学食を通して教育	2,600	6	2	2	0	0	0	0	0	0	1	11	15.7%	66	94%
11	名古屋城から広小路通に、なごやめし通り	2,200	6	5	2	0	0	0	0	0	0	0	13	18.6%	66	94%
12	地下鉄・市バスの駅・車内でイベント案内	2,100	7	0	3	0	1	0	0	0	0	0	11	15.7%	66	94%
12	シェアサイクルを導入	2,100	10	4	1	0	0	0	0	0	0	0	15	21.4%		
14	小中学生向け「名古屋の芸」体験	2,000	4	0	2	0	0	0	0	0	0	1	7	10.0%	69	99%
14	市民が街の良さについて、SNSなどで発信	2,000	7	1	2	0	1	0	0	0	0	0	11	15.7%		
14	神社・仏閣の御朱印を新たにデザイン	2,000	4	3	0	0	0	0	0	0	0	1	8	11.4%		
14	工場見学・社会科見学の外国人対応	2,000	13	2	1	0	0	0	0	0	0	0	16	22.9%		
18	東山動植物園　家族向けアピール	1,900	2	4	0	1	1	0	0	0	0	0	8	11.4%	69	99%
18	メーグル南ルートを新設	1,900	8	4	1	0	0	0	0	0	0	0	13	18.6%		
18	歴史や神話について、旅番組により紹介	1,900	12	2	1	0	0	0	0	0	0	0	15	21.4%		
21	市役所・県庁　来訪者向けオシャレ喫茶	1,600	8	1	2	0	0	0	0	0	0	0	11	15.7%	70	100%
21	市長により名古屋弁で魅力を発信	1,600	3	0	1	0	0	0	0	0	0	1	5	7.1%		
23	周辺の観光地HPと連携したイベント案内	1,500	8	2	1	0	0	0	0	0	0	0	11	15.7%	70	100%
24	侍・町人コスプレの人に割引サービス	1,400	5	3	1	0	0	0	0	0	0	0	9	12.9%	70	100%
25	「芸どころ」をブランド化して発信	900	5	2	0	0	0	0	0	0	0	0	7	10.0%	70	100%
25	地下鉄の駅で、地域のアート作品を展示	900	4	1	1	0	0	0	0	0	0	0	6	8.6%		
25	歴史や神話について、歩きながら説明	900	7	1	0	0	0	0	0	0	0	0	8	11.4%		
28	東山動植物園　映画撮影の誘致	700	3	2	0	0	0	0	0	0	0	0	5	7.1%	70	100%
28	駅駐輪場のデザインをカッコよくする	700	2	1	1	0	0	0	0	0	0	0	4	5.7%		
30	区役所モニターでイベント案内	600	1	0	0	0	1	0	0	0	0	0	2	2.9%	70	100%
	合計	70,000	198	72	42	8	15	2	1	2	0	9	349	100%	—	—

投資対象の該当順位とそれより順位の高い投資対象のいずれかに投資した人数を，順位以上の投資者人数と定義して分析をおこなう．例えば「3 位」であれば「1 位」「2 位」「3 位」のいずれかへ投資した人数である．表 5 より，「2 位」51.4%，「5 位」81.4%とわかる．これより，評価結果の上位に基づいて合意案を作成すると，多くの参加者による意見が反映されるといえる．

4.5 意識調査

提案手法の心理的な効果を検証するために，アンケート調査を行った．アンケート調査は，議論終了後にインターネット上のフォームにより行った．回答者は 41 人であった．アンケート調査の設問内容を表 6 に，その集計結果を図 3 に示す．設問[1]～[5]について，帰無仮説を選択肢毎に差がないとして，カイ二乗検定を行ったところ，全ての設問において 1%水準で有意であった．

表 6 と図 3 より，参加者らは，名古屋の魅力について Web 上で議論したことは良いと 92.7%が答え，今後も Web 上で議論したいと92.7%が答えた．また，参加者らは，議論により新しく名古屋の魅力に気付いたと 85.4%が答え，名古屋の魅力を，以前より感じるようになったと 85.4%が答えた．さらに，合意案に満足したと 78.0%が答えた．

以上より，プレイス・ブランディングに向けて，都市固有の資源などによる魅力やその展開方法について Web 上で議論することは，参加者に良いと思わせる効果があったといえる．また，参加者に新しい地域の魅力を気付かせる効果や，魅力を以前より感じさせる効果があることもわかった．さらに，投資結果の上位に基づいて作成した合意案を良いと思わせる効果があるとわかった．しかし，投資結果における下位の意見が合意案に含まれない課題があった．

5. まとめ

本研究で得られた知見を，以下にまとめる．

(1) 日毎の投稿数と閲覧数を分析して，今回の実験では「発散フェイズ」は投稿しやすく，「収束フェイズ」では，議論することが無くなっていくとわかった．また「評価フェイズ」において，合意案を投稿することが難しいと明らかになった．

(2) 今回の実験では参加者の 77.0%が議論を複数回閲覧する興味があるとわかった．しかし，投稿は参加者の 24.7%となる課題があった．

(3) 予め設定した論点タグは「まちの魅力その他」の付与が多くなる課題が明らかとなった．しかし，盛んに議論する対象であれば多く付与されることがわかった．

(4) 評価結果の上位に基づいて合意案を作成すると，多くの参加者による意見が反映されると明らかになった．

(5) プレイス・ブランディングに向けて Web 上で議論することは参加者に良いと思わせ，新しい地域の魅力を気付かせる効果や，以前より魅力を感じさせる効果があるとわかった．また，投資結果の上位に基づいて作成した合意案は良いと思わせる効果があるとわかった．

今後の課題として，意見や合意案について投稿しやすくなるように，議論の要約を可視化することがあげられる．また，論点タグを議論把握に活用できるように，ファシリテータは議論中に論点タグを整理する必要がある．さらに，投資結果において下位の意見が合意案に含まれるように，合意案を作成する方法を考案する必要がある．

表 6 アンケート調査の設問内容

設問内容
設問[1] 名古屋の魅力について Web 上で議論したことは良いですか．
設問[2] 今後も名古屋の魅力について Web 上で議論したいですか．
設問[3] 議論により新しく名古屋の魅力に気付きましたか．
設問[4] 議論により名古屋の魅力を，以前より感じるようになりましたか．
設問[5] 合意案に満足しましたか．

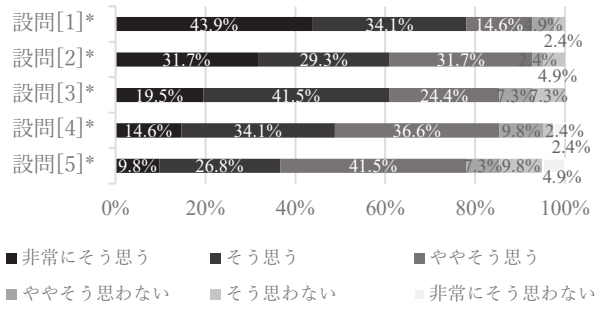


図 3 設問の集計結果 *:x^2 検定 $p<0.01$

将来の展望として，これらの課題を解決する議論の要約を可視化，論点の整理，合意案の作成について，合意形成支援エージェントによりおこなうことがあげられる．

謝辞 本研究の一部は科学技術振興機構戦略的創造研究推進事業（CREST:JPMJCR15E1）の援助を受けて実施したものである．

参考文献

[伊美 15] 伊美 裕麻, 伊藤 孝行, 伊藤 孝紀, 秀島 栄三:オンラインファシリテーション支援機構に基づく大規模意見集約システム COLLAGREE, 情報処理学会論文誌, Vol.56, No.10, 2015

[伊藤 17] 伊藤孝紀, 深町駿平, 杉山弓香, 西田智裕, 秀島栄三, 伊藤孝行: 合意形成支援システムを利用した域学連携手法の有効性, 日本建築学会計画系論文集, Vol. 82, No. 742, pp. 3169-3179, 2017

[西田 18] 西田智裕, 伊藤孝紀, 福島大地, 仙石晃久, 伊藤孝行: ワークショップにおける対面式と非対面式を組合せた手法の検証- まちづくりの社会実験を事例として-, デザイン学研究, Vol. 64, No. 4, 2018

[内木 11] 内木智草, 伊藤孝紀, 堀越哲美: プレイス・ブランディングにおける名古屋駅周辺地区の空間資源の評価と抽出, デザイン学研究, Vol. 58, No. 5, pp. 21-28, 2011

[佐々木 08] 佐々木純一郎, 石原慎士, 野崎道哉: 地域ブランドと地域経済-ブランド構築から地域産業連関分析まで, 同友館, 2008

[錦澤 00] 錦澤滋雄, 米野史健, 原科幸彦: まちづくりワークショップの合意形成機能に関する研究, 日本都市計画学会学術研究論文集, Vol. 35, pp.841-846, 2000

[Mahmoud 11] Hatem Mahmoud, Takafumi Arima: A Web-Based Public Participation System that Supports Decision Making, Architectural/Urban Planning and Design, Vol. 10, pp. 77-84, 2011

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

自律的ファシリテータエージェントのための内容とプロセスを考慮した議論文脈理解モデルの検討

A Consideration of Modeling Understanding of Discussion Context with Content and Process for Developing Autonomous Facilitator Agents

白松 俊 *1 Shun Shiramatsu　池田 雄人 *1 Yuto Ikeda　北川 晃 *1 Ko Kitagawa　幸浦 弘昂 *1 Hiroaki Koura　伊藤 孝行 *1 Takayuki Ito

*1名古屋工業大学 大学院工学研究科
Graduate School of Engineering, Nagoya Institute of Technology

We aim to develop autonomous facilitator agents as a novel technology for large-scale consensus building. In this paper, we consider a model for understanding discussion context that is needed for implementing autonomous facilitator agents. Our consideration consists of two viewpoints: (1) content and (2) process. (1) Content: Facilitator agents need to understand structure of argumentation (e.g., issues, ideas, evidences, and participants' interests). (2) Process: they also need to grasp the change of atmosphere among discussion participants (e.g., dynamics of group interaction and group sentiment). We formulate a model of discussion context from these viewpoints and discuss how to utilize the model for determining facilitators' actions and utterances.

1. はじめに

昨今，急激な人口減少や少子高齢化など，日本社会・地域社会の持続可能性を脅かす社会課題が多く顕在化しつつある．多様な利害関係者が協働して課題に立ち向かう上で，合意形成を支援する技術がこれまで以上に重要となる．特に，多様かつ大規模な数の利害関係者が参加する公共圏での議論には，Web インフラに基づくファシリテーション支援技術の開発が必要不可欠であると我々は考える．

近年，SNS やグループウェア，チャットツール等が広く普及しているが，大規模な合意形成のためのファシリテーション支援技術は未だ研究途上にある．そのため，実際に Web 上で大規模な合意形成を行う際には，議論進行上のリスク（停滞・炎上・逸脱・蒸し返し・認知バイアスなど）を防いだり，議論文脈理解の難しさによる途中参加の敷居を下げたりするために，多人数のファシリテータが大きな労力を払う必要がある．

本研究では，Web 議論システム COLLAGREE[伊美 15, Ito 14] の上で，人間のファシリテータと協調可能な自律的ファシリテータエージェントを開発することで，人間のファシリテータの労力を削減することを目指している．全自動のファシリテーション機構でなく，人間のファシリテータと協調可能なファシリテーション機構にすべき理由として，以下の 2 点が挙げられる．

- **参加者からの受容性を考慮した協調．**参加者の選好によっては，ファシリテータエージェントが全自動で提示した合意案集合を感情的に受容しない可能性が考えられる．そのような場合は，エージェントは補助的な役割に回り，人間のファシリテータを主とした方が良い．
- **エージェントの解析誤りリスク．**開発途上においては，やはり人間のファシリテータの方が議論文脈を理解する能力が高いはずである．そのため，解析精度が向上するまでは，全自動ではなく人間と協調した運用が現実的である．

また，そもそも最終的に合意や意思決定をする主体はファシリテータでなく人間の参加者なので，ファシリテータエージェントは本質的に人間との協調が不可欠である．

連絡先: 白松俊, 名古屋工業大学 大学院工学研究科情報工学専攻, 名古屋市昭和区御器所町, siramatu@nitech.ac.jp

ただし，将来的には人工知能技術に対する社会的受容性が向上する可能性が高い．その場合は，(充分な性能を達成できれば) 全自動でのファシリテータエージェント運用が受容される機会は増加するであろう．その場合でも，やはり最終的な合意や意思決定は人間の参加者に委ねられ，自律的エージェントの役割は飽くまでもファシリテーションであるので，人間との協調が発生する．

参加者に需要される充分な性能のファシリテータエージェントを実現するには，議論文脈の理解が必要不可欠である．人間のファシリテータも議論文脈を 100%理解できているとは限らないが，ある程度正確に理解できるファシリテータの方が参加者に受容される可能性が高いであろう．ここで，「議論文脈のどの部分をどの程度理解できれば，参加者に受容されるファシリテーションが可能になるのか？」というリサーチクエスチョンが生じてくる．

この課題を考える上で必須となるのが，「ファシリテータがどのように議論文脈を理解しているか」という理解モデルの定式化であり，本稿ではこのモデルを検討する．先行研究では，「ファシリテーターの役割は，内容に関するファシリテーションとプロセスに関するファシリテーションに分けられる」とされている [Miranda 99, Eden 90, 津村 15] ことから，議論文脈の理解モデルも，議論内容と議論プロセスに分けて定式化できると考えられる．

また，我々はこれまで Web 議論におけるファシリテータの発言の分析を行い，その結果として問いかけの重要性が示唆

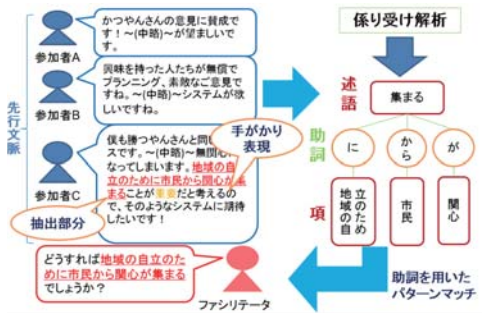


図 1: 表層的なパターンマッチによる掘り下げ質問の生成手法

された [Shiramatsu 16b, Shiramatsu 16a]．この結果を踏まえ，図 1 に示すような，ファシリテータエージェントの質問を表層的なパターンマッチにより生成する手法を開発してきた [Ikeda 17]．この手法でも 60%を超えるサンプルで被験者に許容される質問生成が可能であったが，同時に表層的処理の限界も顕著であった．つまり，内容理解の必要性が示唆された．本稿で検討する内容の理解モデルとプロセスの理解モデルは，ファシリテータエージェントの質問生成や行動決定の質を向上させるためにも，必要不可欠である．

2. 議論の場の定式化

「議論の場」を構成する要素は，内容とプロセスに共通して現れる．まずは，議論の場を以下のように定式化し，これらを用いて内容とプロセスの理解モデルを検討する．

- 議論の場: d.
- d の開始時刻と終了時刻: $start(d), end(d)$.
- 現在時刻: t.
- d の参加者 a_j の集合: $A(d) = \{a_j\}$.
- d が開始してから時刻 t までに述べられた発言 u_j の順序付き集合: $U(d,t) = \{u_j\}$.
- u が述べられた時刻: $time(u) \in [start(d), t]$.
- u の発言者: $s(u) \in A(d)$.
- a によって時刻 t までに述べられた発言 u_j の集合: $U(a,t) = \{u \in U(d,t) \mid s(u) = a\}$

議論内容のファシリテーションにも，議論プロセスのファシリテーションにも，議論文脈すなわち時間的な構造の変化を理解することが重要である．そのため，上記のように時刻 t を用いたモデル化が必要となる．

3. 議論内容の理解モデルの検討

議論内容のファシリテーションに必要な要件として，以下のような機能が挙げられる．

- 途中からの参加者にも，その時点で焦点になっている論点や案がわかるような情報提示
- 途中参加者にも，「これまでにどのような論点集合に対してどのような案が挙がってきたか」という概略的な構造が把握できるようにする情報提示
- 案に関する理解（利点・欠点など）を参加者間ですり合わせるための問いかけ

これらの要件を満たすためには，gIBIS[Conklin 88] や Deliberatorium [Klein 11] 等でも伝統的に採用されてきた，論点（課題）と案に関する課題解決構造の理解や可視化が必要となる．ファシリテータエージェントの内容理解は時刻 t 毎に更新されていくことを考慮すると，以下のような内容理解モデルが考えられる．

- 時刻 t までに d に現れた論点 i の集合: $I(d,t) = \{i\}$.
- 論点 i に関して時刻 t までに d に現れた案 s の集合: $S(d,t,i) = \{s\}$.
- 案 s が採用された場合に論点 i に及ぼす影響として可能性ある事象 e の集合: $E(s,i) = \{e\}$.
- 時刻 t までに論点 i に言及した発言の集合: $desc(i,t) \in U(d,t)$
- 時刻 t までに案 s に言及した発言の集合: $desc(s,t) \in U(d,t)$
- 時刻 t までに事象 e に言及した発言の集合: $desc(e,t) \in U(d,t)$
- 時刻 t における参加者 a による案 s への評価極性: $spol(a,s,t) \in [-1,1]$.

時刻 t までの議論内容の解析により，上記のような構造をエージェントが理解することができれば，案 s に関する質問生成や，質問を投げかける参加者の決定に利用できる可能性がある．現在，そのための訓練コーパスを構築し，自動解析手法を開発中である．

4. 議論プロセスの理解モデルの検討

議論プロセスのファシリテーションに必要な要件として，以下のような機能が挙げられる．

- 参加者間の協力・協調を促すことで，発散から収束，合意へと向かわせる働きかけ．
- 参加者間の発言の偏りを是正し，公平性を担保するための働きかけ．
- 炎上や蒸し返し，停滞といった議論進行上のリスクを検出・予防する働きかけ．

これまでの COLLAGREE でも，図 2 に示すように発散フェーズから収束フェーズへの移行を制御する機構が用意されていた [西田 智裕 17]．これは，インセンティブを与える「議論ポイント」のポイント計算方法をフェーズ毎に変えることで，フェーズに応じた発言を促すことを狙った機能である．



図 2: COLLAGREE における議論フェーズ機構

このような収束・合意へのフェーズ遷移を円滑化するには，参加者間の協力・協調関係を促す必要があり，参加者間の関係性の変化を理解する必要がある．これまで我々は，参加者集合 $A(d)$ 上で以下のパラメータがどう分布し，どう変化するかをモデル化することで，以下のような「議論の場の空気」のモデル化を試みてきた [白松 17]．

- 議論 d における時刻 t 時点の発言者: $turn(d,t) \in A(d)$.
- 時刻 t 時点までに，参加者 a_1 の発言の直後に a_2 が発言した確率 (割合)：$p(a_2|a_1,t)$

- t 時点までに，a が発言した確率 (割合): $urt(a,t) = \frac{|U(a,t)|}{|U(d,t)|}$.
- t 時点での議論 d の盛り上がりの度合: $actv(d,t)$.
- その時点の議論文脈上での発言 u の話題変化度: $shift(u)$.
- 発言 u の発話行為の種別: $spact(u)$.
- u に現れている感情の種別: $senti(u)$.
- u の感情極性: $spol(u) \in [-1,1]$.
- t 時点での参加者 a の感情極性: $spol(a,t) \in [-1,1]$.
- t 時点での a による案 s への評価極性: $spol(a,s,t) \in [-1,1]$. (再掲)
- t 時点で a_1 が感じる a_2 に対する感情極性: $spol(a_1,a_2,t) \in [-1,1]$.
- t 時点で a が緊張/弛緩しているかという極性: $tpol(a,t) \in [-1,1]$
- u に対する a の傾聴の度合: $lisn(a,u) \in [-1,1]$.
- t 時点までに a_1 が a_2 の発言を傾聴していた度合: $lisn(a_1,a_2) \in [-1,1]$.

これらのパラメータの分布は参加者の関係性を表現するものであり，議論プロセスの理解に必要となる．

上記のモデルには非言語的あるいはパラ言語的な振る舞いが深く関係しているため，それらを含まない Web 議論での推定が難しいものも含まれている．しかし，例えばターンテイキングに関するパラメータ（$turn(d,t)$, $p(a_2|a_1,t)$ など）の分布は比較的容易に推定できる．これらのパラメータだけでも，例えば発言者の偏りを是正するといったファシリテーション行動の生成に利用可能である．

本研究では，まずは対面の議論で上記パラメータ群と言語表現の関係を分析し，その知見を Web 議論にも適用する可能性を検討している．対面の議論の言語表現と Web 議論の言語表現には確かに違いがあるが，共通する傾向も存在する可能性がある．そのために本研究では，マイクロフォンアレイ TAMAGO-03, 音源分離・定位システム HARK, ハイラブル社による議論評価サービス DAS[水本 17], 基本周波数解析ツール REAPER, 脳波計 Emotiv EPOC+, モーションセンサーカメラ RealSense 3D 等の各種センサー群を用い，対面の議論のマルチモーダルコーパスを構築中である [白松 17]．特に議論評価サービス DAS は，図 3 に示すような $p(a_2|a_1,t)$ の可視化機能を持ち，ターンテイキングの偏りを是正するためのパラメータ推定に有用である．

5. おわりに

本稿では，議論ファシリテータエージェントの実装のために必要な議論文脈理解モデルとして，議論内容の理解モデルと，議論プロセスの理解モデルを検討した．まず共通する要素として，「議論の場」に関するパラメータを定式化した．ファシリテーションにおいては構造の時間変化が重要なため，時刻 t を重視した定式化を提案した．

議論内容の理解においては，gIBIS や Deliberatorium 等で伝統的に用いられているような，論点（課題）と案から成る課題解決構造が必要と考え，時刻 t を重視した定式化を検討した．また，議論プロセスの理解においては，参加者の関係性変化や「場の空気」に関するパラメータの定式化について述べた．

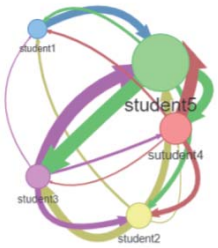


図 3: 議論評価サービス DAS による発言遷移確率 $p(a_2|a_1,t)$ の可視化

議論内容の構造についても，議論プロセスの構造についても，今後コーパスを整備して解析手法を開発する．また，各パラメータの推定結果を活用したファシリテータエージェントの問いかけ・働きかけ行動の生成手法を開発し，Web 議論や対面の議論の評価実験で検証していく予定である．

謝辞本研究の一部は，JST CREST (No. JPMJCR15E1) および JSPS 科研費 基盤研究 (C) (No. 17K00461) の支援を受けたものです．

参考文献

[Conklin 88] Conklin, J. and Begeman, M. L.: gIBIS: A hypertext tool for exploratory policy discussion, *ACM Transactions on Information Systems (TOIS)*, Vol. 6, No. 4, pp. 303–331 (1988)

[Eden 90] Eden, C.: *The unfolding nature of group decision support: Two dimensions of skill*, pp. 48–52, SAGE Publications (1990)

[Ikeda 17] Ikeda, Y. and Shiramatsu, S.: Generating Questions Asked by Facilitator Agents Using Preceding Context in Web-based Discussion, in *Proceedings of the 2nd IEEE International conference on Agents*, pp. 127–132 (2017)

[Ito 14] Ito, T., Imi, Y., Ito, T., and Hideshima, E.: COLLAGREE: A faciliator-mediated largescale consensus support system, in *Collective Intelligence 2014* (2014)

[Klein 11] Klein, M.: How to harvest collective wisdom on complex problems: An introduction to the mit deliberatorium, *Center for Collective Intelligence working paper* (2011)

[Miranda 99] Miranda, S. M. and Bostrom, R. P.: Meeting facilitation: process versus content interventions, *Journal of Management Information Systems*, Vol. 15, No. 4, pp. 89–114 (1999)

[Shiramatsu 16a] Shiramatsu, S. and Ikeda, Y.: An Approach to Discussion Facilitators' Action Selection based on Expected Utility Calculated with Random Forest Regression, in *Proceedings of the 2016 International Conference on Crowd Science and Engineering*, pp. 1–6 (2016)

[Shiramatsu 16b] Shiramatsu, S., Nishida, T., Ito, T., and Fujita, K.: Feature Expression Extraction from Discussion Facilitators' Utterances in Web-based Forum System towards Autonomous Facilitator Agents, in *Proceedings of the 5th IIAI International Congress on Advanced Applied Informatics*, pp. 687–691 (2016)

[伊美 15] 伊美裕麻, 伊藤孝行, 伊藤孝紀, 秀島栄三 他：オンラインファシリテーション支援機構に基づく大規模意見集約システム COLLAGREE–名古屋市次期総合計画のための市民議論に向けた社会実装, 情報処理学会論文誌, Vol. 56, No. 10, pp. 1996–2010 (2015)

[水本 17] 水本武志：音環境分析に基づく議論評価サービスとその応用可能性, 人工知能学会第 2 回市民共創知研究会「みらいらぼ つしま」予稿集, pp. SIG–CCI–002–04 (2017)

[西田 智裕 17] 西田 智裕 他：連続ワークショップに合意形成支援システムを用いた効果検証（まちづくりの社会実験を事例として）, 情報処理学会 研究報告知能システム（ICS）, Vol. 2016-ICS-185, No. 9 (2017)

[津村 15] 津村俊充：グループプロセスに焦点をあてたファシリテーションを学ぶ研修をデザインする, 人間関係研究 (南山大学人間関係研究センター紀要), No. 14, pp. 102–132 (2015)

[白松 17] 白松俊, 北川晃, 幸浦弘昂, 熊崎滉大：議論参加者の行動センシングに基づく場の空気の自動推定に向けた検討, 人工知能学会 第 3 回市民共創知研究会「みらいらぼ なごや」予稿集, pp. SIG–CCI–003–09 (2017)

Oral presentation | Organized Session | [Organized Session] OS-28

[1D3-OS-28b] [Organized Session] OS-28

Tue. Jun 5, 2018 5:20 PM - 7:00 PM Room D (4F Cattleya)

[1D3-OS-28b-01] A Topic Change Judgment Method based on Distributed Representation for Facilitator Support

○Kai Yoshino[1], Takayuki Ito[1] （1. Nagoya Institute of Technology）

5:20 PM - 5:40 PM

[1D3-OS-28b-02] Strategyproof and Fair Matching Mechanism for Union of Symmetric M-convex Constraints

Yuzhe Zhang[1], ○Kentaro Yahiro[1], Nathanael Barrot[2], Makoto Yokoo[1] （1. Graduate School of Information Science and Electrical Engineering, Kyushu University, 2. RIKEN, Center for Advanced Intelligence Project AIP）

5:40 PM - 6:00 PM

[1D3-OS-28b-03] Analysis of Equilibria and Reverse Phenomenon in Two-player All-pay Auction with Asymmetric Information

Tooru Akagi[1], ○Taiki Todo[1], Makoto Yokoo[1] （1. Kyushu University）

6:00 PM - 6:20 PM

[1D3-OS-28b-04] Modeling Multiple Tasks by the Response Threshold Model in Evacuation Simulation

○Akira Tsurushima[1] （1. SECOM CO., LTD.）

6:20 PM - 6:40 PM

[1D3-OS-28b-05] A Cloud-based Argumentation Process Repository using LOD for Consensus Building Knowledge Base -- A Preliminary Report

○Naoki Fukuta[1] （1. Shizuoka University）

6:40 PM - 7:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

ファシリテーター支援を目的としての分散表現を用いた話題変化判定

Topic change judgment using distributed representation for facilitator assistance

芳野 魁[*1]
Kai Yoshino

伊藤 孝行[*1]
Takayuki Ito

[*1] 名古屋工業大学大学院 情報工学専攻
Nagoya Institute of Technology, Department of Computer Science

In order to reduce the burden on the facilitator in the large-scale opinion concentration system COLLAGREE, we propose a topic change judgment method using distributed representation. The proposed method extracts important words from utterances using extractive summaries and calculates similarities between utterances using distributed expressions. Experimental results show that the proposed method has higher performance than the comparative method and word extraction contributes to performance improvement.

1. はじめに

近年, Web 上での大規模な議論活動が活発になっている. 一般的には"5 ちゃんねる(旧 2 ちゃんねる)" や"Twitter" といったシステムが使われている. しかし, 既存のシステムでは議論の整理や収束を行うことが困難である. Web 上での大規模合意形成を実現するために, 伊藤孝行研究室は過去に大規模意見集約システム COLLAGREE を開発した[伊藤 et al., 2015]. COLLAGREE は自由に意見を投稿や返信することができる掲示板のような議論プラットフォームをベースにしている. また, 他のシステムで議論の整理や収束を行うことが困難であった原因として議論の管理を行う者がいないことが挙げられる. 前述の問題に対応するため, COLLAGREE ではファシリテーターによる適切な議論プロセスの進行を行っている. しかし, 長時間に渡って大人数での議論における話題動向をマネジメントし続けるのは困難である.

そして, 分散表現は自然言語処理の分野において多くの研究で使われている. 分散表現は単語の共起頻度に基いて類似度を計算しているため, 同じ文脈で出現することの多い対義語に対応できない点が弱点とされる. しかし, 議論中の話題においては対義語かどうかは関係なく同じテーマ(話題)に沿っているかが重要である. 分散表現における類似度計算は議論における話題の繋がりと似ているため, 分散表現の対義語にできないというデメリットを無視して話題変化判定ができると考えられる.

そこで本研究では分散表現を用いて自動的な話題変化判定を目指す. 本研究の目的はファシリテーターの代わりに議論中の話題変化を判定することである.

2. 関連研究

2.1 COLLAGREE

(1) 概要

COLLAGREE は各ユーザーが自由なタイミングで意見を投稿や返信することのできる掲示板のような議論プラットフォームをベースにしている. 図 1 に COLLAGREE での実際の議論画面を示す. COLLAGREE のような議論掲示板は基本的には1つの議論テーマに対して関連するテーマを扱った複数のスレッドから構成される. スレッドとはある特定の話題・論点に関する1つのまとまりを指す.



図 1:COLLAGREE の議論画面

(2) ファシリテーター

COLLAGREE ではファシリテーターと呼ばれる人物が議論のマネジメントを行っている.

ファシリテーターは議論そのものには参加せずにあくまで中立的な立場から活動の支援を行うため, 自分の意見を述べたり自ら意思決定をすることはない.

連絡先:芳野魁 yoshino.kai@itolab.nitech.ac.jp

ファシリテーターの基本的な役割として"議論の内容の整理", "議論の脱線防止", "意見の促し"等が挙げられる.

ファシリテーターが様々な論点に対する発言を促すことによって議論が発散するため, 十分な議論が行われる.

ファシリテーターの存在や手腕が合意形成に強く影響を与えることや Web 上での議論においてファシリテーターが有用であることが示されている[田中 et al., 2015][伊美 et al., 2015].

2.2 話題遷移検出

話題の遷移に基づいた文章の分割が主に人間によるテキスト全体の内容把握を容易にすることや複数のテキストに対する自動分類や検索精度向上を主な目的として研究されている.

別所ら[別所 et al., 2001]は単語の共起頻度行列を特異値分解で次元を削減して作成した単語の概念ベクトルと TextTiling[Hearst, 1997]を用いてトピック変化点を検出し, 連結された新聞記事を元の形になるように分割をする実験を行っている.

本研究と別所らの研究は両研究とも文字列間の類似度を話題に基いて計算している点で関連している. しかし, TextTiling はグラフ全体の中からブロック(複数の単語を連結したもの)間類似度の小さい地点から分割を行うため, 分割する地点よりも未来の情報を使っている. 故に, リアルタイムな議論での動作には適さない. 本研究は分割する地点よりも未来の情報を使うこと無く話題変化を判定する.

3. 話題変化判定システム

3.1 システム動作の流れ

Algorithm1 を用いて話題変化判定システムの動作の流れについて説明する. 本システムでは話題の変化は発言 R と過去の発言の集合である PG の比較によって判定する.

Algorithm 1 話題変化判定システムの流れ

```
1:  Input : 発言 R
2:  Output : 通知判定 Notify
3:  P G = 過去の発言の集合;
4:  procedure topicChange(R)
5:      SG = {};
6:      update(R)
7:      for Each pastR∈ PG do
8:          sim = similarity(R, pastR)
9:          if sim > threshold then
10:             SG.append(pastR)
11:             Notify = False
12:         if  SG = {} then
13:             Notify = True
14:     return Notify
```

最初に, 新しく投稿された発言 R で使われている単語の情報を 4 章で説明する重み付けで用いるために単語の出現回数等の更新を行う(6 行目). そして, PG に含まれる過去の発言と R の類似度を計算し(8 行目), 類似度が閾値を超えていた場合, 同じ話題である発言集合 SG に比較した 2 発言の話題が同じであるとして登録する(9~10 行目). 全ての比較が終了した後 SG が空集合である, すなわち発言 R と同じ話題である発言がない場合, 話題を変化させる発言であると判定する.

3.2 話題変化判定

発言間の類似度計算は次の3段階で行われる.

(1) 前処理

発言内容の類似度計算の精度を上昇させるために, 本研究では前処理としてストップワードの除去や単語の重み付けを行う. 前処理の詳細については 4 章で述べる.

(2) 発言内容の類似度計算

前処理の情報や分散表現を用いて発言内容文の類似度計算を行う. 文章間の類似度計算の手法については 4 章で詳しく述べる.

(3) 総合類似度計算

計算された発言の文章間の類似度に発言間の時間差と返信関係を組み合わせることで総合類似度を求める. 時間差評価値は式(1)に示すように, 発言間の投稿時間差を最大時間差で割り 1 から引くことで時間差評価値 $tValue$ は 0 から 1 の範囲となる. 2 発言間の時間差が小さいほど関連が強いとみなされて 1 に近くなる.

$$tValue = 1 - \frac{new.created - old.created}{maxTime} \quad (1)$$

$maxTime$は最大時間差を表す数値である. $maxTime$は基本的に議論の制限時間を用いる. $x.created$は発言xが投稿された時間を表す. 総合類似度に時間差評価値を導入して時間的に近いものほど総合類似度を上昇させることで, 議論が基本的に少し前に発言に関連して進行されることが多いという点を考慮した. 具体的には式(2)のように計算される.

$$total = tValue * tWeight + sim * (1 - tWeight) \quad (2)$$

$time$, simはそれぞれ時間差評価値と発言内容の類似度を表す. $tWeight$は時間差評価値の重みを示す. $tWeight$は 0 から 1 の値を取る. また, 2 発言が同じスレッドに属していた場合は何らかの関連があると考えられる. 故に, 2 発言が同じスレッドに属していた場合は時間差評価値を無視し, 発言内容の類似度に補正値を加えたものを総合類似度とした.

4. 話題変化判定システム

4.1 ストップワード除去

分散表現による類似度計算で精度を上昇させるためには発言内容から余分な単語を取り除き重要な単語を抽出するか極めて短く要約することが重要である. 本研究では形態素解析エンジン MeCab による形態素解析の結果, 次の条件を満たす単語を除外した.

1. 品詞細分類に「数」を含む
2. 「読み」, 「発音」が不明である
3. 品詞が「助詞」, 「助動詞」, 「記号」, 「連体詞」のどれかである.
4. 1 文字のひらがなである
5. 品詞細分類に「接尾」または「非自立」を含む

4.2 重み付け

提案手法ではokapiBM25[Robertson, 1995]とLexRank[Erkan, 2004]の2種類の重み付け手法を統合して発言文章中の単語に対して重み付けを行う. アルゴリズムを **Algorithm2** に示す.

Algorithm 2 統合重みの計算アルゴリズム

```
1:  Input : remark
2:  Output : combinedWeight
3:  Array sentList;
4:  procedure calcCombinedWeight(reamrk):
5:    bm25Weight = calcBM25Weight(remark)
6:    for Each sent ∈ remark do
7:      sentList.append(sent)
8:    lexWeight = calcLexRank(sentList)
9:    for Each word ∈ bm25Weight.keys() do
10:     wordWeight = bm25Weight[word]
11:     if word is 固有名詞 then
12:       wordWeight *=4
13:     sentWeight = 0
14:     for Each sent ∈ remark do
15:       if word in sent then
16:         sentWeight+=lexWeight[sent]
17:     combinedWeight[word] = Weight*sentWeight
18:   return combinedWeight
```

$remark$は発言内容の文字列を意味し, $combinedWeight$は $remark$ 中の単語と重みを対応付けた連想配列を表す. $sentList$ には重み付けを行った最大 n 個前までの文章が入る. $remark$を句点, 改行コードで$sent$に分割する(6 行目). 本研究において固有名詞は文章の中で重要な役割を果たす可能性が大きいと考えたため, 固有名詞の単語重みを 4 倍にしている. (12行目). wordを含む全文章の重みの合計を求める(14~16行目). そして, okapiBM25 による単語重みを掛け合わせたものをwordの統合重みとしている(17 行目).

単語重みに単語を含む文章の重みを掛け合わせることで感動詞のような単語を含む文章そのものは重要でないが, 重要性が高いと判断されてしまう単語が選ばれる可能性を下げている.

4.3 重み付け

本研究では計算された単語重みの上位 n 個までの単語を発言文章$remark$において重要度の高い単語であるとして抽出する. それぞれの発言から抽出された単語を分散表現を用いて単語をベクトルに変換した後, 平均ベクトルの Cosine 類似度を取ることで発言文章間の類似度としている. 本研究では分散表現として fastText[Bojanowski et al., 2016]を用いる.

5. 評価実験

5.1 実験設定

評価実験では COLLAGREE 上で行われた議論時間 90 分の 2〜3 名による複数の議論データを用意し, 提案手法と比較手法で実験を行う. 結果として提案手法のほうが分散表現を用いていることで良い精度を出せるか確認する. 議論データに対し, 次に述べる基準で学生にアノテーションを行ってもらった.

1. それまで話題となっていた対象や事態とは異なる, 新しい対象や事態への言及する発言
2. 既に言及された対象や事態の異なる側面へ言及する発言
3. 議論のフェーズを移行させる(可能性の高い)発言
4. ファシリテーターによる議論をコントロールする様な発言

過半数のアノテーション担当者が基準を満たすと判断した発言を話題変化発言とした. また, 比較手法として以下に述べる3つを用いた.

- [比較手法 1]:常に話題変化発言として判定する
- [比較手法 2] : 発言文章を TF-IDF による単語の重みを用いてベクトル化したものを fastText の代わりに用いる
- [比較手法 3] : 発言文章を LDA を用いてトピックベクトル化したものを fastText の代わりに用いる

提案手法1ではパラメーターは次の通りに設定した. 前処理にて用いる okapiBM25 のパラメーターは$k_1=2, b=0.75$とし, LexRank では 50 個前までの文を用いた. また, 重み付けを用いて文章から抽出する単語の数は 5 個とした. fastText は次元数を100次元とし, 学習データにはwikipediaダンプデータを用いた. 提案手法2では単語抽出を行わずに文章中の全単語の平均ベクトルで内積を取る. 式(2)の$tWeight$は 0.5 とし, 総合類似度の閾値は 0.8 とした.

評価指標として適合率 (Precision), 再現率 (Recall), F 値 (F-measure) の 3 種類の指標を用いる.

5.2 実験結果

実験結果として各手法の F 値を表 1 に示す. 各手法の再現率と適合率及び 2 つの値の差を表 2 に示す.

手法	F-measure
比較手法 1 (常に予測値=1)	0.404
比較手法 2 (TF-IDF ベクトル)	0.487
比較手法 3 (LDA ベクトル)	0.385
提案手法 1 (単語抽出あり)	0.515
提案手法 2 (単語抽出なし)	0.086

表 1:実験結果 1

手法	平均評価指標		
	Precision	Recall	Difference
比較手法 1 (常に予測値=1)	0.257	1	0.404
比較手法 2 (TF-IDF ベクトル)	0.489	0.558	0.069
比較手法 3 (LDA ベクトル)	0.573	0.317	0.256
提案手法 1 (単語抽出あり)	0.515	0.552	0.037
提案手法 2 (単語抽出なし)	0.833	0.046	0.787

表 2:実験結果 2

表 1 が示すように, 提案手法 1 は他のどの手法よりも高い F 値を出している. 一方で, 表 2 が示すように, 提案手法では再現率と適合率の間の差が 0.037 で最も小さくなっている. 以上から, 適合率と再現率のバランスが最も良かったことが他の手法よりも高い F 値に繋がったと思われる.

また, 表 1 が示すように, 提案手法 1 は提案手法 2 よりも高い F 値を出している. 一方で, 表 2 が示すように提案手法 2 は非常に高い適合率を示すと同時に, 非常に低い再現率を示している. 提案手法 1 と提案手法 2 の間の違いは単語抽出を行うかどうかだけなので結果に影響を与えたのは明らかに単語抽出である. 単語抽出が結果に影響を与えた理由として, 単語抽出によって平均を取る単語ベクトルの数が減ったことが考えられる. すなわち, 平均を取る単語ベクトルの数が多くなることで単語に関係なく結果的に平均ベクトルが全て似たようなものとなったため, 発言の平均ベクトルの差が小さくなってしまったと想定できる.

6. おわりに

本研究ではファシリテーターの負担を軽減するために, 分散表現を用いて自動的に話題の変化を判定する手法を提案した. COLLAGREE 上で行われた議論のデータを対象にした提案手法の評価実験の結果, 提案手法が比較手法よりも高い精度で話題変化を判定できることが確認できた. しかし, 本研究では実際の議論においてのファシリテーターによる評価が行われていない. また, 現在の状態では提案手法の適合率は高いとは言えない. 原因としては常に適切な単語抽出を行うのは困難であることが考えられる.

したがって, 今後の課題として COLLAGREE での実装及び実証実験を行うことが挙げられる. また, 単語抽出の精度を上昇させること, もしくは, Word Mover's Distance[Kusner et al., 2015] の様な単語抽出を行わない手法への変更を行うことが挙げられる.

参考文献

[伊藤 et al., 2015] 伊藤孝行, et al. ”多人数ワークショップのための意見集約支援システム collagree の試作と評価実験”. 日本経営工学会論文誌, pp83-108, 2015.

[田中 et al., 2015] 田中恵, 伊藤孝紀, 伊藤孝行, 秀島栄三. ”ファシリテー タに着目した合意形成支援システムの検証と評価”. デザイン学研究, pp. 67–76, 2015.

[伊美 et al., 2015] 伊美裕麻, 伊藤孝行, 伊藤孝紀, 秀島栄三. “オンラインファシリテーション支援機構に基づく大規模意見集約システム collagree ―名古屋市次期総合計画のための市民議論に向けた社会実装”, 情報処理学会論文誌, Vol. 56, No. 10, pp. 1996–2010, 2015.

[別所 et al., 2001] 別所克人, et al. “単語の概念ベクトルを用いたテキストセ グメンテーション". 情報処理学会論文誌, Vol. 42, No. 11, pp. 2650–2662, 2001.

[Hearst, 1997] Marti A Hearst. “Texttiling: Segmenting text into multi-paragraph subtopic passages.” Computational linguistics, Vol. 23, No. 1, pp. 33–64, 1997.

[Robertson, 1995] Stephen E Robertson, Steve Walker, Susan Jones, Micheline M Hancock-Beaulieu, Mike Gatford, et al. Okapi at trec-3. Nist Special Publication Sp, Vol. 109, p. 109, 1995.

[Erkan, 2004] Gunes Erkan and Dragomir R. Radev. ”lexrank: Graph-based lexical centrality as salience in text sum- marization”. Journal of Artificial Intel ligence Re- search, pp. 457–479, 2004.

[Bojanowski et al., 2016] Bojanowski and Piotr et al. ”enriching word vec- tors with subword information”. arXiv preprint arXiv:1607.04606, 2016.

[Kusner et al., 2015] Matt Kusner, Yu Sun, Nicholas Kolkin, and Kilian Weinberger. From word embeddings to document distances. In International Conference on Machine Learning, pp. 957–966, 2015.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

対称性を満たすM凸集合の和集合で表現される制約を扱うマッチングメカニズムの提案

Strategyproof and Fair Matching Mechanism for Union of Symmetric M-convex Constraints

張 語哲 *1 Yuzhe Zhang　八尋 健太郎 *1 Kentaro Yahiro　Nathanaël Barrot*2　横尾 真 *1 Makoto Yokoo

*1九州大学 大学院システム情報科学府
Graduate School of Information Science and Electrical Engineering, Kyushu University

*2理化学研究所 革新知能統合研究センター AIP
RIKEN, Center for Advanced Intelligence Project AIP

In this paper, we identify a new class of distributional constraints defined as a union of symmetric M-convex sets, which can represent a variety of real-life constraints in two-sided matching settings. Since M-convexity is not closed under union, a union of symmetric M-convex sets does not belong to this well-behaved class of constraints in general. Thus, developing a fair and strategyproof mechanism that can handle this class is challenging. We present a novel mechanism called Quota Reduction Deferred Acceptance (QRDA), which repeatedly applies the standard DA mechanism by sequentially reducing artificially introduced maximum quotas. We show that QRDA is fair and strategyproof when handling a union of symmetric M-convex sets. Furthermore, in comparison to a baseline mechanism called Artificial Cap Deferred Acceptance (ACDA), QRDA always obtains a weakly better matching for students, and, experimentally, performs better in terms of nonwastefulness.

1. 序論

マッチング理論は，学生と学校，研修医と病院といった二種類のエージェントを適切に割り当てる問題として広く論じられている．マッチング理論において通常扱われる市場は，最大の容量を用いた個別上限制約により定義される．しかしながら，マッチング問題が取り扱うべき現実問題の多くは，学校の集合に割り当てられる学生数を制限する地域上限制約，一定数の学生が割り当てられることを各学校に保証する個別下限制約，異なるタイプの学生 (SES に基づくことが多い) を各学校に割り当てる学生数の分散に関する制約といった多種多様な制約が付与されている場合が通常である．

一対一マッチングにおける安定性は Gale と Shapley により提唱された [Gale 62]．しかしながら，一般に安定マッチングが存在しない場合も知られている．ゆえに，安定性を公平性，非浪費性と呼ばれる二つの性質に分割する考え方が一般的である．本論文では，公平性を満たした上で，可能な限り非浪費性を満たすことを目的とする．既定の上限を用いて動作する基準メカニズム Artificial Cap Deferred Acceptance メカニズム (ACDA) は，公平性，戦略的操作不可能性を満たすが，非浪費性の観点で効率的でないことが知られている．戦略的操作不可能性は，どの学生も自身の選好を偽るインセンティブを持たないことを保証する性質である．

既存研究において，実現可能な割当の集合が M 凸集合と呼ばれる概念で表現できるとき，DA に基づくメカニズムである generalized DA は，公平性，戦略的操作不可能性を満たすことが知られている [Kojima 14]．よって，公平性，戦略的操作不可能性を満たし，M 凸集合より広い制約のクラスを扱うメカニズムの考察は理論的に意義のある課題である．

本論文では，対称性を満たす M 凸集合の和集合で表現される制約を新たに導入する．この制約は，M 凸集合より広い制約であり，現実のマッチング問題に幅広く応用できる制約である．凸性は和集合について閉じていないので，対称性を満たす M 凸集合の和集合は一般に M 凸集合ではない．

我々の知る限り，M 凸集合より広い制約下において公平性，戦略的操作不可能性を満たすメカニズムを考察した既存研究は存在しない．そこで，人為的に定められた上限を段階的に減少させながら，Deferred Acceptance メカニズム (DA) [Gale 62] を繰り返し適用する Quota Reduction Deferred Acceptance メカニズム (QRDA) を新たに提案する．QRDA は公平性，戦略的操作不可能性を満たし，対称性を満たす M 凸集合の和集合で表現される制約を扱う．また，QRDA は ACDA より学生の満足度が高いことを理論的，実験的に示した上で，非浪費性の観点からも QRDA は ACDA より優れていることを評価実験により示す．

連絡先: 八尋健太郎，九州大学大学院システム情報科学府，819-0395 福岡県福岡市西区元岡 744 番地，(092)802-3576，yahiro@agent.inf.kyushu-u.ac.jp

2. モデル

分配制約下における学生と学校間のマッチング問題は $(S, C, X, \succ_S, \succ_C, \mathcal{V})$ の組で定義される．$S = \{s_1, \ldots, s_n\}$ は学生の集合である．$C = \{c_1, \ldots, c_m\}$ は学校の集合であり，$M = \{1, 2, \ldots, m\}$ とする．$X = S \times C$ は契約の集合であり，契約 $(s, c) \in X$ は，学生 s が学校 c に割り当てられることを意味する．$\dot{X} \subseteq X$ について，$\dot{X}_s$ は $\{(s, c) \in \dot{X} \mid c \in C\}$ を，$\dot{X}_c$ は $\{(s, c) \in \dot{X} \mid s \in S\}$ を意味する．$\succ_S = (\succ_{s_1}, \ldots, \succ_{s_n})$ は学生側が持つ選好順序の組である．学生 s が持つ選好順序 $\succ_s$ は，s に関する全ての契約を厳密に順序付ける．以降では，$(s, c) \succ_s (s, c')$ を単に $c \succ_s c'$ と表すこともある．$\succ_C = (\succ_{c_1}, \ldots, \succ_{c_m})$ は学校側が持つ優先順序の組である．学校 c が持つ優先順序 $\succ_c$ は，c に関する全ての契約を厳密に順序付ける．以降では，$(s, c) \succ_c (s', c)$ を単に $s \succ_c s'$ と表すこともある．$\mathcal{V} \subseteq \mathbb{N}_0^m$ は分配制約を満たす m 次元ベクトルの集合である．任意の $\nu \in \mathcal{V}$ について，$\sum_{i \in M} \nu_i = n$ を満たすとする．$\dot{X}$ について，m 次元ベクトル $(|\dot{X}_{c_1}|, |\dot{X}_{c_2}|, \ldots, |\dot{X}_{c_m}|)$ を $\zeta(\dot{X})$ と表す．

定義 1 (実現可能性) $\dot{X} \subseteq X$ に対し，任意の $s \in S$ について $|\dot{X}_s| = 1$ が成り立つとき，$\dot{X}$ は学生側実現可能であるという．学生側実現可能な契約の集合をマッチングと呼ぶ．また，$\zeta(\dot{X}) \in \mathcal{V}$ が成り立つとき，$\dot{X}$ は学校側実現可能であるという．学生側実現可能かつ学校側実現可能であるとき，$\dot{X}$ は実現可能であるという．

各学校は全ての学生を受け入れ可能と仮定する [*1]．すなわち，各学校は学生を受け入れないことより受け入れることを好むとする．学生についても同様である．

また，マッチングに対しての選好順序も同様に定義する．マッチング $\dot{X}, \ddot{X}$ について，$\dot{X}_s = \{x'\}, \ddot{X}_s = \{x''\}, x' \succ_s x''$ であることを $\dot{X}_s \succ_s \ddot{X}_s$ と表す．さらに，$\dot{X}_s \succ_s \ddot{X}_s$ または $\dot{X}_s = \ddot{X}_s$ であることを $\dot{X}_s \succeq_s \ddot{X}_s$ と表す．

メカニズム φ を，学生の選好の組 $\succ_S$ を入力とし契約の集合を出力する関数と定義する．$\varphi_s(\succ_S)$ は $\varphi(\succ_S) = \dot{X}$ となる $\dot{X}_s$ を表す．また，$\succ_{S\setminus\{s\}}$ は s 以外の全ての学生の選好の組を表し，$(\succ_s, \succ_{S\setminus\{s\}})$ は s の選好は $\succ_s$，それ以外の学生の選好の組が $\succ_{S\setminus\{s\}}$ である場合の全ての学生の選好の組を表すとする．

定義 2 (戦略的操作不可能性) メカニズム φ が戦略的操作不可能性を満たすとは，任意の $s, \succ_s, \succ_{S\setminus\{s\}}, \succ'_s$ ($\succ'_s$ は s の任意の選好) について $\varphi_s((\succ_s, \succ_{S\setminus\{s\}})) \succeq_s \varphi_s((\succ'_s, \succ_{S\setminus\{s\}}))$ が成り立つことをいう．

戦略的操作不可能性は，任意の学生は他の学生の申告に関わらず，自身の正直な選好を申告することが弱支配戦略となることを保証する性質である．

定義 3 (公平性) マッチング $\dot{X}$ における $(s,c) \in \dot{X}$ に対し，学生 s が他の学生 $s'(\neq s)$ に妥当な不満を持つとは，ある学校 $c' \in C$ について，$(s,c') \succ_s (s,c), (s',c') \in \dot{X}, (s,c') \succ_{c'} (s',c')$ が成り立つことをいう．マッチング $\dot{X}$ が公平性を満たすとは，妥当な不満を持つ学生が $\dot{X}$ に存在しないことをいい，任意の入力に対して公平性を満たすマッチングを出力するとき，そのメカニズムは公平性を満たすという．

すなわち，学生 s が s' に妥当な不満を持つとは，s は現在割り当てられている学校より c' の方が好ましく，c' も現在受け入れている s' より s の優先順序が高い場合を指す．

定義 4 (非浪費性) マッチング $\dot{X}$ における $(s,c) \in \dot{X}$ に対し，学生 s が c' の空きシートを要求するとは，$(s,c') \succ_s (s,c)$ が成り立ち，$(\dot{X} \setminus \{(s,c)\}) \cup \{(s,c')\}$ が学校側実現可能であることをいう．マッチング $\dot{X}$ が非浪費性を満たすとは，空きシートを要求する学生が $\dot{X}$ に存在しないことをいい，任意の入力に対して非浪費性を満たすマッチングを出力するとき，そのメカニズムは非浪費性を満たすという．

すなわち，学生 s が学校 c' に空きシートを要求するとは，s が現在割り当てられている学校より c' の方が好ましく，s が現在の学校から c' に移動したとしても，マッチングが実現可能である場合を指す．

マッチング理論では慣習上，公平性と非浪費性は**安定性**と呼ばれる概念として集約される．しかしながら，本研究で扱う対称性を満たす M 凸集合の和集合で表現される制約の一種である相対制約の場合に，安定性を満たすマッチングが存在しないことが示されている [Yahiro 18]．そこで，本論文では安定性という概念を公平性，非浪費性の二つに分割し，公平性を満たしつつ，可能な限り非浪費性の観点で効率的なメカニズムの設計に焦点を当てる．

$\mathcal{V}$ が M 凸集合 (連続領域の凸集合に対する離散領域の類似の概念 [*2]) であれば，generalized DA と呼ばれる DA に基づくメカニズムは，公平性，戦略的操作不可能性を満たすことが知られている [Kojima 14]．

定義 5 (M 凸集合) χ_i を i 番目の要素が 1 でそれ以外の要素が 0 の m 次元ベクトルとする．このとき，$\mathcal{V} \subseteq \mathbb{N}_0^m$ が M 凸集合であるとは，任意の $\nu, \nu' \in \mathcal{V}$ について，$\nu_i > \nu'_i$ を満たす任意の i に対し，$\nu - \chi_i + \chi_j \in \mathcal{V}, \nu' + \chi_i - \chi_j \in \mathcal{V}$ を満たす $j \in \{k \in M \mid \nu_k < \nu'_k\}$ が存在することをいう．

次に，集合の対称性について以下で定義する．集合の対称性は本論文で扱う制約のために必要な仮定である．

定義 6 (集合の対称性) $\mathcal{V} \subseteq \mathbb{N}_0^m$ が対称性を満たすとは，任意の $\nu = (\nu_1, \ldots, \nu_m) \in \mathcal{V}$ について，$(\nu_1, \ldots, \nu_m)$ の要素の順列で表される任意の ν' も $\mathcal{V}$ に属することをいう．

本論文では，対称性を満たす M 凸集合の和集合で表現される分配制約を考察する．

定義 7 (対称性を満たす M 凸集合の和集合) $\mathcal{V} \subseteq \mathbb{N}_0^m$ が対称性を満たす M 凸集合の和集合であるとは，対称性を満たす任意の M 凸集合 $\mathcal{V}_i$ により，$\mathcal{V} = \mathcal{V}_1 \cup \cdots \cup \mathcal{V}_l$ と表されることをいう．

3. 対称性を満たす M 凸集合の和集合で表現される制約の例

本章では，対称性を満たす M 凸集合の和集合で表現される現実的な分配制約の例を示す．まず，対称性を満たす M 凸集合により表現される分配制約を示す．

定義 8 (一様個別上下限制約) p と q をそれぞれ学校に共通の個別下限，個別上限制約とする．すなわち，$\mathcal{V} = \{\nu \in \mathbb{N}_0^m \mid \forall i \in M, p \leq \nu_i \leq q, \sum_{i\in M} \nu_i = n\}$ が成り立つことをいう．

一様個別上下限制約は M 凸集合で表現される [Kojima 14]．また，学校に共通の個別上下限制約が課されているため，$\mathcal{V}$ は対称性を満たす．

M 凸集合で表現される新たな制約のクラスを定義するため，最安定ベクトルを定義する．

定義 9 (最安定ベクトル) $\nu \in \mathbb{N}_0^m$ が最安定ベクトルであるとは，任意の $i \in M$ について，$\nu_i = \lfloor n/m \rfloor$ または $\nu_i = \lceil n/m \rceil$ を満たすことをいう．

次に，対称性を満たす M 凸集合の和集合で表現される分配制約を二種類示す．

定義 10 (相対制約) α を $0 \leq \alpha \leq 1$ を満たすパラメータ，$r(\nu) = \frac{\min_{i\in M} \nu_i}{\max_{i\in M} \nu_i}$ とする．このとき，$\mathcal{V} = \{\nu \in \mathbb{N}_0^m \mid r(\nu) \geq \alpha, \sum_{i\in M} \nu_i = n\}$ が成り立つことをいう．

---

*1 強い仮定ではあるが，実現可能なマッチングの保証に必要な仮定である．

*2 厳密には，この集合は M 凸集合の拡張概念である $M^\natural$ 凸集合と呼ばれる．しかしながら，本論文のように学生が必ず学校に割り当てられる場合，$M^\natural$ 凸集合は M 凸集合と等価となる．

相対制約は複数の一様個別上下限制約を組み合わせることで表現される．例えば，$n = 21$, $m = 4$, $\alpha = 0.5$ の場合，$\mathcal{V}$ は個別上下限制約が $p = 3$, $q = 6$ である $\mathcal{V}_1$ と個別上下限制約が $p = 4$, $q = 8$ である $\mathcal{V}_2$ の和集合で表現される．

定義 11 (差異制約) d を差異に関するパラメータ，$\gamma(\nu) = (\max_{i\in M} \nu_i) - (\min_{i\in M} \nu_i)$ とする．このとき，$\mathcal{V} = \{\nu \in \mathbb{N}_0^m \mid \gamma(\nu) \leq d, \sum_{i\in M} \nu_i = n\}$ が成り立つことをいう．

差異制約も同様に，複数の一様個別上下限制約を組み合わせることで表現される．例えば，$n = 21$, $m = 4$, $d = 4$ の場合，$\mathcal{V}$ は個別上下限制約が $p = 3$, $q = 7$ である $\mathcal{V}_1$ と個別上下限制約が $p = 4$, $q = 8$ である $\mathcal{V}_2$ の和集合で表現される．

相対制約も差異制約も複数の一様個別上下限制約の組合せにより実現することができるが，一般に相対制約は差異制約で表現することができず，差異制約も相対制約により表現することができないことに注意する．すなわち，同一の制約ではない．

4. Quota Reduction Deferred Acceptance メカニズム (QRDA)

4.1 概要

Quota Reduction Deferred Acceptance メカニズム (QRDA) は Gale と Shapley による Deferred Acceptance メカニズム (DA) [Gale 62] を繰り返し用いる．標準的なマッチング問題は，$(S, C, X, \succ_S, \succ_C, q_C)$ の組で定義される．本モデルとの違いは，学校の個別上限の組 $q_C = (q_c)_{c\in C}$ が制約として与えられている点である．マッチング $\dot{X}$ が学校側実現可能とは，任意の $c \in C$ について $|\dot{X}_c| \leq q_c$ が成り立つことをいう．DA は標準的なマッチング問題において以下で定義される．

メカニズム 1 (DA)

ステップ 1 各学生 s はまだ拒否されていない学校のうち $\succ_s$ において最も好む学校を選び，申し込む．

ステップ 2 申し込まれた各学校 c は申込があった学生のうち $\succ_c$ の上位 q_c 人までを受け入れ，残りの学生を拒否する．

ステップ 3 全ての学生が拒否されなければ，メカニズムを終了する．そうでなければ，ステップ 1 に戻る．

σ をラウンドロビン順序 $c_1, c_2, \ldots, c_m$ に基づいた学校の順序列 [*3] とする．$\sigma(k)$ は σ の k 番目の学校を表し，$\sigma(k) = c_j$ とする．ただし，$j = 1 + (k - 1 \mod m)$ である．また，$\nu_{max} = \max_{\nu\in\mathcal{V}, i\in M} \nu_i$ とする．

以上の定義をもって，QRDA を定義する．

メカニズム 2 (QRDA) 任意の $c \in C$ について，$q_c^1 \leftarrow \nu_{max}$, $k \leftarrow 1$ とする．

ステージ k (≥ 1):

$(S, C, X, \succ_S, \succ_C, q_C^k)$ の組の下で DA を実行し，得られたマッチングを $\dot{X}^k$ とする．$\dot{X}^k$ が学校側実現可能であれば，$\dot{X}^k$ を出力する．そうでなければ，学校 $c' = \sigma(k)$ について $q_{c'}^{k+1} \leftarrow q_{c'}^k - 1$ とし，それ以外の学校 c ($\neq c'$) については $q_c^{k+1} \leftarrow q_c^k$ とし，ステージ $k + 1$ に進む．

*3 簡略化のため，σ は同じラウンドロビン順序に基づくとしているが，任意のラウンドロビン順序に基づく σ においても本論文における結果には影響しない．すなわち，任意の $l \in \mathbb{N}_0$ において $\sigma(ml + 1), \sigma(ml + 2), \ldots, \sigma(ml + m)$ が $c_1, c_2, \ldots, c_m$ の順列により表されていても構わない．

4.2 メカニズムの理論的性質

まず，対称性を満たす M 凸集合の和集合に関する性質を示す．証明は紙幅の都合上割愛する．

補助定理 1 $\mathcal{V}$ が対称性を満たす M 凸集合の和集合であるとき，全ての最安定ベクトルは $\mathcal{V}$ に属する．

次に，QRDA が公平性を満たし，実現可能なマッチングを出力することを示す．

定理 1 対称性を満たす M 凸集合の和集合で表現される制約を扱うとき，QRDA は公平性を満たし，実現可能なマッチングを常に出力する．

証明 QRDA が実現可能なマッチングを得ることなく，上限を減らし続けた場合を考える．最終的に，$\sum_{c\in C} q_c^k = n$, 任意の $c \in C$ について $\lfloor n/m \rfloor \leq q_c \leq \lceil n/m \rceil$ を満たすステージ k に到達する．補助定理 1 より，全ての最安定ベクトルは $\mathcal{V}$ に属するため，得られたマッチング $\dot{X}$ は実現可能である．ゆえに，QRDA はステージ k' ($\leq k$) で終了する．さらに，$\dot{X}^{k'}$ は $(S, C, X, \succ_S, \succ_C, q_C^{k'})$ における DA の出力結果と同等である．DA は公平性を満たす [Gale 62] ことから，$\dot{X}^{k'}$ も公平性を満たす． □

本論文において最も主要な定理を以下に示す．証明は紙幅の都合上割愛する．

定理 2 対称性を満たす M 凸集合の和集合で表現される制約を扱うとき，QRDA は戦略的操作不可能性を満たす．

QRDA では，ステージが進むにつれて学校の上限は減少していくため，後のステージで失う可能性のある学校のシートを得るために，メカニズムを早い段階で終了させようとするインセンティブを学生に与えてしまう．しかし，QRDA はこのような操作に対して頑健であることを定理 2 は示している．

4.3 基準メカニズムとの理論的関係

本節では，DA によるマッチングが分配制約を満足するような学校の個別上限を定義する手法を示す．このようなメカニズムは，Artificial Cap Deferred Acceptance メカニズム (ACDA) と一般に呼ばれている．ACDA は日本の研修医マッチングプログラムにおいて各県ごとの研修医数の偏りをなくす目的で採用されているとともに，多くの分配制約に関する既存研究でメカニズムの比較対象として利用されている．

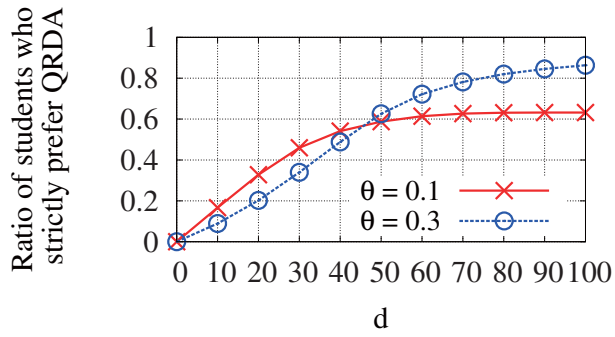
事前にどの学校が人気/不人気であるかを為政者が把握している場合，学生の満足度を最大化するような q_C を意図的に設定することができる．そうでなければ，適切な q_C を定めるために，最安定ベクトルを利用することが考えられる．最安定ベクトルに基づく ACDA は以下で定義される．

メカニズム 3 ((最安定ベクトルに基づく) ACDA) $i \leq (n \mod m)$ を満たす任意の i について，$q_{c_i} \leftarrow \lfloor n/m \rfloor$ とし，$i > (n \mod m)$ を満たす任意の i について，$q_{c_i} \leftarrow \lceil n/m \rceil$ とする．$(S, C, X, \succ_S, \succ_C, q_C)$ の組の下で DA を実行する．

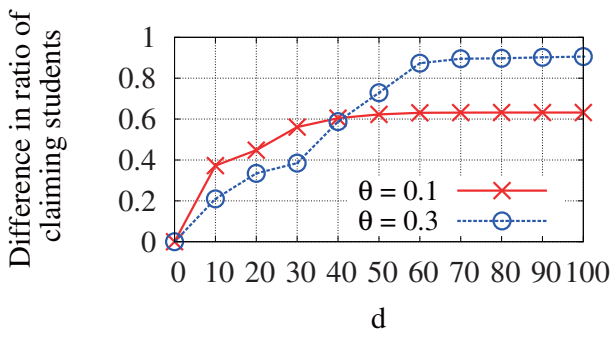
定理 3 ACDA は公平性，戦略的操作不可能性を満たし，実現可能なマッチングを常に出力する．

証明は紙幅の都合上割愛するが，補助定理 1 と ACDA は DA と同等の動作であることから得られる．

QRDA で割り当てられた学校より，ACDA で割り当てられた学校を好む学生は存在しない．この事実を以下の定理で示す．



(a) QRDA を厳密に好む学生の割合



(b) 空きシートを要求する学生の割合の差

図 1: QRDA と ACDA の比較結果

定理 4 任意の学生は ACDA で得られたマッチングより QRDA で得られたマッチングを同等以上に好む．

証明 QRDA における上限が ACDA で用いた q_C と等しくなるステージを k とする．定理 1 の証明と同様に，QRDA はステージ k' $(\leq k)$ で終了する．任意の学校 $c \in C$ について $q_c^{k'} \geq q_c^k$ であり，DA の学校の上限に関する単調性 [Ehlers 16] より，任意の学生は ACDA で得られたマッチングより QRDA で得られたマッチングを同等以上に好む． □

非浪費性の観点では，ACDA より QRDA において空きシートを要求する学生数が多い場合が存在する [Yahiro 18]．すなわち，QRDA が ACDA より非浪費性の観点で常に優れることを示すことができない．Yahiro らは，相対制約の場合にこの事実を示しているが，相対制約は対称性を満たす M 凸集合の和集合で表現される制約の一種であるため，この事実は本モデルにおいても成立する．

5. 評価実験

学生の満足度，空きシートを要求する学生の割合の二つの観点から，コンピュータシミュレーションを用いて QRDA と ACDA の性能を比較した．実験には，対称性を満たす M 凸集合の和集合で表現される制約の一種である差異制約を用いている．

学生は $n = 800$，学校は $m = 20$ で，Mallows モデルと呼ばれる数理モデルに基づき学生の選好を生成した．学生 s の厳密な選好 $\succ_s$ の生成確率 $\Pr(\succ_s)$ は $\frac{\exp(-\theta \cdot d(\succ_s, \succ_{\hat{s}}))}{\sum_{\succ'_s} \exp(-\theta \cdot d(\succ'_s, \succ_{\hat{s}}))}$ で与えられるとする．ここで，$\theta \in \mathbb{R}$ は拡散パラメータであり，$\succ_{\hat{s}}$ は中心選好 (我々の実験では可能な学生の選好の全通りから一様ランダムに選んでいる) と呼ばれる．$d(\succ_s, \succ_{\hat{s}})$ は $\succ_s$ と $\succ_{\hat{s}}$ 間のケンドール距離である．ケンドール距離は，$\succ_s$ と $\succ_{\hat{s}}$ 間の対象対の中で順序が不一致な対の数を表す．$\theta = 0$ のとき，一様ランダムと同一となり，θ が増加するにつれて，学生の選好は中心選好に漸近する．また，各学校の優先順序は一様ランダムで生成している．各パラメータに関して 100 問を生成してその平均を取った．

図 1 (a) は ACDA より QRDA を厳密に好む学生の割合を d に応じて示している．定理 4 より，ACDA を厳密に好む学生は存在しないが，d が大きくなると，メカニズム間の差はより顕著に見られるようになった．

S_{ACDA} (S_{QRDA}) を ACDA (QRDA) において空きシートを要求する学生の集合とし，$(|S_{\mathrm{ACDA}}| - |S_{\mathrm{QRDA}}|)/n$ としてプロットした．この様子を図 1 (b) に示している．図 1 (a) と同様に，d が大きくなると，メカニズム間の差はより顕著に見られるようになった．

6. 結論

本論文では，新たな分配制約のクラスである対称性を満たす M 凸集合の和集合で表現される制約を新たに導入した．さらに，公平性，戦略的操作不可能性を満たし，実現可能なマッチングを常に出力する QRDA を提案し，ACDA より学生の満足度が常に高いことを理論的に証明した．また，学生の満足度，非浪費性の観点から QRDA は ACDA より優れていることを評価実験により示した．

今後の研究課題としては，対称性を満たす M 凸集合の和集合で表現される制約より広い制約のクラスを扱うメカニズムの考察が挙げられる．

謝辞

本研究は JSPS 科研費 JP17H00761 の助成を受けたものです．深く感謝いたします．

参考文献

[Ehlers 16] Ehlers, L. and Klaus, B.: Object allocation via deferred-acceptance: Strategy-proofness and comparative statics, *Games and Economic Behavior*, Vol. 97, pp. 128–146 (2016)

[Gale 62] Gale, D. and Shapley, L. S.: College Admissions and the Stability of Marriage, *The American Mathematical Monthly*, Vol. 69, No. 1, pp. 9–15 (1962)

[Kojima 14] Kojima, F., Tamura, A., and Yokoo, M.: Designing Matching Mechanisms under Constraints: An Approach from Discrete Convex Analysis, in *Proceedings of the 7th International Symposium on Algorithmic Game Theory, SAGT* (2014), (the full version is available at http://mpra.ub.uni-muenchen.de/78637/)

[Yahiro 18] Yahiro, K., Zhang, Y., Barrot, N., and Yokoo, M.: Strategyproof and fair matching mechanism for ratio constraints, in *Proceedings of the 17th Conference on Autonomous Agents and MultiAgent Systems, AAMAS* (2018), forthcoming

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

2人非対称情報オールペイオークションにおける均衡と逆転現象の解析

Analysis of Equilibria and Reverse Phenomenon in Two-player All-pay Auction with Asymmetric Information

赤木 亨 *1　東藤 大樹 *1　横尾 真 *1
Toru Akagi　Taiki Todo　Makoto Yokoo

*1九州大学大学院システム情報科学府
Graduate School of Information Science and Electrical Engineering at Kyushu University

In this work, we study a class of two-player common-value all-pay auctions with asymmetric information, in which each player does not know the exact value of the prize and she must pay her bid even if she does not win the prize. For each player, the auctioneer can give the information about the real value of prize. In particular, the auctioneer can give an *information advantage* to one player, i.e., the information of one player is more precise than that of the other player. We analyze the condition where the equilibrium payoff of the advantageous player is actually lower than that of the disadvantageous player (i.e., a *reverse phenomenon* occurs) when a *bid cap* (a maximum limit of possible bids) is imposed.

1. 序論

オークションは1人の売り手と複数人の入札者からなるゲームである．一般的にはまず，売り手が販売目的の商品を入札者全員に公開する．商品は，例えば骨董品や絵画などの形があるものに加えて，石油の採掘権や公共事業の依頼なども該当する．各入札者は商品を確認し，入札額を決定する．最も高い入札額を選択した入札者を勝者とし，その入札者は入札額を支払い商品を受け取り，他の入札者は支払いを行わない．しかしながら**オールペイオークション**は，すべての入札者が商品を受け取るか否かに関わらず，自分の入札額を支払う．オールペイオークションは上記の性質があるため，現実問題における R&D や特許競争，競技大会といった，入札者の支払うコスト (入札) が回収できない状況をモデル化する方法として広く利用されている．

オールペイオークションにおいて，入札者の得る利益を**利得**と呼ぶ．各入札者は合理的であり，各自の利得が最大となるように入札額を決定すると仮定する．この入札額の決定方法を**戦略**と呼ぶ．すべての入札者が，自分の利得を最大化する戦略を選択している場合，その戦略の組を**ナッシュ均衡**と呼ぶ．本論文ではナッシュ均衡を単に均衡と表記する．

オールペイオークションは，入札者が勝利報酬に対して個別の評価値を持つ場合と，共通の評価値を持つ場合に大きく分類される．一般的なオールペイオークションにおいて，入札者全員が個別の評価値を持つ場合，唯一の均衡が存在し，入札者のうち最も高い評価値を持つ入札者と，2番目に高い評価値を持つ入札者のみが入札を行い，その他の入札者は入札をしない (厳密には，入札額を常に 0 とする) ．入札者全員が共通の評価値を持つ場合には，複数の均衡が存在し，任意の均衡において最低2人の入札者が入札する [Siegel 14]．本論文では，入札者が 2 人で両者が勝利報酬に対して共通の評価値を持つモデルを扱う．

また，各入札者が勝利報酬の価値に関する情報を持つモデルが存在し，この情報を**情報区画**と呼ぶ．厳密には，勝利報酬は状態変数に依存して決まり，情報区画はその状態変数に関する情報を与えるが，これは勝利報酬の価値に関する情報を与えることと同じである．よって，情報区画が勝利報酬の価値に関する情報と仮定して説明する．情報区画は複数の区画からなり，区画は，勝利報酬がとり得る値の集合である．勝利報酬がある値に定まった時，入札者は自分の情報区画の中からその値を含む 1 つの区画を受け取る．各入札者は，自身に与えられた区画に含まれる値のいずれかが，実際の勝利報酬の評価値であると知ることが可能である．情報区画は均衡にも影響を与え，売り手が正確に勝利報酬の評価値を知っている場合，情報区画を用いて入札者に与える情報を制御することで，各入札者の戦略や利得を操作できる可能性がある．

売り手は情報区画を操作することによって，常に特定の入札者が他の入札者以上に正確な情報を得るように情報区画を定めることも可能である．入札者が 2 人の場合においては，より正確な情報を得る入札者は**情報優位性**を持つと定義する．既存研究において，情報優位性を持つ入札者は，情報優位性を持たない入札者以上の利益を得ることが示されている．

また，現実問題として，入札額に限度がある場合や，高額な入札が売り手にとって利益とならない場合も存在する．このような背景から，各入札者に**入札上限**を設けたモデルが考察されている [Che 98]．入札上限を設けることで，均衡における各入札者の戦略が変化する．直感的には，入札上限を設けることで入札額の期待値が減少すると考えられるが，既存研究においては，入札上限を設けることで，入札額の期待値が増加する例も示されている．

情報優位性を持つ入札者は，情報優位性を持たない入札者以上の利益を得ることが示されているが，入札上限が同時に存在する場合，情報優位性を持つ入札者の利得が，情報優位性を持たない入札者の利得と比較して低くなる現象が生じることが示された [Einy 16]．この現象を**逆転現象**と呼ぶ．逆転現象の存在が与える影響は大きい．例えば，売り手が 2 人の入札者のうち一方に対して他方の入札者より強い友好関係があるなどの理由から，一方の入札者の利得を他方の入札者の利得より高くしたいと考えたとする．逆転現象が発生する条件の下では，単純にその入札者に他方の入札者より正確な情報を与えるだけでは達成不可能である．従って，逆転現象の発生条件を解明することは大きな課題である．

また，入札上限を設けることで，各入札者の入札額の期待値

連絡先: 赤木 亨，九州大学大学院システム情報科学府，819-0395 福岡県福岡市西区元岡 744 番地，(092)802-3576，akagi@agent.inf.kyushu-u.ac.jp

が変化する可能性もある．現実問題として売り手が各入札者の入札額の期待値を増加させたいと考えることは自然である．従って，入札上限が入札額の期待値に与える影響を解明することも大きな課題である．

本論文では，入札者が 2 人で，かつ情報区画と入札上限が同時に存在する場合について，2 つの点から解析を行う．まず，既存研究で各入札者に与えた情報区画 [Einy 16] と異なる情報区画を開示することによって，逆転現象発生の有無を変化させるための条件について説明する．次に，任意の情報区画と均衡の戦略が等しい特定の情報区画 [Einy 17] に対して入札上限を導入し，全入札者の入札額の期待値の総和が変化しない入札上限の条件と，その時に成り立つ均衡を示す．

2. モデル

オークションに参加する 2 人の入札者をそれぞれ A, B とする．入札者 $j \in \{A, B\}$ に対し，$-j$ は他方の入札者を表すとする．各入札者は入札を行い，より高い入札をした入札者が勝利報酬を得る．入札額が等しい場合は，勝利報酬は無作為にどちらかの入札者が得る．勝利報酬は自然が選ぶ状態に依存して決定される．この状態の集合を $\Omega = \{\omega_1, \omega_2, \omega_3, \ldots, \omega_n\}$ とする．状態 ω_i が起こる確率を p_i，状態 ω_i における入札者間で共通の勝利報酬を v_i とする．また，一般性を失わずに勝利報酬の値に関して $v_1 < v_2 < v_3 < \cdots < v_n$ が成り立つとする．

次に，入札上限と情報区画を定義する．入札上限は 2 人の入札者で共通であり，d で表す．入札額を x とすると，常に $0 \leq x \leq d$ を満たす．情報区画は入札者それぞれに与えられ，入札者 j の情報区画を Π_j と表す．Π_j は状態集合 Ω の分割である．状態 ω_i が選ばれた時，入札者 j は，$\omega_i \in \pi$ を満たす Π_j 上の区画 π を売り手から受け取る．そして入札者は，π に属するいずれかの状態が選択されたと予測することが可能である．入札者はこの予測に従って入札額を決定する．ここで，情報区画に関して以下を定義する．

定義 1 (情報区画の連続性) $1 \leq e < e + m \leq n$ を満たす整数 e, m に対し，入札者が ω_e と ω_{e+m} を区別不可能な場合，1 以上 m 未満の全ての整数 k に対して ω_{e+k} も上記の 2 状態と区別することが不可能である．すなわち，

$$\forall \pi \in \Pi, 1 \leq k < m, \omega_e \in \pi \wedge \omega_{e+m} \in \pi \rightarrow \omega_{e+k} \in \pi$$

が成り立つ．この時，情報区画は**連続性を持つ**という．

情報区画の連続性は，入札者が勝利報酬に対して 2 つの値を区別できない場合，その中間値も同様に区別できないことを意味し，既存研究で用いられている．[Einy 16, Einy 17].

ここで，オークションの流れについて説明する．まず自然が状態を選択し勝利報酬が定まる．次に，各入札者の情報区画に従って，それぞれの入札者が 1 つの区画を受け取る．入札者は自身の受け取った区画に従って戦略を決定し，入札を行う．入札者 j が区画 π を受け取った場合の戦略を表現する方法として，本モデルでは**累積分布関数** $F_j : \Pi_j \times [0, d] \rightarrow [0, 1]$ を用いる．$F_j(\pi, x)$ は，入札者 j が区画 π を受け取った場合に x より小さい額を入札する確率を示す．

次に利得を定義する．j の利得は，j の入札額と $-j$ の戦略によって定まる．$-j$ が得る区画を π' とし，状態 ω_i が選択された時に j が得る区画を π_i，$-j$ が得る区画を π'_i で表す．ここで，j が区画 π を受け取り，a の入札をする確率を $Q_j(\pi, a)$ とすると，式 (1) のようになる．

$$Q_j(\pi, a) = \lim_{\epsilon \rightarrow +0} (F_j(\pi, a + \epsilon) - F_j(\pi, a - \epsilon)) \tag{1}$$

式 (1) より，$-j$ が混合戦略 F_{-j} に従い，状態が ω_i の場合に，j が x を入札した場合の期待利得 R は，式 (2) のように表せる．

$$R_j(\omega_i, x, F_{-j}) = v_i \left(F_{-j}(\pi'_i, x) + \frac{1}{2} Q_{-j}(\pi'_i, x) \right) - x \tag{2}$$

次に $f_j(\pi, x)$ は $F_j(\pi, x)$ を x で 1 階微分したものであるとする．$F_j(\pi, x)$ が x 上の $0 \leq x \leq d$ の区間において連続である場合，$f_j(\pi, x)$ を用いることで，入札者 j 及び $-j$ が混合戦略 F_j, F_{-j} に従った場合の j の期待利得は，式 (3) で表される．

$$E_j(F_j, F_{-j}) = \sum_{i=1}^{n} p_i \int_0^d f_j(\pi_i, x) R_j(\omega_i, x, F_{-j}) dx \tag{3}$$

$F_j(\pi, x)$ が x 上の $0 \leq x \leq d$ の区間において，いくつかの点で連続でないとする．連続でない x 上の点を，小さい順に $g_1, g_2, \ldots, g_m$ とし，$g_0 = 0, g_{m+1} = d$ とする．上記の記号を用いて，入札者 j 及び $-j$ が混合戦略 F_j, F_{-j} に従った場合の j の期待利得 E は式 (4) で表される．

$$E_j(F_j, F_{-j}) = \sum_{i=1}^{n} p_i \sum_{t=0}^{m} \int_{g_t}^{g_{t+1}} f_j(\pi_i, x) R_j(\omega_i, x, F_{-j}) dx + \sum_{i=1}^{n} p_i \sum_{t=1}^{m} Q(F_j, g_t) R_j(\omega_i, c_t, F_{-j}) \tag{4}$$

最後に，最適反応戦略と均衡について定義する．

定義 2 (最適反応戦略) 戦略 F_j が $-j$ の戦略 F_{-j} に対しての**最適反応戦略**であるとは，j が選択可能なすべての戦略 F'_j について，F_j が式 (5) を満たすことをいう．

$$E_j(F_j, F_{-j}) \geq E_j(F'_j, F_{-j}) \tag{5}$$

定義 3 (ナッシュ均衡) ある戦略の組 (F_A, F_B) が**ナッシュ均衡**であるとは，F_A 及び F_B が，各入札者 $j \in \{A, B\}$ の選択可能なすべての戦略 F'_j について，式 (5) を満たすことをいう．

3. 逆転現象

本章では，まず初期状態として，既存研究が示す式 (6), (7) の情報区画 [Einy 16] を与えた場合の均衡を考える．この情報区画は，一方の入札者には追加情報を与えず，もう一方の入札者には完全情報を開示することを意味する．この情報区画を与えた場合の均衡を，初期状態の均衡と呼ぶことにする．

$$\Pi_A = \{\{\omega_1, \omega_2, \ldots, \omega_n\}\} \tag{6}$$

$$\Pi_B = \{\{\omega_1\}, \{\omega_2\}, \ldots, \{\omega_n\}\} \tag{7}$$

まず最初に，初期状態の均衡において逆転現象が生じる場合に，情報区画の操作によって逆転現象が生じない均衡となる条件とその例を示す．次に，初期状態の均衡において逆転現象が生じない場合に，情報区画を操作することで逆転現象が生じる均衡となる条件とその例を示す．

3.1 準備

本節では，全ての入札者が**純粋戦略**を選択する場合を扱う．純粋戦略とは，各入札者が受け取る区画に従って，自身の入札額をある 1 つの値に決定する戦略である．j が区画 π を受

け取った場合に入札する額を $S_j(\pi)$ と定義すると，純粋戦略 $S_j(\pi)$ は，戦略 F_j を用いて式 (8) のように表現できる．

$$F_j(\pi, x) = \begin{cases} 1 & (S_j(\pi) \leq x) \\ 0 & (S_j(\pi) > x) \end{cases} \tag{8}$$

式 (8) を用いて各 S_j に対応する F_j を用いることで，u_j 及び E_j を以下のように定義する．

$$\begin{aligned} u_j(\pi, x, S_{-j}) &= u_j(\pi, x, F_{-j}) \\ E_j(S_j, S_{-j}) &= E_j(F_j, F_{-j}) \end{aligned}$$

次に，情報優位性と逆転現象の定義を示す．

定義 4 (情報優位性) 入札者 $j, -j$ の情報区画が式 (9), (10) を同時に満たす場合，j は情報優位性を持つ．

$$\forall \pi_j \in \Pi_j, \exists \pi_{-j} \in \Pi_{-j}, \pi_j \subseteq \pi_{-j} \tag{9}$$
$$\exists \pi_j \in \Pi_j, \exists \pi_{-j} \in \Pi_{-j}, \pi_j \subset \pi_{-j} \tag{10}$$

逆転現象とは，ある均衡において，情報優位性を持つ入札者の期待利得が，他方の入札者と比較して低くなる現象のことである．

定義 5 (逆転現象) 逆転現象とは，入札者 j が情報優位性を持ち，かつ 2 人の入札者の利得が式 (11) を満たすことをいう．

$$E_j(S_j, S_{-j}) < E_{-j}(S_{-j}, S_j) \tag{11}$$

加えて，新たに以下に示す 2 つの記号を定義する．

$$P_k = \sum_{i=1}^{k} p_i \qquad \underline{v}_k = \sum_{i=1}^{k} p_i v_i$$

3.2 逆転現象の条件

定理 1 は，初期状態の均衡において逆転現象が生じない場合であっても，情報操作によって逆転現象が生じる均衡となるための条件を示す．

定理 1 式 (12), (13) を同時に満たす k が存在する場合，特定の情報区画に対して，逆転現象が生じる均衡が存在する．

$$\frac{1}{2}(\underline{v}_n - \underline{v}_k) \geq d \tag{12}$$
$$P_k d < \underline{v}_k \leq 2P_k d \tag{13}$$

証明は紙幅の都合上割愛するが，定理 1 で述べる均衡は，式 (12), (13) を同時に満たす k に対して，式 (14), (15) の情報区画を与えた場合に存在する．

$$\Pi_A = \{\{\omega_1, \omega_2, \ldots, \omega_n\}\} \tag{14}$$
$$\Pi_B = \{\{\omega_1, \omega_2, \ldots, \omega_k\}, \{\omega_{k+1}, \omega_{k+2}, \ldots, \omega_n\}\} \tag{15}$$

均衡における戦略は，式 (16), (17) のようになる．

$$S_A(\{\omega_1, \omega_2, \ldots, \omega_n\}) = d \tag{16}$$

$$S_B(\pi) = \begin{cases} 0 & (\pi = \{\omega_1, \omega_2, \ldots, \omega_k\}) \\ d & (\pi = \{\omega_{k+1}, \omega_{k+2}, \ldots, \omega_n\}) \end{cases} \tag{17}$$

定理 1 は，情報区画の操作によって，逆転現象が生じる均衡が存在するための条件を示す．すなわち売り手は，情報区画の操作によって，初期状態の均衡において逆転現象が生じない場合であっても，新たに逆転現象を生じさせることができる可能性がある．これとは対照的に，定理 2 では情報区画の操作によって，初期状態の均衡において逆転現象が生じる場合であっても，逆転現象が生じない均衡となるための条件について示す．

定理 2 式 (18), (19) を同時に満たす k が存在する場合，特定の情報区画に対して，逆転現象が生じる均衡が存在する．

$$\frac{1}{2}(\underline{v}_n - \underline{v}_k) > d \tag{18}$$
$$\underline{v}_k \leq P_k d \tag{19}$$

証明は紙幅の都合上割愛するが，定理 2 で述べる均衡は，式 (18), (19) を同時に満たす k に対して，式 (14), (15) の情報区画を与えた場合に存在する．均衡における戦略も同様に，式 (16), (17) のようになる．定理 2 も，売り手が情報区画の操作をすることで，逆転現象の発生の有無を変化させる条件を示すが，定理 1 とは対照的に，こちらは逆転現象を生じない均衡となる可能性を示す．

4. 入札上限の影響

既存研究においては，特定の情報区画に限り，均衡における各入札者の入札額の期待値が，入札上限によって変化しない入札上限の条件が示されている [Einy 16]．本論文では，任意の情報区画に対して入札上限を設けた場合に，入札上限がない場合の均衡と比較し，各入札者の入札額の期待値が等しい均衡となる入札上限の条件を示す．

入札者が 2 人で，任意の情報区画が与えられた場合の均衡は，n が奇数の場合は式 (20), (21) ，n が偶数の場合は式 (22), (23) に示す情報区画を与えた場合における均衡と戦略が等しい [Einy 17]．

$$\Pi_A = \{\{\omega_1\}, \{\omega_2, \omega_3\}, \ldots, \{\omega_{n-1}, \omega_n\}\} \tag{20}$$
$$\Pi_B = \{\{\omega_1, \omega_2\}, \ldots, \{\omega_{n-2}, \omega_{n-1}\}, \{\omega_n\}\} \tag{21}$$

$$\Pi_A = \{\{\omega_1\}, \{\omega_2, \omega_3\}, \ldots, \{\omega_n\}\} \tag{22}$$
$$\Pi_B = \{\{\omega_1, \omega_2\}, \ldots, \{\omega_{n-1}, \omega_n\}\} \tag{23}$$

ここで，以下に示す記号を新たに定義する．

$$\begin{aligned} p^{a,b} &= \frac{p_a}{p_a + p_b} \quad (a \neq b) \\ x_1 &= p^{1,2} v_1 \\ x_i &= p^{i,i-1} p^{i,i+1} v_i + x_{i-1} \quad (i = 2, 3, \ldots, n-1) \\ x_n &= p^{n,n-1} v_n + x_{n-1} \end{aligned}$$

便宜上，$p_0 = p_{n+1} = 0$ とする．また式 (24) が常に成り立つと仮定する．

$$p^{k+1,k+2} v_{k+1} - v_k > 0 \quad (k = 1, 2, \ldots, n-1) \tag{24}$$

式 (20), (21) または式 (22), (23) に示す情報区画において，同じ区画を受け取る入札者は存在しない．従って，両者の戦略を区画に依存する 1 つの戦略で表すことができる．ここで，

情報区画の各区画を以下のように表記し，以後の証明において，区画 π_i を受け取った場合の入札者の戦略を $F(\pi_i, x)$ と表記する．

$$\begin{aligned}\pi_0 &= \{\omega_1\}\\ \pi_k &= \{\omega_k, \omega_{k+1}\} \quad (k = 1, 2, \ldots, n-1)\\ \pi_n &= \{\omega_n\}\end{aligned}$$

本章では，上記 2 つの情報区画に対して入札上限を設けた場合に，均衡における入札額の期待値が，入札上限が存在しない場合の均衡における値と等しくなるための入札上限の条件と均衡について述べる．

定理 3 は，式 (20), (21) または式 (22), (23) に示す情報区画 [Einy 17] に対して，条件を満たす入札上限が与えられた場合の均衡を示す．次に，その均衡において全入札者の入札額の期待値の総和が，入札上限がない場合の均衡における値と等しいことを示す．

定理 3 入札上限 d が式 (25) を満たす場合，入札上限が存在しない場合の均衡と比較して，全入札者の入札額の期待値の総和が等しくなる均衡が存在する．

$$x_{n-1} + \frac{1}{2}p^{n,n-1}v_n \leq d \leq x_n \tag{25}$$

証明は紙幅の都合上割愛する．均衡となる戦略は式 (26), (27), (28), (29) に示す通りである．ただし k は $1 \leq k \leq n-2$ を満たし，$x' = 2d - x_n$ とする．

$$F(\pi_0, x) = \begin{cases} 0 & (x = 0)\\ \frac{x}{p^{1,2}v_1} & (0 < x \leq x_1)\\ 1 & (x_1 < x)\end{cases} \tag{26}$$

$$F(\pi_k, x) = \begin{cases} 0 & (x \leq x_{k-1})\\ \frac{x - x_{k-1}}{p^{k,k-1}v_k} & (x_{k-1} < x \leq x_k)\\ p^{k,k+1} + \frac{x - x_k}{p^{k+1,k+2}v_{k+1}} & (x_k < x \leq x_{k+1})\\ 1 & (x_{k+1} < x)\end{cases} \tag{27}$$

$$F(\pi_{n-1}, x) = \begin{cases} 0 & (x \leq x_{n-2})\\ \frac{x - x_{n-2}}{p^{n-1,n-2}v_{n-1}} & (x_{n-2} < x \leq x_{n-1})\\ p^{n-1,n} + \frac{x - x_{n-1}}{v_n} & (x_{n-1} < x \leq x')\\ p^{n-1,n} + \frac{x' - x_{n-1}}{v_n} & (x' < x \leq d)\\ 1 & (d < x)\end{cases} \tag{28}$$

$$F(\pi_n, x) = \begin{cases} 0 & (x \leq x_{n-1})\\ \frac{x - x_{n-1}}{p^{n,n-1}v_n} & (x_{n-1} < x \leq x')\\ \frac{(x') - x_{n-1}}{p^{n,n-1}v_n} & (x' < x \leq d)\\ 1 & (d < x)\end{cases} \tag{29}$$

定理 3 により，十分に高い入札上限が設定された場合には，入札上限によって入札額の期待値の総和が変化しないことが示された．また，式 (25) から，定理 3 に示した均衡となるための入札上限の範囲は，v_n 及び v_{n-1} の値に大きく依存することが示された．

5. 結論

本論文では，共通価値を持つ 2 人オールペイオークションにおいて，入札上限と情報区画が与える影響について 2 つの点から解析を行った．逆転現象発生の有無については，入札上限に限らず情報区画を操作することによっても変化する可能性があることを示した．また，任意の情報区画が与えられた場合においても，入札上限が十分に高い場合，均衡における入札額の期待値の総和は，入札上限が存在しない場合の均衡における値と等しくなることを示した．

今後の課題としては，入札上限の影響を異なる観点から考察することが挙げられる．例えば既存研究においては，入札上限を設けることで入札額の期待値が大きくなる可能性が示されている．この現象を本モデルで適用することで，入札額の上昇を望む売り手が，自身の最適な入札上限の設定をする場合に応用可能である．また，現実問題として競争相手が複数人であることは自然である．従って，このモデルを入札者が 3 人以上の場合に拡張することで，競争相手が複数人である場合であっても，入札者の行動予測や，売り手が情報区画や入札上限の操作をする場合に応用することが可能である．

6. 謝辞

本研究は JSPS 科研費 JP17H00761 の助成を受けたものです．深く感謝いたします．

参考文献

[Siegel 14] Siegel, Ron Asymmetric all-pay auctions with interdependent valuations. *Journal of Economic Theory*, Vol. 153, pp. 684–702, 2014.

[Che 98] Che, Yeon-Koo and Gale, Ian L Caps on political lobbying. *The american economic review*, Vol. 88, pp. 643–651, 1998.

[Einy 16] Einy, Ezra and Haimanko, Ori and Orzach, Ram and Sela, Aner Common-value all-pay auctions with asymmetric information and bid caps. *International Journal of Game Theory*, Vol. 45, pp. 63–88, 2016.

[Einy 17] Einy, Ezra and Goswami, Mridu Prabal and Haimanko, Ori and Orzach, Ram and Sela, Aner Common-value all-pay auctions with asymmetric information. *International Journal of Game Theory*, Vol. 46, pp. 79–102, 2017.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

避難シミュレーションにおける反応閾値モデルによる複数タスクのモデル化

Modeling Multiple Tasks by the Response Threshold Model in Evacuation Simulation

鶴島　彰
Akira Tsurushima

セコム株式会社　IS 研究所
SECOM CO., LTD., Intelligent Systems Laboratory

It is widely known that herd behavior, a cognitive bias in humans, causes irrational or inappropriate behaviors in evacuation situations. In this paper, we propose the evacuation decision model for herding based on the biological response threshold model. We also show that the proposed model can be applied for multi task problems in which the agents must choose two or more tasks to perform such as evacuation and fire fighting.

1. はじめに

災害避難の現場において、避難行動に対する認知バイアスの影響が指摘されている。代表的なものとして正常性バイアスと同調行動があり、その影響による避難行動の遅れや非効率、不合理な行動がしばしば大きな被害に結びついている。

このような認知バイアスや心理的要因を、シミュレーションモデルに組み込み、よりリアルな状況を再現しようとする試みがいくつか行われてきた [Tsai 11, Bulumulla 17]。しかし、これらのモデルの多くは認知バイアスを、事前定義したシナリオやルールとして直接エージェントに組み込んでいるため、予め設計者が想定した状況下でその行動が再生されるのみであり、未知の状況下における認知バイアスの影響の分析や、認知バイアスを誘発させる原因の探求などの、より踏み込んだ研究の目的には適さない。

一方、[Helbing 00] は、ソーシャルフォースモデルにより、パニック状況における人間の避難行動をモデル化し、事前定義したシナリオやルールを使うことなしに、アーチ形状の滞留や出口の非対称な使用などの特徴的な行動を再現してみせた。しかし、[Helbing 00] のモデルは、速度、力、摩擦などの物理量のみ（壁から離れたい、などの心理的な効果も物理量に置き換えられている）で組み立てられたものであり、認知バイアスのような認知的な要因を組み込むことはそのままでは難しい。

本稿は、災害避難状況における人間の同調行動に焦点をあて、それが避難行動におよぼす影響をモデル化する。そして、これを拡張することにより、たとえば救助活動や消火活動などの避難以外の行動を導入したとき、対立する二つの行動間でジレンマ状態に晒されるエージェントの行動モデルを提案する。

2. 反応閾値モデル

同調行動とは、（自分の意志や意図でなく）他者の行動により自分の行動を決定する一連の行為の連携であり、心理学や社会学、動物行動学など様々な分野で研究されている。同調行動が発生するためには、集団の中に、自分の意志によって行動する個体と、他人の行動に影響されて行動する個体の二種類が必要になる。前者がいなければ、集団中にいかなる行動も発生しえないので、このことは明らかであろう。以後、前者をリーダー、後者をフォロワーと呼ぶことにする。

同調行動を記述するには、集団をリーダーとフォロワーに割り当てる必要がある。そのため、どの個体をリーダーにし、どの個体をフォロワーにするか、その役割は永続的なのか動的に変わるのか、リーダーとフォロワーの比率はどれくらいで、その比率は定常的なのか動的に変化するのか、変化するのであればその規則はどんなものなのか、といった疑問に答える必要が出てくる。本稿ではこれらを説明するモデルとして、生物学や生態学の分野で、真社会性生物の分業の説明に使用される反応閾値モデル [Bonabeau 96] を採用する。

実行すべきタスクがあり、そのタスクに関連付けられた刺激 s があるとする。タスクに従事する個体数が少なく、遂行度が十分でない時、刺激 s は増加し、タスク遂行が十分なとき s は抑制される。個体は心的状態を表す確率変数 X と個別の反応閾値 θ をもつ。$X = 1$ のとき個体は活動的であり、$X = 0$ のとき非活動的である。個体は以下の確率で活動的になる。

$$P(X = 0 \to X = 1) = \frac{s^2}{s^2 + \theta^2} \tag{1}$$

個体は以下の固定確率で非活動的になりタスク遂行を止める。

$$P(X = 1 \to X = 0) = \epsilon \tag{2}$$

タスクに関連した刺激の強度は以下の式により与えられる。

$$s(t + 1) = s(t) + \delta - \alpha \frac{c}{C} \tag{3}$$

ただし、δ は単位時間あたりの刺激の増加量、α はタスク遂行効率のスケールファクター、c は現在タスクに従事する個体数、C は全体の個体数を表す。

3. 避難意思決定モデル

2. 節で示した反応閾値モデルを避難シミューションに適用するための避難意思決定モデルを提案する。実行すべきタスクとしては、部屋を表す閉鎖空間内にいる全てのエージェントが部屋の外に出る作業とする。エージェントは二つの心的状態をとり、$X = 1$ のときはリーダーとして自分の判断で避難を行い、$X = 0$ のときはフォロワーとして近傍内の最も多いエージェントの取る行動に同調する。

連絡先: 鶴島　彰
セコム株式会社 IS 研究所
a-tsurushima@secom.co.jp



図 1: 避難シミュレーションの例

式 3 における c と C は、実際には各エージェントが知ることが難しい大域的な情報なので、これらの代わりにタスクの遂行状況を指し示す局所的な推定値を導入する。ここでのタスクは、全エージェントが部屋から出る事なので、各エージェントの周囲のエージェント数がその推定値として利用できる。作業の遂行度を推定する進捗関数 F を次のように定義する。

$$F(n) = \begin{cases} 1 - n/N_{max} & n < N_{max} \\ 0 & \text{otherwise,} \end{cases} \tag{4}$$

ここで、n はエージェントの近傍にいるエージェント数、N_{max} は近傍における最大エージェント数を表す固定値である。

部屋または空間を表す環境は、客観的なリスクを表す値 r を持っており、この情報には室内の全てのエージェントがアクセスできる。環境内の全ての場所においてリスク値は同一であるとする。エージェントは、個体に固有の値 θ と μ を持ち、θ は反応閾値、μ はエージェントのリスク感度を表すパラメータである。各エージェントのリスク認知 R を以下の関数で表す。

$$R(r) = \frac{1}{1 - e^{g(r-\mu)}} \tag{5}$$

ただし、g はシグモイド関数の曲率を表すパラメータである。

避難タスクの刺激 s として、式 3 の刺激抑制項を、タスクの進捗に加えて、個体の安全の認知（1 からリスク認知を引いたもの）で拡張し、以下のように定義する。

$$s(t+1) = max\{s(t) + \hat{\delta} - \alpha(1-R)F,\ 0\} \tag{6}$$

ただし $\hat{\delta}$ は単位時間あたりの刺激の増加分である。

$$\hat{\delta} = \begin{cases} \delta & \text{if } r > 0 \\ 0 & \text{otherwise,} \end{cases} \tag{7}$$

s は時間とともに増大するが、$r < \mu$ のとき、または近傍の人数が少なくなったとき、α が働き抑制的となる。また、タスクが十分以上に遂行された事を意味する負の値をとると、式 1 が正となり、不必要に活動的になってしまう事を避けるため非負としている。

図 1 に避難意思決定モデルを組み込んだエージェントによる避難シミュレーションの例を示す。この例では 16×128 グリッドの部屋に配置された 600 人のエージェントが、線形に増加する r 値によって避難行動を行っている様子が示されている。室内のエージェントは唯一の出口がある左方向に向かって避難を行っている。図において赤で示されたエージェントは $X = 1$ のもの、緑で示されたエージェントは $X = 0$ かつすでに行動中のもの、黄色で示されたエージェントは $X = 0$ かつまだ行動を起こしていないものである。

図 1 は避難の途中であるが、エージェントは空間に一様に分布しておらず、所々に塊を作りながら不均一に分布している。また未だ行動を起こしていない（黄色い）エージェントが、出口から最も遠い右端にのみ分布している。これは、全てのエージェントが左方向に移動するため、部屋の右端にいるエージェントは同調行動の影響を受けにくいためである。

4. 複数タスク避難意思決定モデル

3. 節で示した避難意思決定モデルは、全てのエージェントは部屋から外に出るという、単一のタスクしか持っていなかった。本節では避難タスクに加えて、救助活動や消火活動といった新たなタスクを導入して、複数タスクの遂行を求められるエージェントをモデル化する。エージェントが実行できるのは、一度に一つのタスクのみのため、シミュレーション中のエージェントは対立する二つのタスク間でジレンマ状態に置かれている。

エージェントは、避難タスクを表す X_1、消火タスクを表す X_2 の二つの確率変数をもち、確率変数が 1 を取るとき、そのタスクに従事するとする。ただし二つの確率変数が同時に 1 を取ることはないものとする。X_1、X_2 がどちらも 0 のとき、エージェントはフォロワーの状態にあり同調行動を行う。同調行動では、周囲のエージェントが行っている行動のうち、最も従事しているエージェント数の多い行動を行う。

エージェントは X_1、X_2 のそれぞれに対し、反応閾値 θ_1、θ_2 と、タスクに関する刺激 s_1、s_2 を持つ。X_1 に対する進捗関数 F_1、タスク刺激 s_1 は、それぞれ式 4、式 6 と同じであるが、X_2 の進捗関数に関しては消火タスクへの過剰な割当てを防ぐ目的で、

$$F_2(n) = \begin{cases} 1 - abs(\frac{n_2 - \xi}{N_{max}}) & n_2 < N_{max} \\ 0 & \text{otherwise,} \end{cases} \tag{8}$$

とした。さらにタスク刺激を

$$s_2(t+1) = max\{s_2(t) + \hat{\delta_2} - \alpha_2 R F_2,\ 0\} \tag{9}$$

とする。ただし式 8 の n_2 は消火タスク X_2 に従事しているエージェント数、ξ は局所領域あたりの消火タスクに対するエージェントの最適割当数を表し、$r > \mu$ かつ $n_2 = \xi$ のとき最も抑制的になることを意味する。

環境のリスク r は、n_2 により以下のように変化する。

$$r(t+1) = max\{r(t) - \gamma n_2 + \pi,\ 0\} \tag{10}$$

ただし γ は消火タスクに関するスケールファクター、π は単位時間あたりの増加分とする。

以上より、複数タスク避難意思決定モデルは以下のようになる。

$$P_1(X_1 = 0 \to X_1 = 1) = \frac{s_1^2}{s_1^2 + \theta_1^2} \tag{11}$$

$$P_2(X_2 = 0 \to X_2 = 1) = \frac{s_2^2}{s_2^2 + \theta_2^2} \tag{12}$$

$$P_1(X_1 = 1 \to X_1 = 0) = \epsilon_1 \tag{13}$$

$$P_2(X_2 = 1 \to X_2 = 0) = \epsilon_2 \tag{14}$$

エージェントが実行できるタスクは一度に一つなので、X_1、X_2 のうちから一つを選ばねばならない。この競合解消法として、

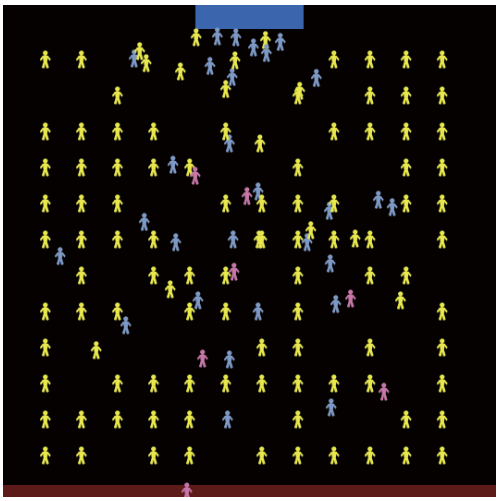


図 2: 避難消火シミュレーションの例

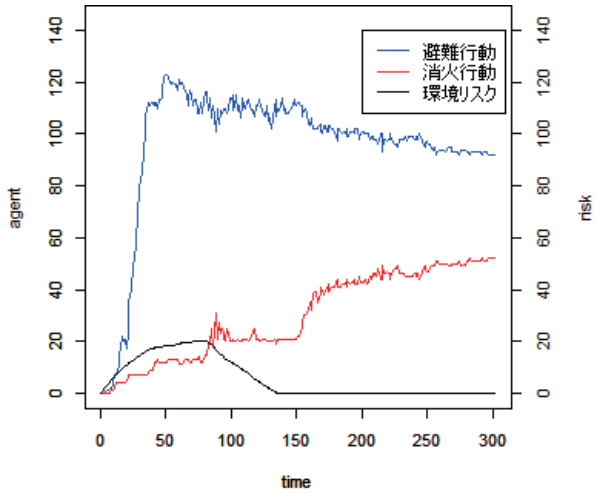


図 3: 環境リスクと避難行動、消火行動の変化

$P_i(X_i = 0 \to X_i = 1) > P_j(X_j = 0 \to X_j = 1) + offset$ を i への状態遷移の条件とし、X_i、X_j の値に関わらず常に P_i、P_j を計算し、その差が $offset$ 以上になると $X_i = 1 \wedge X_j = 0$ に遷移する。

5. 避難消火シミュレーション

本節では、避難と消火の二つのタスクを想定したシミュレーションについて説明する。図 2 のような 40×40 グリッドの部屋に、144 人のエージェントが整列して配置されている。144 人のエージェントには、θ_1 と θ_2 と μ が $(0, 100]$ の範囲でランダムに割り当てられている。部屋上部の青い部分は部屋からの出口を、下部の薄赤の部分は消火活動の行われる場所を示している。青いエージェントは $X_1 = 1$ のもの（避難行動）、赤いエージェントは $X_2 = 1$ のもの（消火行動）、黄色いエージェントは $X_1 = 0 \wedge X_2 = 0$ のものである。シミュレーションの初期には全てのエージェントは黄色で、一定の間隔で室内に配置されている。避難行動を行うエージェントは出口に向かって移動し、消火行動を行うエージェントは、$r > 0$ なら部屋の下部に向かって移動し、そうでなければ初期の配置に戻る。シミュレーション初期には環境のリスクは $r = 0$ で、シミュレーションが開始されると式 10 に従って変化していく。

図 2 は、シミュレーションを開始してすぐの画面である。リスク値の増加により、すでに多くのエージェントが避難を開始しており、それらの中には同調行動を行う黄色のエージェントも混じっている。また、比較的少数のエージェントが消火活動に従事しているのも見られる。

この後エージェントには、避難行動をするもの、消火行動をするもの、同調行動により避難や消火をするもの、一方の行動を打ち切り別の行動に切り替えるもの、一度は部屋から出たにも関わらず再び戻って来るもの、一度動き出したにも関わらず再び停止してしまうものなど、多様な行動をとるものが現れ、シミュレーションは複雑な様相を示すようになる。シミュレーション終了時には、ほとんどのケースで消火に成功するが、消火に失敗し、全てのエージェントが避難して無人になってしまうこともある。なお、上記のシミュレーションで使ったパラメータは、$\epsilon_1 = 0.3$、$\epsilon_2 = 0.0$、$\delta_1 = 1.0$、$\delta_2 = 0.2$、$\alpha_1 = 1.2$、$\alpha_2 = 1.2$、$g = 1.0$、$N_{max} = 10$、$\xi = 5.4$、$\gamma = 0.05$、$\pi = 0.7$ である。また、エージェントの進行方向に向かって 180 度、半径 10 グリッドの範囲をエージェントが影響を受ける近傍であるとした。

6. 分析

図 3 に、シミュレーション中の環境リスク、避難行動、消火行動に携わるエージェント数の変化の一例を示す。シミュレーションが始まるとすぐに、同調行動により避難行動をとるエージェントが増加するが、同時に少数のエージェントが消火活動を行う。やがて消火エージェントが増えると環境リスクが減少し、それにともなって消火エージェント数が増え、避難エージェント数が減少していく。

避難意思決定モデルは、エージェントの心的状態の確率的変化を記述したモデルであるから、シミュレーション期間中のエージェントの心的状態の遷移を分析することにより、エージェント全体の動きを調べることができる。ここで、避難消火シミュレーションを 20 回行った結果の、2880 人（144 人 × 20）のエージェントの心的状態が、シミュレーション中にどう変化したかについて分析してみよう。

同調行動を 0、避難行動を 1、そして消火行動を 2 とした時、各行動間の遷移の頻度を図 4 に示した。図を見ると、同調行動 (0) と避難行動 (1) の間で頻繁に遷移が起きているが、消火行動 (2) と他の行動の間ではほとんど遷移が起きない事が読み取れる。これは、$\epsilon_2 = 0.0$ と設定したことと、δ_1、δ_2 に大きな差があることが主な原因となっている。しかし X_1、X_2 のパラメータを同じにしても、避難行動と消火行動間の遷移はほぼ発生せず、二つの行動間で遷移が起きるのは、ほとんどの場合、同調行動を通してであることが分かった。

状態遷移の頻度によりエージェントを特徴づけるため、階層型クラスタリングを使って、2880 人のエージェントを四グループに分類した (表 1)。大多数が属するグループ 1 のエージェントは、避難行動と同調行動を交互に繰り返す。グループ 2 は、避難と消火の両方を行うが、両者間の遷移は頻繁ではなく、しばらく一方を行ってから他の行動に移るという動きである。グループ 3 は、同調行動によって消火行動に従事する例外的なエージェントで、グループ 4 はほぼ常に消火活動に従事するエージェントである。このように同調行動は、消火よりも避難に対してより強く働く。

これらのグループと、エージェントのもつ反応閾値との関係を示したのが図 5 である。図 5 は、横軸に θ_1 縦軸に θ_2 を取っ

グループ	size	$0 \to 1$	$1 \to 0$	$0 \to 2$	$2 \to 0$	$1 \to 2$	$2 \to 1$	$0 \to 0$	$1 \to 1$	$2 \to 2$
1	2178	0.1900	0.1884	0.0009	0.0	0.0001	0.0006	0.1583	0.4402	0.0215
2	411	0.0426	0.0445	0.0052	0.0	0.0002	0.0021	0.1550	0.1032	0.6472
3	26	0.0037	0.0040	0.0033	0.0	0.0	0.0004	0.7107	0.0085	0.2694
4	265	0.0024	0.0026	0.0035	0.0	0.0002	0.0004	0.0736	0.0052	0.9119

表 1: 状態遷移の頻度によるエージェントの分類

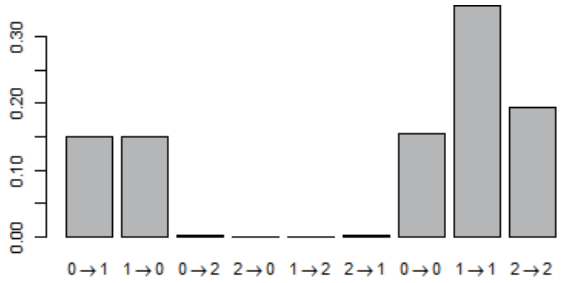


図 4: 心的状態の遷移の頻度

た散布図に各グループを示したものである。図から、グループ 1 はパラメータに関わらず空間全体に広がり、グループ 2 と 4 は θ_2 に影響され、特にグループ 4 はその傾向が強く、グループ 3 は主に θ_2 が大きい領域で例外的に現れる事が分かる。

7. まとめと今後の課題

避難意思決定モデルは、反応閾値モデルをベースに、避難状況での人間の同調行動を再現したもので、これまで筆者らが避難状況における人口密度の影響や、出口選択問題 [Helbing 00] の分析などに活用してきたものを、消火などの複数タスクがある状況へと拡張したものである。むろん 6. 節で示したような行動は、θ_1, θ_2, μ などのパラメータ設定に左右され、設定によっては二つの状態間での振動が頻繁になるなど不自然な動きも起きるが、本モデルは避難状況での様々な行動を再現する潜在力をもつと考えている。

本モデルは心理的な要因のみを扱ったものであり、人間行動のモデルとしては、高次認知と物理的要因という二つの重要な要素が欠けている。たとえば、本稿で示したシミュレーションでは、エージェントは最短経路を探索しようともしないし、目の前に他人がいてもそれを通り抜けてしまう。現実的なシミュレーションを行うには、これら二つは不可欠であろう。同時に避難意思決定モデルは、複数の心的状態を確率的に切り替える単純なモデルに過ぎず、それらの状態のとき何を行うかについては言及していない。だから、心的状態のひとつを高次認知のモデルにしたり、本モデルの出力を、たとえば [Helbing 00] のモデルなどに繋げることで、高次認知や物理的行動モデルと自然に繋げていくことは、おそらく容易であろうと考える。

最後に、避難意思決定モデルの実証的な検証は困難で、特に現実のデータが乏しい避難状況などに関しては極めて難しい。この問題については、やや遠回りではあるが、たとえば出口選択問題のような、人間の認知過程が影響すると考えられる、避難状況に特異な現象をひとつひとつ定性的に再現してみせることによりアプローチしていきたい。

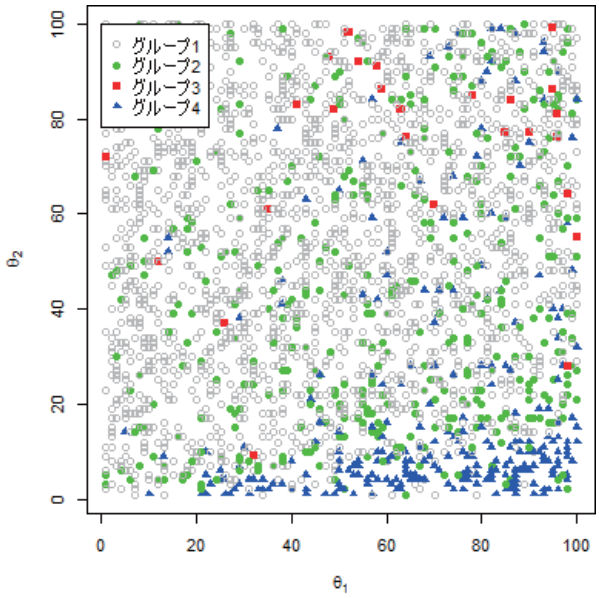


図 5: 反応閾値とエージェントの種類

参考文献

[Bonabeau 96] Bonabeau, E., Theraulaz, G., and Deneubourg, J.-L.: Quantitative study of the fixed threshold model for the regulation of division of labour in insect societies, *Proceedings of The Royal Society B*, Vol. 263, No. 1376, pp. 1565–1569 (1996)

[Bulumulla 17] Bulumulla, C., Padgham, L., Singh, D., and Chan, J.: The importance of modeling realistic human behaviour when planning evacuation schedules, in *Proceedings of the 16th International Conference on Autonomous Agents and Multiagent Systems AAMAS 2017*, pp. 446–454 (2017)

[Helbing 00] Helbing, D., Farkas, I., and Vicsek, T.: Simulating dynamical features of escape panic, *Nature*, Vol. 407, No. 28, pp. 487–490 (2000)

[Tsai 11] Tsai, J., Fridman, N., Bowring, E., Brown, M., Epstein, S., Kaminka, G., Marsella, S., Ogden, A., Rika, I., Sheel, A., Taylor, M. E., Wang, X., Zilka, A., and Tambe, M.: ESCAPES - evacuation simulation with children, authorities, parents, emotions, and social comparison, in *Proceedings of 10th International Conference on Autonomous Agents and Multiagent Systems AAMAS 2011*, pp. 457–464 (2011)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

合意形成過程の蓄積・知識化のための LOD技術に基づく議論過程クラウドの設計と課題

福田 直樹 *1
Naoki FUKUTA

*1静岡大学 学術院情報学領域
Colledge of Informatics, Shizuoka University

In this paper, we present our preliminary design and issues of a mechanism with a set of software and tools for storing online discussions and arguments with linked open data accesses to make it as a great knowledge repository. The prototype design is based on Linked Data and Knowledge Graph structure and it includes mechanisms which aim to realize effective accesses to the stored structured discussion data.

1. はじめに

人と人との間の，あるいはその集団としての社会における合意形成の効果的な支援の必要性やその課題についての議論は，民主主義にかかわり長く行われてきた議題の 1 つである．効果的な議論と合意形成のための条件については，フィシュキンらの熟議に基づく民主主義 [Fishkin 09] などの文脈でも，市民の関与を単に世論調査のようなアンケートに答える程度の浅いもので求めても「合理的無知」などにより有効な「民意」の抽出が難しいことが言われており，社会的な合意形成への市民の関与を高めることへの重要性と課題が議論されている [篠原 12]．

社会的問題解決に向けた討議では，古くは J.S. ミルの自由論 [Mill 59] にあるのように，議論の論拠の正しさに基づくことで議論の結果や正当性を担保することの重要性がいわれており [Fishkin 09]，そのための論拠の 1 つとして，オープンなデータの活用は 1 つの選択肢である．

議論における主張への論証の適切さの評価については，議論の論理構造に基づいて，論理に基づいて分析評価するアプローチも行われている [Walton 16]．議論の論理構造の定式化については，Argumentation および非単調推論の分野における Dung 意味論 [Dung 95] が広く知られる．Dung 意味論では議論同士の論破関係そのものを計算するための論理は規定せずそのフレームワークのみを規定しているため，その個々の主張の間における矛盾関係や非整合性を導出する論理の準備は利用者に委ねられていることから，そのための枠組みとして，議論の構造を規定するオントロジーやそれに基づく推論の活用が 1 つの可能性として考えられる．

議論の過程や結果への理解を深めるのに役立つような閲覧支援の実現が課題となる [福田 16b][福田 17a][Fukuta 16] と同時に，そのための議論過程を効果的に蓄積して知識化し，活用するための基盤の実現も，重要な課題の 1 つとなる．本研究では，特にこの点に焦点を絞り，特に議論過程の蓄積と知識化のための基盤の基本設計を示すことで，個々の議論における構造や関係性についての深い理解を促すことを目的とした，議論過程やその関係性の閲覧支援機構の実現を可能とするための方策について述べる．

2. 議論過程の知識化の重要性

実世界とインターネット上などのオンライン上の議論とをあわせたハイブリッドな議論について，その実現についての試みが報告されつつある [Ito 16]．それら 1 つ 1 つの議論には，興味深く目を向けるべきものが多くあると考えられ，ある 1 つの大きなテーマ内であれば，ファシリテーターなどをうまく動員してそれらをうまく結びつけられる可能性も十分に考えられる．一方で，その議論をさらに深め確実なものとするには，時期やテーマを超え，議論の過程やその際の情勢，その後の経過などを含めて，より広い範囲での議論の参照が重要となってくる．特に，その議論の背景に深い歴史的背景やそれに起因する対立などがある場合には，その重要性大きいと考えられる [福田 16a][福田 17b]．

文脈に基づいて社会的合意のための議論を深いレベルで行うためには，過去の社会的合意形成問題における種々の議論がそこに適切に継承・参照されることが望ましい [武田 13] と考えられる．社会的合意を目指す当事者の個人的な利害関係や立場が原因となって，武田の指摘するような「囚人のジレンマ的な状況で相互の議論を噛み合う状態になるようにお互いが譲歩できない状況」[武田 13] を乗り越えるための 1 つのアプローチとして，過去に積み重ねられ蓄積されてきた議論が LOD のような枠組みによって再利用可能となり，社会的合意形成における議論にすみやかに参照可能とされることが望ましい [福田 16b][福田 17b]．

3. 議論過程の知識化に向けた機構設計と 課題

議論過程の知識化に向けた課題に対応するための基盤として，設計を進めてきた社会的合意のための議論の過程に対する関係性の付与・閲覧支援機構 [福田 17a] を，さらに複数の異なる議論過程に拡張し，議論過程や関連するデータの閲覧支援に適用可能にするための機構の設計の概要について，文献 [福田 17b] で述べている．この機構は，議論における主張間の相互関係性の記述の拡張およびその利用をを効果的に行えるようにするために，LOD に基づく関係性の記述や拡張を議論閲覧支援機構の設計に適用可能としており，そのためのソフトウェアおよびフレームワークの設計についても，文献 [福田 17b] において，あわせて述べている．

この機構の設計では，それぞれの議論のテーマやその議論が行われた環境，時期などの，議論が行われた状況に対するメタデータの付与が，必ずしも考慮されていないことから，そのための機構を新たに追加していく必要がある．ここでの課題として，仮に 1 つの議論の過程が短時間にわたるものであったとしても，それらの議論の過程を複数，長期間にわたって蓄積していこうとする場合には，それらの議論過程に対するメタデータの付け方のニーズも，多様化し，変化していくことが考えら

連絡先: 福田直樹，静岡大学 学術院情報学領域，432-8011 浜松市中区城北 3-5-1，fukuta (at) inf.shizuoka.ac.jp

れる．そのようなメタデータの多様性と変化 (drift) に対して許容的な設計を行うことが，長期間にわたって議論過程を蓄積し知識化することを試みる際には重要な課題となる．

これまでに，著者らは，文献 [Fujino 12] などで，LOD に対するオントロジーマッピング技術を適用した柔軟な検索・順序づけ技術を開発・提案してきている．これらは，クエリの記述を適切に行う必要があるという点に課題があるが，多様性や変化がメタデータに対するオントロジーに生じた場合でのシステムの許容性の向上に役立つと考えられる．

議論過程の閲覧支援としては，すでに文献 [福田 17b] において，その初期の設計の概要を示している．本研究で主に扱う議論過程は基本的に [福田 17b] と同様の前提をおいている．その前提とは，議論が，その議論当初には実空間における対面での議論が組み合わされる場合もあるが，発言の投稿とそれに対する返信という構造を基本として，Web 上におけるオンライン議論として構成され，それらに「いいね」等の付加情報が付与される形で構成される [Ito 17]，ということである．また，その議論の過程では，ファシリテーターと呼ばれる議論の整理や進展を促す役割のユーザにより，通常のユーザとは異なる権限により議論の方向性などに対する調整が行われる場合があることも，前提とする．ここで，長期的に議論過程を蓄積していった場合には，これらの前提が時間の経過や環境の変化によって異なるものに変容・多様化していくことが想定される．そうした変化に寛容な閲覧支援技術の実現が，重要な課題の 1 つとなる．

議論内に見られる要素間の種々の関係には，文献 [福田 17b] における閲覧機構では，当初の発言・返信関係とあわせて，議論どうしの関連性や根拠他関連データなどとの関連づけが行われ，その情報も併せて表示できることを許容している．また，Carroll らで提案された関係性そのものに ID を付与する手法 [Carroll 05] と併用することで，それらの関連づけに対するメタなアノテーションが可能となる [福田 17a]．ここでの課題は，その関連づけに対するメタなアノテーションの基盤となるオントロジーそのものも，ニーズや社会の変化にあわせて深化し，多様化することが考えられる．そのようなオントロジーの変更や変化への許容性と高速な計算可能性の両立は，重要な課題の 1 つとなる．

4. おわりに

議論などの理解の支援では，論証内のミクロな係り受け関係をより上位の抽象度の関係でとらえていくことと同時に，それぞれの信念や立場に基づいたときに，それらがどのように見えるのかを理解していくことが，重要な一助となると考えられる．このために，異なる視点からの議論の見え方に関しての論理的な構造をふまえた分析・閲覧支援を論理的矛盾なども踏まえて行えるようにすることは，今後の課題である．

謝辞

本研究の一部は，JST CREST JPMJCR15E1 の支援を受けたものである．

参考文献

[Carroll 05] Carroll, J. J., Bizer, C., Hayes, P., and Stickler, P.: Named Graphs, Provenance and Trust, in *Proc. of the International World Wide Conference (WWW2005)*, pp. 613–622 (2005)

[Dung 95] Dung, P. M.: On the acceptability of arguments and its fundamental role in nonmonotonic reasoning, logic programming, and n-person games, *Artificial Intelligence*, Vol. 77, pp. 321–357 (1995)

[Fishkin 09] Fishkin, J. S.: *When the People Speak: Deliberative Democracy and Public Consultation*, Oxford University Press (2009)

[Fujino 12] Fujino, T. and Fukuta, N.: SPARQLoid - a Querying System using Own Ontology and Ontology Mappings with Reliability, in *Posters and Demonstrations Track, The 11th International Semantic Web Conference(ISWC2012)* (2012), (demonstration)

[Fukuta 16] Fukuta, N.: Toward A Linked-Open-Data-based Architecture for an Open Consensus Building Support, in *Proc. of 1st International Workshop on Possibilities and Challenges for Smarter and more Democratic crowd Decision-Making (SDDM2016)*, pp. 135–138 (2016)

[Ito 16] Ito, T., Otsuka, T., Kawase, S., Sengoku, A., Shiramatsu, S., Matsuo, T., Oishi, T., Fujita, R., Fukuta, N., and Fujita, K.: Preliminary Results on A Large-scale Cyber-Physical Hybrid Discussion Support Experiment, in *Proc. of 11thInternational Conference on Knowledge, Information and Creativity Support Systems (KICSS 2016)* (2016)

[Ito 17] Ito, T., Otsuka, T., Kawase, S., Sengoku, A., Shiramatsu, S., Ito, T., Hideshima, E., Matsuo, T., Oishi, T., Fujita, R., Fukuta, N., and Fujita, K.: Experimental Results on Large-scale Cyber-Physical Hybrid Discussion Support, *International Journal of Crowd Science*, Vol. 1, (2017)

[Mill 59] Mill, J. S.: *On Liberty*, John W. Parker and Son (1859)

[Walton 16] Walton, D.: *Argument Evaluation and Evidence*, Springer (2016)

[篠原 12] 篠原 一（編）: 討議デモクラシーの挑戦–ミニ・パブリックスが拓く新しい政治, 岩波書店 (2012)

[武田 13] 武田 徹 : 原発議論はなぜ不毛なのか, 中央公論新社 (2013)

[福田 16a] 福田 直樹 : 合意形成支援システムの高度化のための LOD 連携機構の概念設計, 2016 年人工知能学会全国大会講演論文集, pp. 1N4–OS–19a–2 1–2 (2016)

[福田 16b] 福田 直樹 : 社会的合意形成支援に向けたオントロジーと LOD の活用方法の検討, セマンティック Web とオントロジー研究会, pp. SIG–SWO–038–10 1–3 (2016)

[福田 17a] 福田 直樹 : 議論に基づく合意形成支援における議論構造を考慮した議論過程 LOD の閲覧支援機構の設計, セマンティック Web とオントロジー研究会, pp. SIG–SWO–041–07 1–2 (2017)

[福田 17b] 福田 直樹 : 合意形成過程の再利用に基づく LOD 技術による議論過程検索提示機構の設計, 2017 年人工知能学会全国大会講演論文集, pp. 1P3–4 1–2 (2017)

[1E1] [General Session] 1. Basis / Theory

座長:新田 克己（産業技術総合研究所）

Tue. Jun 5, 2018 1:20 PM - 3:00 PM Room E (4F Queen)

[1E1-01] A Cunning Ant System with Multi-Pheromones for Constraint Satisfaction Problems

○Takuya Masukane[1], Kazunori Mizuno[1] （1. Takushoku University）

1:20 PM - 1:40 PM

[1E1-02] Algorithm of Traveling Salesman Problem using Particle Swarm Optimization

○Yamada Yuki[1], Anada hajime[1] （1. Tokyo City Univercity）

1:40 PM - 2:00 PM

[1E1-03] Toward Optimal Parameters for ACO in Data Clustering

○Takayuki Nakayama[1], Kazunori Mizuno[1] （1. Takushoku University）

2:00 PM - 2:20 PM

[1E1-04] Conversion from Logic Programming Language PROLEG to Bipolar Argumentation Framework

○Tatsuki Kawasaki[1], Kazuko Takahashi[1] （1. Kwansei Gakuin University）

2:20 PM - 2:40 PM

[1E1-05] A Proposal of Qualitative Spatial Representation Focused on Change of Shapes

○Momo Tosue[1], Kazuko Takahashi[1] （1. Kwansei Gakuin University ）

2:40 PM - 3:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

複数種類のフェロモンを用いたcASによる制約充足問題の解法

A Cunning Ant System with Multi-Pheromones for Constraint Satisfaction Problems

増金拓弥 *1　　水野一徳 *1
Takuya Masukane　　Kazunori Mizuno

*1拓殖大学工学部情報工学科
Department of Computer Science, Faculty of Engineerig, Takushoku University

To solve hard constraint satisfaction problems, ant colony optimization, ACO, based meta-heuristics is proposed. However, ACO based algorithms should be sometimes ineffective because the algorithms have only single pheromone trail. In this paper, we propose an ACO based model with multiple pheromone trails. Each artificial ant constructs a candidate assignment by referring several pheromone trails to find solutions satisfying all constraints. We also implement the proposed model to the cunning ant system algorithm based on ACO. Then we evaluate the effectiveness of our proposed model for solving graph coloring problems.

1. はじめに

制約充足問題 (Constraint Satisfaction Problem: CSP) は，離散値をとるいくつかの変数について割り当て可能な値の組合せのうち，与えられた全ての制約を満たす組合せを探索によって発見する問題である．CSP は設計や計画問題などをはじめ，人工知能分野やパターン処理分野などの広い分野にわたって応用されている基盤的技術である．

CSP を解く際，網羅的に割当てられる全ての値の組合せを調べることで，必ず解を見つけることはできる．しかし，問題のサイズが大きくなると，網羅的な探索では実用時間内に解を発見することは困難である．そこで近年では，そのような大規模な CSP を解くための手法として，山登り法などを基本アルゴリズムとした，反復改良型のアルゴリズムの研究が盛んに行なわれている．だがそれらのアルゴリズムには，局所最適解に陥りやすい，局所最適解に陥った際にそこから抜け出すのが難しいといった欠点がある．そのため，局所最適解に陥りづらい，もしくは，局所最適解に陥った際にそこから効率よく抜け出すための手法として，メタヒューリスティクスに注目が集まっている．

そのようなメタヒューリスティクスの 1 つに，蟻コロニー最適化というものがある．蟻コロニー最適化は，蟻のフェロモンコミュニケーションをモデル化したメタヒューリスティクスであり，巡回セールスマン問題 (Traveling Salesman Problem: TSP)，グラフ彩色問題 (Graph Coloring Problem: COL)，車両配送問題 (Vehicle Routing Problem: VRP) など多くの組合せ最適化問題や制約充足問題に有効な手法として取り入れられている [1, 2, 4, 5, 6].

蟻コロニー最適化をもとにしたアルゴリズムはフェロモンをもとに解候補を生成するが，探索の過程次第では局所最適解に陥っているような状態になってしまう可能性があると考えられる．本研究では，そのような状態に陥ってしまうことを避けるために，解候補生成の指標となるフェロモンを複数種類用いるモデルを提案する．また，この提案モデルを従来の ACO アルゴリズムに適用し，提案モデルの有効性を実験的に示す．

連絡先: 増金拓弥，拓殖大学工学部情報工学科，
東京都八王子市館町 815-1，
042-665-0519，phsl.masukane@gmail.com

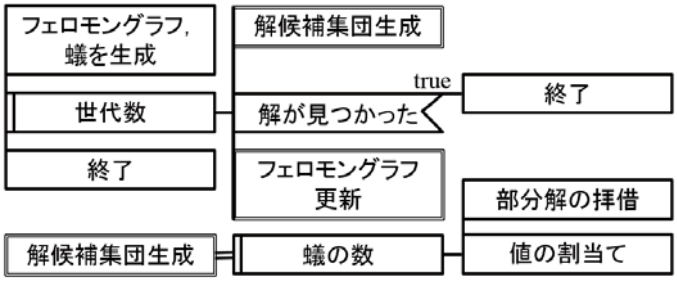


図 1: cAS のアルゴリズム

2. 研究分野の概要

2.1 グラフ彩色問題

グラフ彩色問題 (graph coloring problem: COL) は制約充足問題における基本的な問題である．そのため，アルゴリズムを評価するためのベンチマークとしてしばしば用いられる [10, 11, 13]．グラフ彩色問題における制約充足解は，無向グラフにおいて隣接する頂点同士が同じ色に彩色されていないような彩色パターンである．特に，全ての頂点を 3 色で塗り分ける問題を 3COL と呼ぶ．ここで，無向グラフの頂点数を n，辺数を c とした際，制約密度 d を $d = c/n$ と定義する．3COL において，$d = 2, 3 \sim 2.4$ の領域は相転移領域と呼ばれ，難しい問題が集中していることがわかっている [3, 8, 11].

2.2 蟻コロニー最適化

蟻コロニー最適化 (Ant Colony Optimization: ACO) は，蟻の採餌行動をモデル化したメタヒューリスティクスである [6]．蟻は餌から巣まで戻る際，通った経路にフェロモンを落とす．餌から巣までの経路が長い場合，フェロモンが堆積するよりも早く蒸発してしまう．逆に短い経路であればフェロモンが堆積していく．つまり，餌から巣の距離が短く，蟻が巣まで戻るのにより適した経路が残っていく．このような過程が最適化手法として用いられている．

2.3 カニングアントシステム

カニングアントシステム (cunning Ant System: cAS) は，ACO をもとにした探索アルゴリズムの 1 つである [14]．図 1 に cAS のアルゴリズムを示す．cAS を含む ACO アルゴリズムは，各世代の各蟻が 1 つずつ解候補を持つことによる集団探索を行なう．ACO アルゴリズムの解候補生成は確率的に行なわれる．任意の解候補 A における任意の変数 x_j に対して任意の値 v を割当てる確率 $p_A(< x_j, v >)$ は，以下の式で与えられる．

$$p_A(< x_j, v >) = \frac{[\tau_A(< x_j, v >)]^\alpha [\eta_A < x_j, v >)]^\beta}{\sum_{w \in D_j} [\tau_A(< x_j, w >)]^\alpha [\eta_A(< x_j, w >)]^\beta}, \quad (1)$$

$$\tau_A(< x_j, v >) = \sum_{< x_k, u > \in A} \tau(< x_k, u >, < x_j, v >),$$

$$\eta_A(< x_j, v >) = \frac{1}{1 + conf(\{< x_j, v >\} \cup A) - conf(A)},$$

ただし，$\tau(< x_k, u >, < x_j, v >)$ は “値 u を割り当てた変数 x_k” と “値 v を割り当てた変数 x_j” 間に溜まっているフェロモンの量を，$conf(A)$ は解候補 A の制約違反数をそれぞれ表している．また，α と β はそれぞれフェロモンと制約違反を重視する重みを表している．全ての蟻が解候補を生成した後，フェロモングラフの更新を行なう．フェロモングラフにおけるフェロモン量 $\tau(< x_k, u >, < x_j, v >)$ の更新式を以下に示す．

$$\tau(< x_i, u >, < x_j, v >) = (1 - \rho) \times \tau(< x_i, u >, < x_j, v >) + \Delta\tau$$

$$\Delta\tau = \begin{cases} \frac{1}{conf(A_{best})}, & (< x_i, u >, < x_j, v >) \in A_{best} \\ 0, & otherwise \end{cases}$$

ただし，ρ はフェロモンの蒸発率，A_{best} は集団内で最も評価の高い解候補を表している．

cAS の特徴は，図 1 における “部分解の拝借” である．多くの ACO アルゴリズムは，各世代において前世代の解候補を全て破棄し，初めから解候補を生成する．しかしこれでは，前世代に生成された高品質な部分解を利用することができない．また，全ての世代で解候補を初めから生成すると，解候補生成に時間がかかってしまう．cAS では，値の割当てを行なう前に，前世代が生成した解候補の 1 部を拝借することで，前述した ACO アルゴリズムの欠点を補っている．cAS の有効性は実験的に示されている [7, 12]．

3. 提案手法

3.1 基本方針

cAS をはじめとする ACO を用いたアルゴリズムは，探索が進んでいくにつれてフェロモングラフの状態が徐々に固定されていく傾向にある．解候補はフェロモンに従って生成されるため，フェロモンの溜まり方次第では，生成した解のほとんどが制約充足解になり得ないものになってしまい，局所最適解に陥ってしまっているような状態になる可能性があると考えられる．このような欠点に対して本研究では，解候補を構築する際の指標として “新たな別の要素” を取り入れる．より多くの指標を用いて解候補を生成することにより，構築した解候補が局所最適解に陥ってしまっているような状態になることを避け，制約充足解の発見率の向上を目的とする．

本研究ではこの “新たな別の要素” を，従来のフェロモンとは異なるもう 1 つのフェロモンとする．これを “ネガティブフェロモン” と呼ぶこととする．ACO アルゴリズムにおける解候補の構築について，従来のフェロモングラフが高い評価をもつ解への収束を助ける働きをするのに対して，ネガティブフェロモンのグラフには低い評価をもつ解からの発散を助ける働きをもたせる．そこで，ネガティブフェロモングラフは従来のフェロモングラフとは対照的に，生成された解候補集団の中で最も評価の低い解候補を用いて更新されるものとする．本研究の基本方針は以下の 3 点である．

- 従来のフェロモングラフに加え，ネガティブフェロモングラフを生成する．
- 各蟻はこれらの 2 種類のフェロモンと制約違反数をもとに，確率的に解候補を生成する．
- 各世代の最後に，集団内の最も評価が高かった解を用いて従来のフェロモングラフを，最も評価が低かった解を用いてネガティブフェロモングラフをそれぞれ更新する．

3.2 アルゴリズム

本研究で提案するモデルを cAS に適用したものを cASNEP (cAS with NEgative Pheromone) とする．cASNEP が cAS と異なる点は後述する 2 点であり，その他については全く同じアルゴリズムである．

1 つは値を割当てるための確率式である．従来のフェロモングラフのみを参照する cAS における割当て確率の式 (1) とは異なり，cASNEP の値割当てには 2 つのフェロモングラフが参照され，その確率は以下の式 (2) で表される．

$$p_A(< x_j, v >) = \frac{\frac{[\tau_A(< x_j, v >)]^{\alpha_u} [\eta_A(x_j, v >)]^\beta}{[N\tau_A(< x_j, v >)]^{\alpha_n}}}{\sum_{w \in D} \frac{[\tau_A(< x_j, w >)]^{\alpha_u} [\eta_A(< x_j, w >)]^\beta}{[N\tau_A(< x_j, v >)]^{\alpha_n}}}, \quad (2)$$

$$N\tau_A(< x_j, v >) = \sum_{< x_k, u > \in A} N\tau(< x_k, u >, < x_j, v >),$$

ただし，$N\tau(< x_k, u >, < x_j, v >)$ は “値 u を割り当てた変数 x_k” と “値 v を割り当てた変数 x_j” 間に溜まっているネガティブフェロモンの量を表している．また，α_u と α_n はそれぞれ通常のフェロモングラフとネガティブフェロモングラフを参照する際の重みを表している．

もう 1 つは，ネガティブフェロモングラフの更新である．cASNEP では，従来のフェロモングラフを更新する処理とは別に，ネガティブフェロモングラフを更新する処理を行なう．以下に cASNEP におけるネガティブフェロモングラフの更新式を示す．

$$N\tau(< x_i, u >, < x_j, v >) = (1 - \rho) \times N\tau(< x_i, u >, < x_j, v >) + \Delta N\tau$$

$$\Delta N\tau = \begin{cases} conf(A_{worst}), & (< x_i, u >, < x_j, v >) \in A_{worst} \\ 0, & otherwise \end{cases}$$

ただし，A_{worst} は解候補集団内で最も評価の低い解候補を表している．従来のフェロモングラフの更新と比べると，解候補集団の中から最も評価が低い解を用いることの他に，“フェロモンの蓄積量” が異なっている．従来のフェロモンの蓄積量が解候補の制約違反数の逆数であったのに対して，ネガティブフェロモンの蓄積量は解候補の制約違反数そのものとする．これは，制約違反数が多い解候補生成を避けるためのネガティブフェロモングラフにおいて，制約違反数が多い解候補ほど参考とする価値が高いためである．

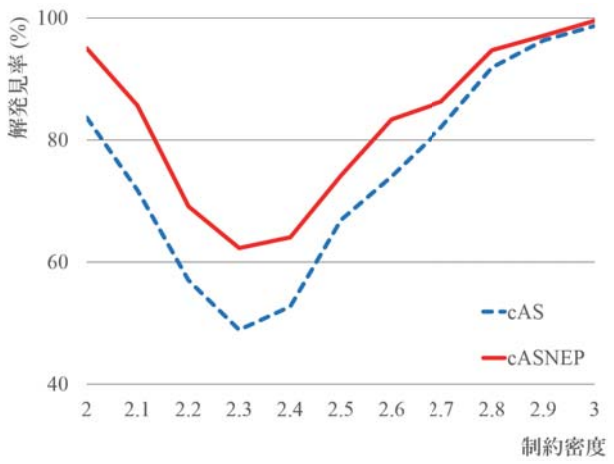


図 2: 世代数 2000 における制約充足解の発見率

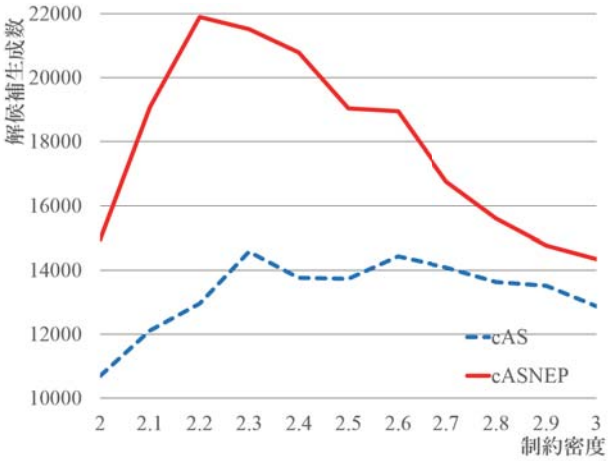


図 4: 世代数 2000 における解候補の生成数

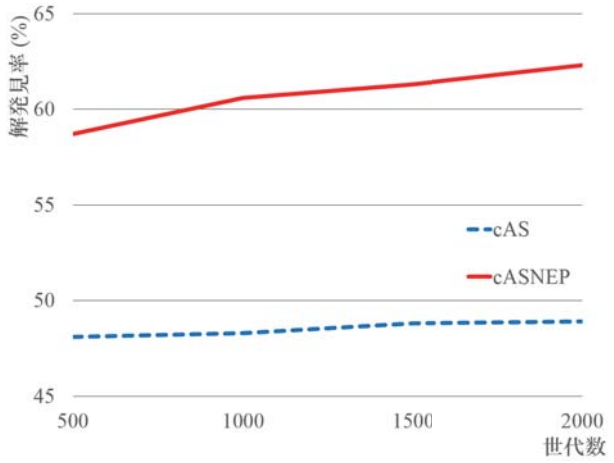


図 3: $\rho = 2.3$ における制約充足解の発見率

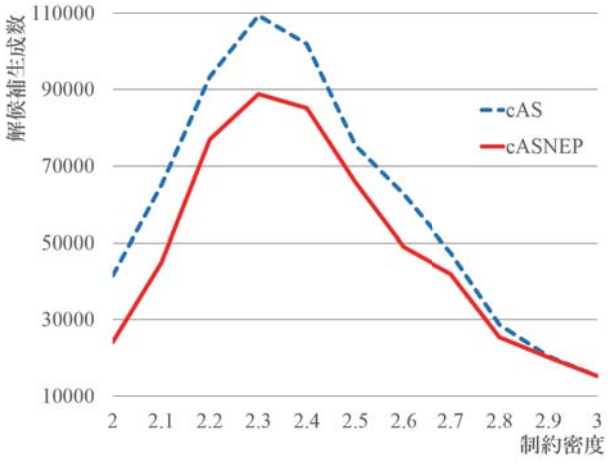


図 5: 世代数 2000 における，探索失敗時も考慮した解候補の生成数

4. 評価実験

4.1 実験条件

本手法の性能を評価するために実験を試みた．ここでは頂点数 $n = 100$ である 3COL を，制約密度 $d = 2.0 \sim 3.0$ の範囲で 0.1 毎に 11 のケースに対して，それぞれランダムに 100 問生成した．ここで生成した問題は全て解が存在する．生成した各問題について，それぞれ 10 回ずつ試行を行なった．本実験のパラメータは，蟻の数を 100，蟻の最大世代数を 2000，フェロモンの重み $\alpha = \alpha_u = \alpha_n = 5.0$，制約違反の重み $\beta = 10.0$，フェロモンの蒸発率 $\rho = 1\%$ とした．また，比較する手法は cAS と cASNEP の 2 つである．これらの手法について，制約充足解の発見率と，制約充足解を発見できた場合において制約充足解を発見するまでに生成した解候補の数を比較した．

なお，実験には PC/AT 互換機（CPU: Intel Core i7 880 3.07GHz，RAM: 4GByte）を使用し，プログラムはすべて Java 言語で記述した．

4.2 実験結果と考察

実験結果を図 2〜 図 5 に示す．図 2 は，生成した問題の制約密度ごとの制約充足解の発見率を表したものである．実験結果より相転移領域 ($d = 2.3 \sim 2.4$) を含む全ての制約密度の問題について，提案手法である cASNEP の解発見率が従来手法の cAS を上回っている．特に，相転移領域周辺において cASNEP と cAS の解発見率の差は 10%以上であり，ネガティブフェロモンを導入したことによるそれぞれの制約密度における解発見率の上昇量が最大となっている．また，図 3 は，制約密度 $\rho = 2.3$ における制約充足解の発見率を表したものである．横軸は解を発見するまでにかかった世代数である．図 3 より従来手法である cAS は，解候補を多く生成しても解の発見にはほとんどつながらない．しかし，提案手法の cASNEP は解候補の生成に対して，わずかながらも制約充足解発見率の上昇が見られる．これらのことから，ネガティブフェロモンの導入が相転移領域周辺の難しい問題を解く際，制約充足解の発見率向上に寄与できる可能性があるといえる．よって，制約充足解発見率の向上という本研究の目的を達成できたのではないかと考えられる．

次に，図 4 は，制約充足解を発見できた試行について，解を発見するまでに生成した解候補数の平均を表したものである．横軸は制約密度である．実験結果より全ての制約密度にお

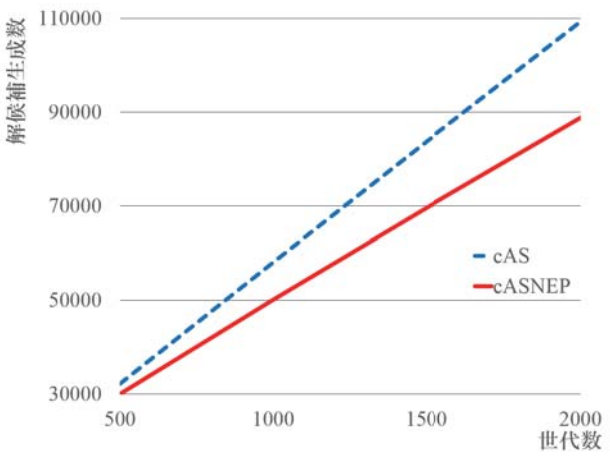


図 6: $\rho = 2.3$ における，探索失敗時も考慮した解候補の生成数

いて，制約充足解を発見するまでに，cASNEP の方が cAS よりも平均的に多く解候補を生成していることがわかる．つまり，平均的には cASNEP の方が解を見つけるまでに時間がかかっているということになる．しかしこれは，“解が発見できた試行における” 解候補の平均生成数を表したものである．平均生成数が増加したということは，cAS が解けなかった問題を，cASNEP が比較的多くの解候補を生成することで解けたということである可能性がある．

最後に，図 5 と図 6 は，試行全体における解候補平均生成数を表している．ただし，制約充足解を発見できなかった試行については，探索を終了させるまでの間に生成した解候補数を，その試行の解候補生成数とした．解を発見できなかった試行についても解候補生成数を与えるのは，ある試行において解を発見できなかった際の時間的なロスを表すためである．図 5 の横軸は制約密度を，図 6 の横軸は世代数をそれぞれ表している．図 5 より，cASNEP の方が cAS より解候補の平均生成数が少ない．これは，cASNEP が cAS と比べて解発見率が高いことが起因していると考えられる．また図 6 より，世代数が増すにつれて解候補の平均生成数の差は大きくなっている．これらのことから，解を発見できない試行によって発生するロスも考慮すると，解発見率の高い cASNEP において解発見に必要な解候補数が多いことはあまり問題ではないと考えられる．

5. おわりに

本研究では，相転移領域周辺の難しい 3COL を解くために，複数のフェロモングラフを用いる ACO モデルを提案した．本モデルは，従来のフェロモングラフに加えて，解候補集団内で最も評価が低い解候補を用いて更新されるネガティブフェロモングラフを解候補生成に用いるものである．この提案モデルと従来のモデルを実験的に比較し，提案モデルの有効性を示した．今後の課題としては，他のメタヒューリスティクスとの比較，他の CSP への適用が挙げられる．

参考文献

[1] Bell, J. E. and McMullen, P. R.: Ant colony optimization techniques for the vehicle routing problem, Advanced Engeneering Informatics, Vol. 18(1), pp. 41–48 (2004).

[2] Bui, T. N., Nguyen, T. H., Petal, C. M. and Phan, K. T.: An ant-based algorithm for coloring graphs, Discrete Applied Mathematics, Vol. 156, pp. 190–200 (2008).

[3] Cheeseman, P., Kanelfy, B. and Walsh, T.: Where the really hard problems are, Proc, IJCAI’91, pp. 331–337 (1991).

[4] Dorigo, M. and Di Caro, G.: The Ant Colony Optimization meta-heuristic, New Ideas in Optimization, pp. 11–32 (1996).

[5] Dorigo, M., et. al.: The Ant System: Optimization by a Colony of Cooperating Agents, IEEE Transaction on Systems, Man, and Cybernetics - Part B, Vol. 26, pp. 26–41 (1996).

[6] Dorigo, M. and Di Caro, G.: The Ant Colony Optimization Meta-Heuristics, New Ideas in Optimization, pp. 11–32 (1999).

[7] Hayakawa, D., Mizuno, K., Sasaki, H. and Nishihara, S.: Solving Constraint Satisfaction Problems by A Population Based Cunning Ant System, The 2012 International Conf. on Technologies and Applications of Artificial Intelligence (TAAI2012), pp. 205–210 (2012).

[8] Hogg, T., Huberman, B. A. and Williams, C. P.: Phase transition and search problem, Artificial Intelligence, Vol. 81, pp. 1–16 (1996).

[9] Masukane, T. and Mizuno, K.: Ant Colony Optimization with Multi-Pheromones for Solving Constraint Satisfaction Problems, The 2016 International Conf. on Technologies and Applications of Artificial Intelligence (TAAI2016), pp. 110–115 (2016).

[10] Mizuno, K. and Nishihara, S., et. al.: Population migration: a meta-heuristics for stochastic approaches to constraint satisfaction problems, Informatica, Vol. 25, pp. 421–429 (2001).

[11] Mizuno, K. and Nishihara, S.: Constructive generation of very hard 3-colorability instances, Discrete Applied Mathematics, Vol. 156(2), pp. 218–229 (2008).

[12] Mizuno, K., Hayakawa, D., Sasaki, H. and Nishihara, S.: Solving Constraint Satisfaction Problems by ACO with Cunning Ants, The 2011 Conf. on Technologies and Applications of Artificial Intelligence (TAAI2011) (2011).

[13] Tayarani-N, M. H. and Prugel-Bennett, A.: Anatomy of the fitness landscape for dense graph-colouring problem, Swarm and Evolutionary Computation, Vol. 22, pp. 47–65 (2015).

[14] Tsutsui, S.: cAS: Ant Colony Optimization with Cunning Ants, Proc. of the 9th Int. Conf. on Parallel Problem Solving from Nature (PPSN IX), pp. 162–171 (2006).

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

粒子群最適化を用いた巡回セールスマン問題の解法

Algorithm of Traveling Salesman Problem using Particle Swarm Optimization

山田 悠希[*1]
Yuki Yamada

穴田 一[*1]
Hajime Anada

[*1] 東京都市大学
Tokyo City University #1

Particle swarm optimization (PSO) is a population based stochastic optimization technique inspired by social behavior of bird flocking or fish schooling. PSO has been applied to various combinatorial optimization problems belonging to non-deterministic polynomial-time hard (NP-hard) combinational problems. Of these, the traveling salesman problem (TSP) is one of the most important problems in the fields of technology and science. Insertion-based PSO strategy (IPSO) is an algorithm that improved the PSO for TSP. The update of the particle in IPSO is done by using the information of the own best solution and the solution of the nearby particles. However, IPSO has a problem that it converges to the local optimal solution before sufficient search. Therefore, we proposed to provide the information of the farthest particle and the randomly selected particle as well as nearby particles for the particle's update. We confirmed the effectiveness of our algorithm using several benchmark problems taken from the TSPLIB, which is a library of traveling salesman problem.

1. はじめに

工業や経済の問題の多くは，最も効率が良い組み合わせを求める組み合わせ最適化問題に帰着することができる．その中に，与えられた全ての都市を巡る最短経路を求める巡回セールスマン問題 (Traveling Salesman Problem,TSP) という問題がある．本庄らは，最適化問題に用いられるアルゴリズムの一つである粒子群最適化(Particle Swarm Optimization, PSO)[Kennedy 95]をTSP 向けに改良した挿入操作 PSO 戦略（Insertion-based PSO strategy, IPSO)を提案した[本庄 16]. IPSO は，解空間上に配置された各粒子がそれまでの最良解と，近傍の粒子の最良解の情報を基に解の更新を繰り返すことで解空間の探索を行うアルゴリズムである．しかし，この IPSO には探索が十分に行われないうちに，局所解に陥ってしまうという問題点がある．

そこで本研究では解の更新時に，各粒子のそれまでの最良解と近傍の粒子の最良解の情報に加え，解空間上で最も遠い粒子の情報とランダムに選択した粒子の情報を与えることで，既存手法よりも広範囲の探索を行えるアルゴリズムを構築した．そして，TSPLIB に掲載されているベンチマーク問題を用いて既存手法と提案手法の比較をすることで，性能の向上を確認した．

2. 既存研究

2.1 粒子群最適化

粒子群最適化(Particle Swarm Optimization,PSO)とは，魚や鳥などに見られる群行動を探索手法に応用した，最適化手法の一つである．解空間上に位置と速度を持った複数の個体(以下，粒子と表記)をランダムに配置する．各粒子の位置は問題の解を表現しており，適応度の高い位置の情報を近傍の粒子と交換し，その情報を基に，より良い位置に近づくように速度と位置を更新する．この操作を繰り返すことで，解空間を探索する．t イテレーション目における粒子 i の位置 $x_i(t)$ と速度 $v_i(t)$ の更新式は次式で定義される．

$$x_i(t) = x_i(t-1) + v_i(t-1) \quad (1)$$

$$v_i(t) = wv_i(t-1) + c_1r_1\left(pbest_i - x_i(t)\right) + c_2r_2\left(lbest_i - x_i(t)\right) \quad (2)$$

ここで，w, c_1, c_2はパラメータ，r_1とr_2 は [0,1] の一様乱数，$pbest_i$ はその粒子 i のそれまでの最良解，$lbest_i$ は粒子 i の近傍の中のそれまでの最良解である．PSO のアルゴリズムの流れは以下の通りである．

①初期設定

全粒子の位置と速度をランダムに設定し，各粒子 i のそれまでの最良解 $pbest_i$ を現在位置に設定する．次に，設定した近傍数 k を元に，各粒子 i と距離が近い k 個の粒子を粒子 i の近傍に設定する．そして，各粒子 i の近傍の中で適応度が最も高い解を近傍内の最良解 $lbest_i$ と設定し，全粒子の中で最も高い適応度の位置を $gbest$ と設定する．

②位置の更新

各粒子において，(1)式に従い，位置の更新を行う．

③適応度の評価

全ての粒子において適応度の計算と評価を行う．適応度は問題に適した粒子ほど高くなるよう，評価関数を事前に設定しておく．

④ $pbest_i$ と $gbest$ の更新

各粒子 i が新たに得た解の適応度がこれまでの $pbest_i$ よりも高かった場合，$pbest_i$ を更新する．近傍内で適応度が最も高い解が $lbest_i$ よりも短かった場合，$lbest_i$ をその解で更新する．この操作を全粒子に行う．全粒子の中で最も適応度が高い解が $gbest$ よりも適応度が高かった場合，$gbest$ をその解で更新する．

⑤速度の更新

各粒子において，(2)式に従い，速度の更新を行う．

初期設定を①で行い，②から⑤までの操作を 1 イテレーションとし，終了条件を満たすまで繰り返すことで解空間を探索する．

2.2 挿入操作 PSO 戦略

本庄らが提案した IPSO は，PSO に基づき TSP の解空間の探索を行うアルゴリズムである．まず，解空間上に複数の粒子を配

連絡先：山田悠希，東京都市大学，〒158-8557
東京都世田谷区玉堤 1-28-1

置する. これらの粒子は, それぞれ巡回路である解を持っており, 各粒子のそれまでの最良解と近傍の粒子の最良解から抽出した部分経路を, 各粒子の現在の解に挿入することで解の更新を行い, これを繰り返すことで, 解空間を探索する. IPSO のアルゴリズムの詳細な流れは以下の通りである.

①初期設定

各粒子に解 x_i をランダムに設定し, 各粒子のそれまでの最良解 $pbest_i$ を現在の解 x_i に設定する. 粒子 i と粒子 j 間の距離 d_{ij} を以下のように定義し, 全粒子間の距離を計算する.

$$d_{ij} = \frac{1}{S_{ij}} \tag{3}$$

$$S_{ij} = \frac{|E_i \cap E_j|}{n}$$

ここで, E_i は粒子 i が持つ解 x_i の経路の集合, $|E_i \cap E_j|$ は E_i と E_j の共通している経路の本数, n は都市数を表している. 距離 d_{ij} は x_i と x_j の共通の経路が多くなるほど短くなる. 次に, 設定した近傍数 k を元に, 粒子 i と距離が近い k 個の粒子を粒子 i の近傍に設定する. 各粒子 i の近傍の中で総経路長が最も短い解を近傍内の最良解 $lbest_i$ と設定する. また, 全粒子の中で最も総経路長が短い解を全粒子の最良解 $gbest$ と設定する.

②解の更新

解 x_i は $pbest_i$ の部分経路である $pbest_i'$ と $lbest_i$ の部分経路である $lbest_i'$ を総経路長が最も短くなるように挿入することで更新される. 粒子 i の解の更新の詳細は以下の通りである. また, 9 都市の TSP の解の更新の例を図 1 に示す. 図 1 の例の$x_i = (1,4,7,5,6,9,8,3,2)$は都市 1→都市 4→ … →都市 3→都市 2 と都市を巡り, 都市 1 に戻る巡回路を表している.

I 部分経路の作成

粒子 i の $pbest_i$ から, p 本の連続する経路をランダムに抜き出し, 部分経路 $pbest_i'$ とする. また, 粒子 i の $lbest_i$ から, l 本の連続する経路をランダムに抜き出し, 部分経路 $lbest_i'$ とする. p と l は以下の式で表される.

$$p = [c_1 r_1 (n+1)] \tag{4}$$

$$l = [c_2 r_2 (n+1)] \tag{5}$$

ここで c_1 と c_2 は $[0,1]$ を満たすパラメータ, r_1と r_2 は $[0,1]$ を満たす一様乱数, n は都市数である. $[c_1 r_1 (n+1)]$ は$c_1 r_1 (n+1)$ の整数部分を表している. 図 1 の例では$pbest_i' = (5,4,8,7)$と $lbest_i' = (8,9,6)$を抜き出している.

II $pbest'$ の再形成

$pbest_i'$ と$lbest_i'$ に共通した都市が含まれていれば, $pbest_i'$ から該当した都市を削除し, 残った都市で総経路長が最も短くなるよう部分経路を再形成する. 図 1 の例では都市 8 が共通しているため, $pbest_i'$ から都市 8 を削除し, $pbest_i'$ を再形成している.

III x_i' の形成

x_i に $pbest_i'$ と $lbest_i'$ と共通する都市が含まれていれば, x_iから該当した都市を削除し, 残った都市で総経路長が最も短くなるよう巡回路を再形成し, x_i' とする. 図 1 の例では, $pbest_i'$ と $lbest_i'$ にある都市 4,5,6,7,8,9 を x_i から削除し, $x_i' = (1,2,3)$となっている.

IV $pbest_i'$ の挿入

$pbest_i'$ を x_i' に総経路長が最も短くなるよう挿入する. 図 1 の例では都市 1 と都市 3 の間に $pbest_i'$ を挿入している.

V $lbest_i'$の挿入

$lbest_i'$ を x_i' に総経路長が最も短くなるよう挿入する. 図 1 の例では都市 5 と都市 3 の間に $lbest_i'$ を挿入している.

以上の I ～V の操作を全粒子で行う.

③総経路長の計算

全ての粒子が持つ巡回路の総経路長の計算を行う.

④近傍の更新

全粒子間の距離を再計算し, 近傍を更新する.

⑤ $pbest, lbest, gbest$ の更新

粒子 i が新たに得た解 x_i' の総経路長が $pbest_i$ よりも短かった場合, $pbest_i$ を x_i' で更新する. 近傍内で総経路長が最も短い解がこれまでの $lbest_i$ よりも短かった場合, $lbest_i$ をその解で更新する. この操作を全粒子に行い, 全粒子の中で総経路長が最も短い解がこれまでの $gbest$ よりも短かった場合, $gbest$ をその解で更新する.

初期設定を①で行い, ②から⑤までの操作を 1 イテレーションとし, 終了条件を満たすまで繰り返すことで TSP の解空間を探索する.

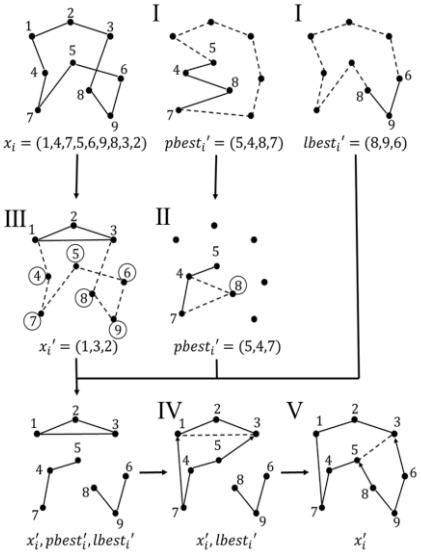


図 1:解の更新の例

3. 既存手法の問題点

既存手法である IPSO は, 各粒子 i のそれまでの最良解である $pbest_i$ と近傍の粒子の最良解である $lbest_i$ の部分経路を挿入することで解 x_i の更新を行っている. しかし, $pbest_i$ と $lbest_i$ は探索がある程度進むと, x_i とほぼ同じような巡回路となり, 部分経路を挿入しても, 元の解と全く同じ解ができる無駄な更新が起こりやすい. この無駄な更新の影響で, 新規の経路の獲得が起こりにくく, 探索が十分に行われないうちに局所解に陥ってしまうという問題点がある.

4. 提案手法

IPSO の解の更新時における部分経路の作成において, 挿入要素を抽出する解を$lbest_i$ から次式で表される x_i^{ins} に変更した.

$$x_i^{ins} = \begin{cases} lbest_i \ with \ probability \ P_l \\ x_i^f \ with \ probability \ P_f \\ x_i^r \ with \ probability \ P_r \end{cases} \tag{6}$$

ここで, $lbest_i$ は近傍内の最良解, x_i^f は解空間上で一番遠い

粒子の解，x_i^r は自分以外の粒子の中からランダムに選択された粒子を表しており，x_i^{ins}は $lbest_i$ ，x_i^f ，x_i^rの三つの解から確率的に選択される解である．また，P_l は $lbest_i$ が選ばれる確率，P_f はx_i^f が選ばれる確率，P_r は x_i^r が選ばれる確率である．最遠の粒子の解 x^fとランダムに選択された粒子の解 x^rの部分経路を挿入することで，既存手法では獲得できなかった経路を獲得でき，各粒子が広範囲の探索を行うことが期待される．

5. 結果

提案手法の有用性を確認するため，TSPLIB に掲載されている TSP のベンチマーク問題である rd100，kroA150，kroA200，pr299 を用いて評価実験を行った．既存手法，提案手法ともに事前実験により決定された粒子数 $m = 64$，近傍数 $k = 2$，$c_1 = 0.9$，$c_2 = 0.1$というパラメータを使用した．また，提案手法の x^{ins} において $lbest$ を選択する確率 P_l ，x^f を選択する確率 P_f，x^r を選択する確率 P_r はそれぞれ，事前実験により決定された，$P_l = 0.6$，$P_f = 0.3$，$P_r = 0.1$ を使用した．終了条件は rd100 と kroA150 は 20000 イテレーション，kroA200 と pr299 は 30000 イテレーションとした．各問題 50 試行の結果を表 1～4 に表す．また，表中で用いられている誤差率は，試行内で得られた最良解の最適解に対する誤差の割合を，最終更新イテレーションは最後に $gbest$ を更新したイテレーションを表している．

表 1：rd100 の 50 試行の結果

rd100(最適解 7910)	既存	提案
最適解到達率(%)	88	98
平均誤差率(%)	0.0099	0.0002
誤差率の標準偏差	0.0601	0.0018
平均最終更新イテレーション	3210.4	1961.0
平均時間(秒)	8.3	6.5

表 2：kroA150 の 50 試行の結果

kroA150(最適解 26524)	既存	提案
最適解到達率(%)	10	34
平均誤差率(%)	0.25	0.05
誤差率の標準偏差	0.24	0.12
平均最終更新イテレーション	6951.2	4349.9
平均時間(秒)	32.7	33.0

表 3：kroA200 の 50 試行の結果

kroA200(最適解 29368)	既存	提案
最適解到達率(%)	2	20
平均誤差率(%)	0.50	0.25
誤差率の標準偏差	0.29	0.25
平均最終更新イテレーション	13684.2	12206.1
平均時間(秒)	100.5	88.7

表 4：pr299 の 50 試行の結果

pr299(最適解 48191)	既存	提案
最適解到達率(%)	0	2
平均誤差率(%)	1.13	0.63
誤差率の標準偏差	0.39	0.44
平均最終更新イテレーション	21655.9	20767.4
平均時間(秒)	261.7	247.7

実験の結果，既存手法に比べ，最適解到達回数，平均誤差率，平均最終更新イテレーション，平均時間のほとんどの項目において提案手法の方が良いことを確認した．これは，x^f と x^r の部分経路を挿入することによって，$lbest$ の挿入だけでは獲得できなかった経路の組み合わせを獲得できたことが要因だと考える．

続いて，pr299 の更新した粒子の割合の推移を表したグラフを図 1 に表す．縦軸は更新した粒子の割合，横軸はイテレーションを表し，黒線は既存手法，赤線は提案手法の推移を表している．

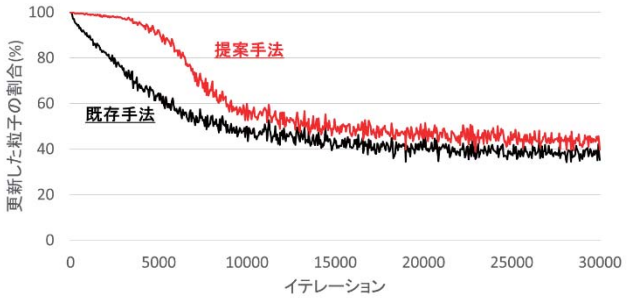


図 1：pr299 の更新した粒子の割合

グラフより，既存手法に比べ，提案手法の方が更新した粒子の割合が全イテレーションにおいて多いことが分かる．これは，既存手法の問題点である無駄な更新を減らし，効率の良い探索が行えていると言える．

6. 今後の課題

今後の課題として，全粒子が持っていない新規の経路を獲得することが挙げられる．提案手法では，全粒子が持っていない新規の経路の獲得が難しく，最適解ではない解に収束しやすいという欠点がある．そこで，解の更新が一定のイテレーション行われなかった場合，いくつかの粒子の経路を入れ替えるといった収束に対する刺激を与えることで，現在の提案手法よりも最適解に到達しやすいアルゴリズムにしたいと考えている．

参考文献

[Kennedy 95] J.Kennedy，R.C.Eberhart，：”Particle swarm optimization”IEEE International Conf. on Neural Networks，pp.1942-1948 (1995)

[本庄 16] 本庄将也，飯塚博幸，山本雅人，古川正志，”巡回セールスマン問題に対する粒子群最適化の提案と性能評価”，日本知能情報ファジィ学会誌，vol.28，no.4，pp.744-755 (2016)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

ACOを用いたデータクラスタリングにおける最適パラメータの考察

Toward Optimal Parameters for ACO in Data Clustering

中山 貴幸 *1　　水野 一徳 *1
Takayuki Nakayama　Kazunori Mizuno

*1拓殖大学工学部情報工学科
Department of Computer Science, Faculty of Engineering, Takushoku University

In data clustering ,ACO based methods have been effective for cluster distributions with high accuracy. However, it have been difficult to set optimal parameters for each data set, requiring trial-and-error repetitions of parameter tuning. In this paper, we have analyzed the behavior of the ACO based algorithm, called ESACC, and clarified optimal parameters in ESACC for some benchmark datasets. We also demonstrate that ESACC with our found parameters can be more effective than some clustering method.

1. はじめに

クラスタリング (clustering) とは，分類対象の集合を，内的結合と外的分離が達成されるような部分集合に分割することである．統計解析や多変量解析，データマイニングといった分野において頻繁に利用されている．現在，その効率的な手法について，誠意研究がされている．

群知能の一種である蟻コロニー最適化 (Ant Colony Optimization: ACO) を取り入れたクラスタリングアルゴリズムとして ESACC が挙げられる．ESACC は，適切なパラメータ設定により精度の高いクラスタリングが実現可能であるが，パラメータ設定は非常に困難である．これは，パラメータ設定を複数回の試行や経験に基づいて行う必要があり，データによって適切なパラメータが変化するためである．

そこで，本稿では ESACC の挙動や傾向を解析することで，最適なパラメータの設定を行うにあたり考察を行う．具体的に，クラスタリング対象データの解析によるパラメータの自動設定，パラメータを動的に変更することによる最適化を行うことを視野に入れる．最終的には，パラメータをユーザーが設定する必要なく，高い精度のクラスタリングを行うことを目標とする．

2. 概要

2.1 クラスタリング

クラスタリング (clustering) とは，分類対象の集合を，内的結合と外的分離が達成されるような部分集合に分割することである．統計解析や多変量解析，データマイニングといった分野において頻繁に利用されている．

クラスタリングは，外的基準でなくデータの持つ特徴量を用いて行うため，教師なし学習である．よって，後述の目的関数等を用いて解候補を評価しつつ解探索を行う．

クラスタリングは大きく 2 つに分けることができる．階層型クラスタリングと非階層型クラスタリングである．前者は，データを階層的に分類することを目的とした処理であり，データウォード法，群平均法，最短距離法，最長距離法等，様々な手法が提案されている．後者は，データを非階層的，つまり階層的な構造を持たず決められた数のクラスタにデータを分類することを目的とした処理である．本稿では後者を対象とし，以降クラスタリングと呼称する．

非階層型クラスタリングでは，n 次元の特徴量を持つデータを K 個のクラスタに分類する．

各データ x とそれが所属するクラスタ i の中心 c_i との距離 $d(x, c_i)$ を算出し，その合計を目的関数とする．目的関数を小さくすることを目的とした組合せ問題として捉える．

目的関数を式 1 に示す．ただし，クラスタの総数を K，クラスタ i を C_i，クラスタ i の中心点を c_i とする．

$$f = \sum_{i=1}^{K} \sum_{x \in C_i} (d(x, c_i))^2 \tag{1}$$

2.2 ESACC

ACO は組み合わせ最適化問題の近似解を探索するために用いられるメタヒューリスティクスである。ACO では，アリを模したエージェントがフェロモンテーブルをもとに解候補を探索する．フェロモンテーブルにより良い解の情報を蓄積することで，より良い解探索を可能とする手法である．

ACO を用いたクラスタリングアルゴリズムとして ESACC が挙げられる．Algorithm1 に ESACC のアルゴリズムを示す．

ESACC は，SACC[Guluzar:2006] というアルゴリズムに変更を加えたものである．前世代で一番優秀なアリから解候補の一部を引き継ぐことで，形質遺伝といった遺伝的アルゴリズム（Genetic Algorithms:GA）の要素が取り込まれている．

使用するデータ構造を以下に示す．ただし，クラスタ数を K，クラスタ対象のデータ数を n とする．

フェロモンテーブル：2 次元配列 (行数:k , 列数:n)

アリ (解候補)：配列 (要素数:n)

フェロモンの更新を行う際，目的関数値 (式 1) の逆数を，アリが持つ解候補をもとにフェロモンテーブル内に追加する．よって，目的関数が小さく優秀なアリは，より多くのフェロモンを堆積する．フェロモンを追加する処理は上位 L のアリだけ行われる．

例えば，データ x_a をクラスタ C_b に属する解候補を持つアリの目的関数が示す値を f_c であるとする．その場合は，フェロモンテーブル内 a 行 b 列の要素に $1 \div f_c$ の値を追加する．

連絡先: 中山貴幸，拓殖大学工学部情報工学科，東京都八王子市館町 815-1，042-665-0519，takanakahiko@gmail.com

Algorithm 1 ESACC

パラメータの設定
フェロモンテーブルの初期化
while 一定回数 **do**
　複数の解候補をフェロモンテーブルより生成
　解候補の評価
　フェロモンの堆積
　フェロモンの蒸発
end while
評価の一番高い解候補を最終的な解とする

フェロモンテーブルの値は毎世代，蒸発率に応じて値を減らされる．この操作を行うことで，フェロモンが飽和してしまうことを防ぐ．なお，フェロモンテーブルは 0 以上 1 未満の値を保持し，範囲を超えた場合は切り捨てを行う．

解候補の生成には，フェロモンテーブルと前世代で一番優秀であった解候補を利用する．解候補は，クラスタリング対象のデータ数の長さを持つ配列に格納される．まず，E を $Emin$ 以上 $Emax$ 以下の整数よりランダムで決定する．E の値は解候補生成時に毎回決め直す．新しく解候補を生成する際，一番優秀なアリが持つ解候補内のランダムな E 個の要素を，次世代のアリの解候補に用いる．それ以外の要素については，フェロモンテーブルより確率的に選択することで解候補を生成する．つまり，フェロモンテーブル内 a 行 b 列の要素の数値を正規化したものを，次の世代のアリがデータ x_a をクラスタ b に分類する確率と見立てる．

ESACC アルゴリズムでは，以下のパラメータ群を設定し使用する．

世代数
　解候補の生成，評価，フェロモンテーブルの更新，といった一連の処理を繰り返す回数．

アリの数
　1 世代につき用いる解候補の個数．

蒸発率
　1 世代につき行うフェロモンの蒸発処理における蒸発量．

L
　1 世代につき，フェロモンにテーブルに値を書き込むアリの匹数．アリの総数に対する割合を考慮し決定する．

Emin
　解候補生成時に用いる E の最小値．クラスタリング対象データの総数に対する割合を考慮し決定する．

Emax
　解候補生成時に用いる E の最大値．ラスタリング対象データの総数に対する割合を考慮し決定する．

ESACC は，適切なパラメータ設定により精度の高いクラスタリングが実現可能であるが，パラメータ設定は非常に困難である．

ESACC には，パラメータを決定するための指標が存在しない．よってユーザがパラメータ設定を複数回の試行や経験に基づいて行う必要がある．また，クラスタリング対象データによって適切なパラメータが変化するため，適宜変更する必要がある．

表 1: FM-index で使用するラベル

	flag2=True	flag2=False
Flag1=True	TP	FP
Flag1=False	TN	FN

表 2: 挙動解析実験に用いたパラメータ

	最小	最大	間隔	パターン数
世代数	1000	1000		1
アリの数	20	20		1
蒸発率	0.01	0.30	0.01	30
L	1	30	1	30
Emin	0	15	1	16
Emax	1	20	1	20

2.3 FM-index

クラスタリングの精度を計測する指標として FM-index(Fowlks Mallows index)[Fowlkes:1983] が挙げられる．FM-index は二つのクラスタリング結果の同一性を求めるものであるが，クラスタリング結果と正解ラベルを比較することで，クラスタリングの精度を求めることが可能である．

クラスタリング結果 A とクラスタリング結果 B を比較する際，以下のように FM-index を求めることが可能である．まずデータ 2 つの組合せすべてに対し，以下の真偽値を求め，表 1 のようにラベルを付与する．

flag1：結果 B にて同じクラスタである

flag2：結果 B にて同じクラスタである

ラベリングされたデータの数を式 2 に代入することで FM-index を求めることができる．

$$FMI = TP \div sqrt((TP + FP) * (TP + FN)) \quad (2)$$

3. 挙動解析実験

3.1 実験内容

ESACC について，データセット Iris[UCI] に対して表 2 に示すパラメータ群の全ての組合せを試行し，クラスタリングの結果を評価する．

クラスタリング結果は FM-index を用いた評価を行う．

パラメータ群とデータセットの組合せを 1 つ評価する行動を 1 試行とする．1 試行において同じパラメータにおいて実験した 10 回の評価値の平均を算出する．

3.2 結果

フェロモンの蒸発率と L 値の間は，FM-index に対して同じような相関があることが分かった．図 1 に，蒸発率と L 値を変更した組合せによる 81 回の試行について評価値を算出したものを示す．

Emin 及び Emax が異なる場合でも同様の相関関係を示した．つまり，フェロモンの蒸発率が決定された場合，それに対する最適な L 値が存在すると考えられる．FM-index 値が低い場合，フェロモンの堆積量と蒸発量の釣り合いが適切でない場合が多い．

		蒸発率								
		0.02	0.04	0.06	0.08	0.1	0.12	0.14	0.16	0.18
L	2	0.83016	0.83103	0.77319	0.77004	0.71564	0.73729	0.694	0.67965	0.66059
	4	0.75088	0.83677	0.80592	0.79052	0.77546	0.77502	0.74211	0.72765	0.72934
	6	0.66475	0.81533	0.82325	0.81786	0.80635	0.78479	0.76873	0.76912	0.75869
	8	0.61577	0.76582	0.81765	0.82195	0.79997	0.81086	0.78557	0.78165	0.7591
	10	0.55722	0.68149	0.81515	0.81791	0.82157	0.80045	0.79891	0.75017	0.75207
	12	0.52188	0.65771	0.73169	0.81148	0.81173	0.79966	0.79945	0.76932	0.75639
	14	0.47242	0.61094	0.69838	0.76425	0.80146	0.77944	0.79561	0.78297	0.75283
	16	0.41972	0.58838	0.65736	0.72401	0.76231	0.79488	0.75579	0.71994	0.71288
	18	0.35855	0.46067	0.58149	0.66503	0.70338	0.71997	0.68973	0.67168	0.6422

図 1: 蒸発率と L 値の組合せによる評価値

4. パラメータ設定とその評価

4.1 パラメータ設定

挙動解析実験の結果をもとに，パラメータの設定を行う．パラメータ設定にあたり，パラメータをタイプ A 及びタイプ B へと分類する．

タイプ A : 世代数 , アリの数

タイプ B : 蒸発率 , L , Emin , Emax

タイプ A のパラメータは，処理に与えられる時間やマシンスペックによって適切なパラメータを設定しなければならない．これらは，組み合わせ最適化問題を解く際におけるパラメータであり，ESACC 特有のパラメータではない．よって，今回のパラメータ設定の適用外とする．

タイプ B のパラメータは適切な設定をすることで，高い精度を期待することができる．よって，よって，今回のパラメータ設定の対象とする．

タイプ B に関して，図 1 に示した実験結果により，パラメータの設定が容易となったと考えられる．

蒸発率はフェロモンの総量の調整に用いる．目的関数が低くなるデータセットの場合は，フェロモンの堆積量が多くなる．よって，単純なデータセットの場合，蒸発率を高くする必要がある．データを解析し，特徴量の分散度を計算することで，蒸発率を決定することが可能である．

また，実験結果より L は蒸発率によって決定することが可能である．よって，蒸発率を適切に設定することで，適切な L を設定可能である．

Emin 及び Emax に関しては，前途の実験では関係性が明らかにならなかった．よって，グリッドサーチで決定するものとする．

4.2 評価実験概要

上記に示したパラメータ設定を用い，他のデータセットにおいても有効であるか検証を行う．

ここでは，UCI Machine Learning Repository[UCI] のデータセットである，Iris，Wine，Synthetic Control Chart Time Series Data Set(Sccts) を用いた．

Iris

アヤメのデータを品種毎にラベリングしたデータセットである．がく片の長さ，がく片の幅，花弁の長さ，花弁の幅，といった 4 つの特徴量を持つ 150 個のデータで構成されている．これらを 3 つの品種に分類を行う．特徴量，クラスタ数ともに少数であるため，比較的クラスタリングが容易なデータセットである．

表 3: 実験に使用したデータセット

	データ数	属性数	クラスタ数
Iris	150	4	3
Wine[UCI]	178	13	3
Sccts[UCI]	600	60	6

表 4: ESACC に用いたパラメータ

	蒸発率	L	Emin	Emax
Iris	0.1	10	2	6
Wine	0.1	16	5	10
Sccts	0.1	30	10	20

Wine

白ワインのデータを品種毎にラベリングしたデータセットである．アルコール，リンゴ酸，灰，灰のアルカリ性，マグネシウム，フェノール類全量，フラバノイド，非フラバノイドフェノール類，プロアントシアニン，色彩強度，色調，蒸留ワインの OD280/OD315，プロリンといった 13 つの特徴量を持つ 178 個のデータで構成されている．これらを 3 つの品種に分類を行う．

Sccts

連続した数値のデータを傾向毎にラベリングしたデータセットである．有効数字 6 桁かつ 100 以下の有理数を 60 個持つ 600 個のデータで構成されている．これらを 6 つの傾向 (通常，循環，上昇，下降，上方移行，下方移行) に分類を行う．

データセットの詳細を Table3 に示す．
実験に用いるプログラムは，以下の環境で実装を行なった．

OS : ubuntu16.04 LTS 32bit

CPU : Intel®Core™i7-4790 CPU

メモリ : 15.7GiB

プログラミング言語 : Python2.7

また，実装にあたり numpy ライブラリを使用し，並列処理や遅延評価を取り入れた効率的な計算を行った．
以下の 3 つのアルゴリズムに対して，それぞれ評価を行う．挙動解析実験と同様に FM-index を用いた評価を行い，1 試行において 10 回の評価値の平均を算出する．

1. ESACC:提案された論文 [Liu:2010] によるパラメータを用いた ESACC
2. ESACC-OPT:前章で示したパラメータ設定を適用した ESACC
3. k-means:クラスタリングにおける代表的なアルゴリズム

ESACC に用いたパラメータの一部を表 4 に示す．ESACC には，ESACC が提案された論文のパラメータをそのまま使用する．

表 5: ESACC-OPT に用いたパラメータ

	蒸発率	L	Emin	Emax
Iris	0.04	4	2	2
Wine	0.1	5	2	2
Sccts	0.09	17	10	20

表 6: 共通で用いたパラメータ

	世代数	アリの数
Iris	1000	20
Wine	1000	20
Sccts	1000	60

ESACC-OPT に用いたパラメータの一部を表 5 に示す．ESACC-OPT には，前章で示したパラメータ設定を施したパラメータを設定する．

なお，ESACC 及び ESACC-OPT に用いた共通のパラメータを 6 に示す．

4.3 結果

評価結果を図 2，図 3，図 4 に示す．

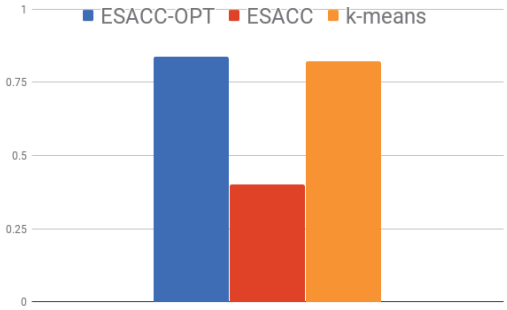


図 2: 各アルゴリズムの FM-index 値 (Iris)

3 つすべてのデータセットについて，ESACC と比較し ESACC-OPT が精度の向上を確認することができた．また，Iris と Wine のデータセットに関して，ESACC-OPT が k-means を上回る精度を得られた．

上記のパラメータ設定が，クラスタリング精度の向上に有効であることが確認できた．

4.4 考察

ESACC に比べ ESACC-OPT の精度がすべてのデータセットにおいて高かったという実験結果により，パラメータ設定がより正しい値を設定できたことがわかった．このことにより，パラメータ設定が適切であることが考えられる．

また，k-means と比較した結果においては，Sccts において精度を上回ることができなかった．属性数及びクラスタ数が多い場合を想定し，蒸発率や L の範囲を広げた挙動解析実験を行うことで，Sccts に対応したパラメータ設定を行うことができると考えられる．

5. 今後の展望

本稿では，挙動解析に基づいたパラメータ設定の有効性の検証を行った．しかし，最適なパラメータを自動的に設定可能

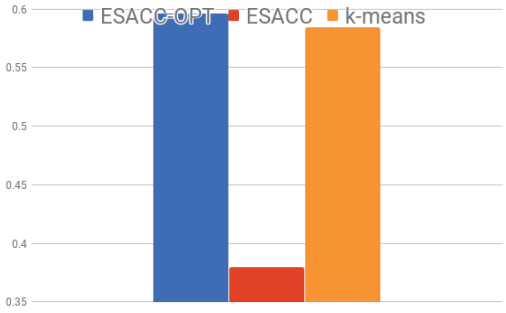


図 3: 各アルゴリズムの FM-index 値 (Wine)

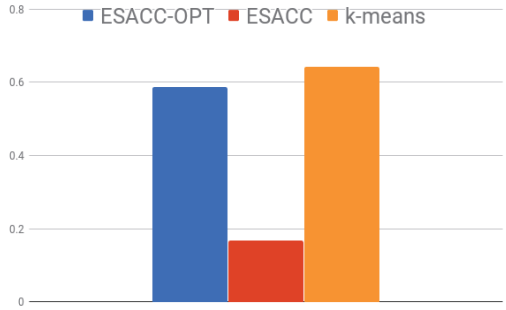


図 4: 各アルゴリズムの FM-index 値 (Sccts)

とする仕組みを確立するに至らなかった．

今後の研究において，以下の方法を検討し，正確かつ自動的なパラメータ決定を行う手法を検討する．

- パラメータ設定の数式化
- *Emin* 及び *Emax* の自動的な決定

さらに，手書き数字画像等，他のデータセットに利用することで，様々なデータのクラスタリングに有効であることを示すとともに，実際のシステムで適用可能であるかを示す．

参考文献

[Guluzar:2006] KEKE, Guluzar, N. Yumusak, and Numan ELEB.: Data Mining and Clustering With Ant Colony., Proceedings of 5th International Symposium on Intelligent Manufacturing Systems. (2006).

[Liu:2010] Liu, Xiaoyong, and Hui Fu.: ”An Effective Clustering Algorithm With Ant Colony.” JCP 5.4 (2010): 598-605.

[Fowlkes:1983] Fowlkes, Edward B., and Colin L. Mallows.: ”A method for comparing two hierarchical clusterings.”, Journal of the American statistical association 78.383 (1983): 553-569.

[UCI] UCI Repository for Machine Learning Databases , http://archive.ics.uci.edu/ml/

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

論理型言語 PROLEG から双極議論フレームワークへの変換

Conversion from Logic Programming Language PROLEG to Bipolar Argumentation Framework

川崎 樹　　高橋　和子
Tatsuki Kawasaki　Kazuko Takahashi

関西学院大学大学院　理工学研究科
School of Science & Technology, Kwansei Gakuin University

This report describes the conversion from a logic programming language PROLEG to a Bipolar Argumentation Framework(BAF), aiming at a support for judicial judgment using Artificial Intelligence. Although reasoning process of a judgment is clealy shown in PROLEG, it is difficult to understand the relationship between inference rules and the entire structure of a judgment. Here, we give a semantics to a BAF and convert the descrition in PROLEG to BAF, so that the semantics of PROLEG is reserved. As a result, it is easier to understand the relationship between inference rules and the entire structure of a judgment in the obtained BAF which consists of a set of arguments and relations of attack and support between arguments.

1. はじめに

Dung が抽象議論フレームワークを提案して以来，数理議論学はここ 20 年ほど人工知能の一分野として注目を集めている．議論は参加者が論証をかわす一種の対話で，ある主張を相手に受け入れさせるために根拠をあげ，それに対する反論を繰り返すという構造をもつため，その応用の一つとして法的推論が活発に研究されている [4]．抽象議論フレームワークでは，(発言) 論証同士の関係や議論全体の構造が容易に把握できる．

人工知能による裁判支援は論理プログラミングの分野でも提案されている．裁判において民法や刑法の条文を論理プログラミングで記述しその上で推論をすることによって，判決に至る推論過程を明確に示すことができる．そのため，プログラミングになじみのない法曹に親しみやすい記述形式を与える言語として PROLEG が考案された [3]．PROLEG は判決を行うための推論過程を論理プログラミングとして表現する．しかし，PROLEG の実行は推論過程が明確になるものの，判決に用いられた推論規則間の関係や推論の全体像が把握しにくい．

例えば，判決として殺人罪を適用する場合の推論過程を，簡単化した形で考える．一般に，殺人がありかつ犯人が殺意を抱いていたなら殺人罪が適用されるが，そうであっても正当防衛ならば無罪となる．ただし，正当防衛であるためには，相当性を示さなければならない．この時判決文では,「殺人罪である」,「殺人があった」,「殺意があった」,「正当防衛である」,「相当性がある」といったことが互いにどのように影響した結果として殺人罪を適用するという結論になったかは陽に記述されず，そのため理解しづらい．ここで,「『殺人があった』ことと『殺意があった』ことが合わせて殺人罪を適用する理由となっていて,『正当防衛である』ことは『殺人罪である』ことを否定しているが,『正当防衛である』ことを肯定するための理由である『相当性がある』ことが示されていないので，殺人罪が適用できる」というように，推論規則間の関係が陽に記述されていれば，推論過程の中で推論規則間の関係が理解しやすく，全体像も把握しやすい．判決文の規模が大きくなればこの効果は大きい．

連絡先: 川崎 樹，関西学院大学大学院 理工学研究科 高橋和子研究室，兵庫県三田市学園 2 丁目 1 番地，079-565-8391，dkw40829@kwansei.ac.jp

本研究では，PROLEG の記述を抽象議論フレームワーク [2] の拡張である双極議論フレームワーク [1] に変換する手法を考案する．また双極議論フレームワークに対して意味論を与えることで，この変換手法によって得られる双極議論フレームワークに PROLEG の記述が表す意味と同じ意味を持たせる．

本発表は以下のように構成される．まず，第 2 節では PROLEG について述べる．まず PROLEG の記述法を述べ，その後 PROLEG の推論を述べる．第 3 節では双極議論フレームワークについて述べ，さらに受理集合を定義する．第 4 節では，PROLEG の記述を BAF に変換する手法を述べる．最後に第 5 節でまとめと今後の課題を述べる．

2. PROLEG

PROLEG は Prolog を拡張して開発された，裁判支援を目的とする論理型記述言語であり，ある条文が持つ法律構成と例外事由，事実を記述することで条文が適用できるかを判定するシステムである [3]．法律構成は求めたい罪とその罪が持つ条件の関係，もしくは条件間の関係を表す．例外事由はそれが成立すれば，法律構成による推論結果よりも優先して，否という推論を行う特殊な処理を表す．事実は各裁判において実際に確認される事実を表す．

先の例で言えば,「殺人罪」が求めたい罪であり,「殺人があった」ことと「殺意があった」ことが殺人罪が持つ条件である。さらに「殺人罪」に対して「正当防衛である」ことが例外事由であり，さらに「正当防衛である」ことは「相当性がある」という条件を持っている．

これを PROLEG で記述すると，以下の例 1 のようになる．ただし記述中における'%' はそれ以下に続く文がコメントであることを示す．

例 1

```
% ルールベース
殺人罪 ⇐ 殺人行為 ∧ 殺意.
例外事由 (殺人罪, 正当防衛).
正当防衛 ⇐ 相当性.
% ファクトベース
殺人行為.
殺意.
```

PROLEG の記述はルールベース，ファクトベースの 2 つから構成される．ルールベースは法律構成と例外事由を記述する部分であり，ファクトベースは事実を記述する部分である．ファクトベースに記述された事実はすべて真であり，記述されなかった事実は偽である．よってファクトベースに記述されていない「相当性」は偽であり,「正当防衛」も偽である.「正当防衛」が偽であるので，例外事由 (正当防衛, 過剰防衛) が成立しない．また,「殺人行為」と「殺意」はファクトベースに記述されているので,「殺人罪」は真である．

もし仮に，ファクトベースに「相当性」が記述されていたならば,「正当防衛」は真となり，例外事由 (正当防衛, 過剰防衛) が成立し,「殺人罪」は偽となる．

3. 双極議論フレームワーク (BAF)

Dung は議論を抽象化するシステムである抽象議論フレームワーク (AF) を提唱した [2]．Dung は議論における発言を論証と呼び，論証の集合と論証間の攻撃関係で議論を表現した．AF は論証をノード，攻撃関係をエッジとしたグラフ表現が可能である．

Cayrol らは AF を拡張した双極議論フレームワーク (BAF) を提唱した [1]．BAF は AF に論証間の支持関係を追加し，論証の集合とその上での 2 種類の二項関係の 3 つ組 $\langle AR, ATT, SUP\rangle$ で定義される．ここで AR，ATT，SUP はそれぞれ論証，攻撃関係，支持関係の集合である．攻撃関係とはある論証が他の論証に対する反論という関係にあるという意味であり，支持関係とはある論証が他の論証を支持する関係にあるという意味である．また AF と同様に，論証をノード，攻撃関係と支持関係を 2 種類のエッジとしたグラフ表現が可能である．

例えば以下の BAF のグラフ表現は図 1 となる．

例 2 $BAF = \{\{A, B, C, D\}, \{(D, B)\}, \{(B, A), (C, A)\}\}$

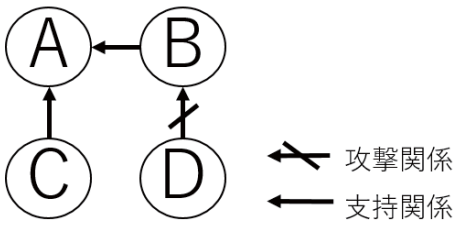


図 1: BAF の例

BAF に意味論を与える．すなわちどの論証が受理可能かを決める．

まず，例として図 1 で表される BAF を考える．論証 C と論証 D は他のどの論証からも攻撃されておらず，支持もされていない．よって論証 C と論証 D は受理可能であると考えることができる．また，論証 B は受理可能であると考えた論証 D に攻撃されている．よって論証 B は受理可能でないと考えることができる．論証 A は，受理可能であると考えられる論証 C に支持されているので受理可能であると考えられるが，一方で受理可能でないと考えられる論証 B にも支持されているため受理可能でないとも考えられる．ここで，論証 A が受理可能であると考えると受理集合 $\{A, C, D\}$ が得られる．一方で，受理可能でないと考えると受理集合 $\{C, D\}$ が得られる．

このようにどちらを優先するかによって得られる受理集合が変わる．本研究では，PROLEG を変換して得た BAF の受理集合が PROLEG の記述において真である集合と一致することが肝要なため，それに適した意味論を与える． [1] で与えられた方法に基づいて以下のように受理集合を定義する．

定義 1 *(受理集合)*. $BAF = \langle AR, ATT, SUP\rangle$ において論証の受理集合 $E \subseteq AR$ を以下のように定義する．A を論証とする．

- いずれからも攻撃されておらず，支持されていない論証はすべて E の要素である
- E の任意の 2 つの要素間に攻撃関係が存在しない
- A を支持している E の要素である論証が存在するなら，A は E の要素である
- A を支持している論証が，すべて E の要素でないなら，A は E の要素でない
- A を支持している論証が存在せず，A を攻撃している論証がすべて E の要素でないなら，A は E の要素である

4. PROLEG から BAF への変換

PROLEG の記述における推論過程を議論とみなすことで，PROLEG の記述を BAF に変換する．

PROLEG の記述中の各ゴールを論証とし，ゴール間の関係を攻撃関係と支持関係に対応させる．例 1 では「殺人罪である」ことが持つ条件は「殺人があった」ことと「殺意があった」ことである．これは「『殺人があった』かつ『殺意があった』」ことが「殺人罪である」ことを支持しているとみなすことができる．このように同時に存在する条件を 1 つにまとめ，PROLEG の記述を表現する．また「正当防衛である」ことが持つ条件は「相当性がある」ことであるので,「相当性がある」ことは「正当防衛である」ことを支持しているとみなすことができる．さらに,「正当防衛である」ことは「殺人罪である」ことを否定している．これは「正当防衛である」ことが「殺人罪である」ことを攻撃しているとみなすことができる．

PROLEG の記述において各ゴールを論証として扱うことで，論証間の関係を得ることができる．さらに，ボディゴールを要素として持つ集合を論証として扱うことで，その集合と単一の論証との間の関係も得る．これらの関係を用いて BAF を作成することで，PROLEG の意味論に対応した BAF を得る．ここで対応するとは BAF に意味論を与えた時に得られる受理集合が PROLEG の記述における真である集合と一致するということである．

以下では PROLEG の記述から BAF に変換する手法について述べる．まず，ルールベースの記述をその種類によって変換する．ここで攻撃関係 (B, A) とは論証 B が論証 A を攻撃している関係であるということを意味し，同様に支持関係 (B, A) とは論証 B が論証 A を支持している関係にあるということを意味する．

変換 1 *(攻撃変換)*. A, B を論証とする．*PROLEG* の記述「例外事由 *(A,B).*」を攻撃関係 (B, A) に変換する．

変換 2 *(単支持変換)*. A, B を論証とする．*PROLEG* の記述「$A \Leftarrow B.$」を支持関係 (B, A) に変換する．

変換 3 *(集合支持変換)*. A, B を論証，$S = \{B_1, B_2, \ldots, B_n\}$ を論証の集合とする．*PROLEG* の記述「$A \Leftarrow B_1 \wedge B_2 \wedge \cdots \wedge B_n.$」を支持関係 (S, A) に変換する．

この変換によって，例 1 の PROLEG のルールベースの記述は以下のように変換される．
$BAF = \langle AR, ATT, SUP \rangle$
AR = { 殺人罪, 殺人行為, 殺意, 正当防衛,
相当性, { 殺人行為, 殺意 }}
ATT = {(正当防衛, 殺人罪)}
SUP = {({ 殺人行為, 殺意 }, 殺人罪), (相当性, 正当防衛)}

次に存在論証を定義し，これを用いてファクトベースを BAF に変換する．存在論証とは，裁判において実際に確認される可能性があるすべての事実を示す論証である．裁判では確認された事実のみを使って推論を行う．これを BAF で表現するために，ファクトベースに記述されているときは存在論証がその事実に対応する論証に支持をし，そうでなければ攻撃をすると考える．

存在論証はルールベースの中で，規則のヘッドもしくは例外事由のゴールとして現れないすべてのゴールに対して定義される．よって例 1 では「殺人行為」,「殺意」,「相当性」に対してそれぞれ存在論証が定義され，前者 2 つには支持関係を,「相当性」には攻撃関係を加える．

変換 4 *(事実変換)*. A を論証，$existence(A)$ を存在論証とする．*PROLEG* のルールベースにおいてヘッドとして記述されていないゴール A に対し，ファクトベースに「*A.*」と記述されているなら支持関係 $(existence(A), A)$ に変換する．記述されていないなら攻撃関係 $(existence(A), A)$ に変換する．

以上の変換により以下の BAF が得られる．
$BAF = \langle AR, ATT, SUP \rangle$
AR = { 殺人罪, 殺人行為, 殺意, 正当防衛, 相当性,
{ 殺人行為, 殺意 }, $existence$(殺人行為),
$existence$(殺意), $existence$(相当性)}
ATT = {(正当防衛, 殺人罪), ($existence$(相当性), 相当性)}
SUP = {({ 殺人行為, 殺意 }, 殺人罪), (相当性, 正当防衛),
($existence$(殺人行為), 殺人行為), ($existence$(殺意), 殺意)}

この BAF のグラフ表現は図 2 となる．

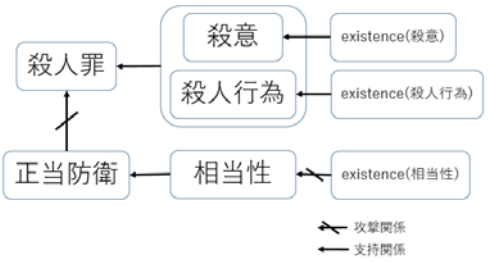


図 2: 例 1 を変換した結果得られた BAF のグラフ

変換して得られた BAF の受理集合は E = { 殺人罪, 殺人行為, $existence$(殺人行為), 殺意, $existence$(殺意), $existence$(相当性)} である．ここから存在論証を除いた集合は，PROLEG の記述で真である集合 (= { 殺人罪, 殺意, 殺人行為 }) と一致する．

5. まとめ

本発表では PROLEG の記述から BAF に変換する手法を提案した．さらに PROLEG の記述を BAF に変換するプログラムを Prolog を用いて実装した．将来的には本研究を裁判支援システムに組み込むことを目指す．

今後の課題は，変換ルールと意味論の証明を与えることと，実用可能な変換プログラムを実装することである．

参考文献

[1] Cayrol，C and Lagasquie-Schiex，M-C : Bipolar abstract argumentation systems，Artificial Intelligence，pp．65-84(2005)．

[2] Dung,P.M.: On the acceptability of arguments and its fundamental role in nonmonotonic reasoning, logic programming and n-person games. *Artificial Intelligence*, 77, 321-357 (1995).

[3] 佐藤 健ほか: PROLEG:論理プログラミングをベースとした民事訴訟における要件事実論の実装，人工知能学会第 92 回知識ベース研究会資料, pp.1 - 8(2011)．

[4] Prakken，H and Sartor，G : Law and logic : A review from an argumentation perspective．Artificial Intelligence，pp．214-215（2015）．

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

形状変化に着目した定性空間表現の提案

A Proposal of Qualitative Spatial Representation Focused on Change of Shapes

東末　桃　　高橋　和子
Momo Tosue　Kazuko Takahashi

関西学院大学大学院　理工学研究科
School of Science & Technology, Kwansei Gakuin University

This report proposes a qualitative spatial representation focused on the change of shapes, and describes temporal spatial reasoning using this representation. It aims at an application to the developmental biology by symbolically representing a process of development such as cell division and organ formation. In the process, we can find some crucial shape-changes such as bending, getting a hole, division and so on. We propose a language to represent such a characteristics and show the conditions to find possible state transitions from a given state. It enables qualitative simulation and backward reasoning for an observation of an unusual situation.

1. 序論

生命科学の分野において，単一の細胞が生き物の形をつくっていくプロセスの中には，さまざまな形状の変化がある．例えば細胞が一回分裂しひとつ数を増やす際に見られる形状変化や，細胞の塊の中の個々の細胞がそれぞれの決められた役割へ分化し移動していく際に見られる形状変化，あるいは細胞の集合体が臓器や器官を作り出す際に見られる形状変化など，さまざまな形状変化が複雑に組み合わさることによって，生き物の形状形成は成立している [4, 5].

このような発生過程をシミュレートして解析したり可視化したりする研究は多く行われており，そこではデータ解析や画像処理の様々な技術が使われている．たとえば，色情報，周波数，位相，特徴点，輝度勾配，ヒストグラム，テクスチャ，エッジなどの情報を用いて，画像データから特定の部位を抽出するテクスチャ解析や，画像データから細胞数を自動でカウントするためのアルゴリズムなどである [7]．これらは，対象の量的な側面に着目し数値的な情報を取り扱う定量的なアプローチによる研究である．定量的なアプローチでは，扱うデータが正確なものである反面，そのデータ量はかなり大きなものとなる．しかし，目的によっては詳細で正確なデータを必要としないものも多い．

本研究の目的は，発生生物学において，たくさんの細胞が並ぶことによって作られる面 (細胞シートとよばれる) が生き物のさまざまな臓器や器官を作っていくプロセスについて，細かい変化は見ずに形状という特性に着目し，その定性的な変化をとらえることである．

そのために本研究では定性空間推論 (Qualitative Spatial Reasoning, QSR) を使ったアプローチをとる．QSR は，画像や図形などの空間データについて，着目したい性質および特性を取り出し記号表現によって記述しようとするものである [1, 2, 3]．先に述べた定量的なアプローチとは対照的な見方で，どのような点に着目するかは，目的によって変わる．例えば二つの空間領域が存在し，その相対的な位置関係について着目する場合，必要なのは離れているか，重なっているかであり，領域間の具体的な距離については考慮しない．このようにユーザが必要な情報のみを扱うので，定量的なアプローチに比べてデータ量がはるかに少なくてすむという利点がある．

形状に着目した QSR の一つとして，形をその輪郭線の特徴で表現する手法がある [3]．この研究では，曲線のセグメントの形状を曲率によって 7 種類に分類して基本要素とし，それを列として輪郭の形状を表現する．しかし，このような既存の QSR では発生生物学において特に重要な凹部の形成や自身と接しているといった特徴的な形状を表現することができない．そのため本研究ではこれらを表現するための独自の記述方法を提案し，それを使って発生の過程を記述する．

本発表の構成は以下の通りである．第 2 章では形状のモデル化と記述言語について述べる．第 3 章では形状の特徴によって分類されたクラス間の遷移について述べる．第 4 章では結論と今後の課題について述べる．

連絡先: 東末　桃，関西学院大学大学院 理工学研究科 高橋和子研究室，兵庫県三田市学園 2 丁目 1 番地，079-565-8391，emu48539@kwansei.ac.jp

2. 形状の表現

2.1 特徴の表現

本研究では，細胞シートの断面図をみて，細胞シートの形状変化を線の形状変化に置き換えて扱う．形状の特徴として端点をもつ有限な線を対象とし，凹部の有無，接点の有無，空洞の数の三つに着目し，オブジェクトを分類する．

凹部の有無 対象とするオブジェクトの中に凹部があるかないかで区別する．このとき，凹部の位置や大きさについては考えない．凹部があれば D，なければ $\neg D$ と表記する．

接しているか 対象とするオブジェクト自身が自分と接点をもつかどうかで区別する．接点をもっていれば T，もっていなければ $\neg T$ と表記する．

空洞の数 対象とするオブジェクトが構成する，閉じた面の数によって区別する．オブジェクトが空洞を n 個含むことを，$N(n)$ と表記する．

図 1 は管状の器官とその断面図をあらわすもので，(a) は $D \wedge \neg T \wedge N(1)$，(b) は $D \wedge T \wedge N(2)$ のように表記する．

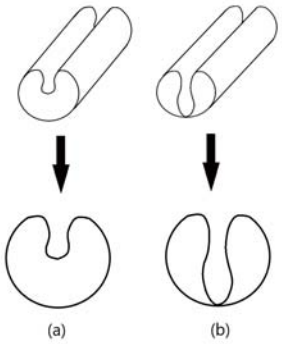


図 1: 特徴による分類

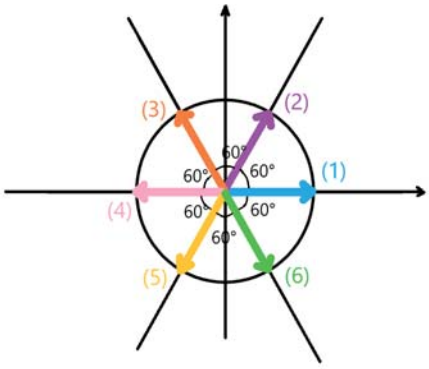


図 3: *dline* と方向の対応関係

2.2 モデル化

まずシートの断面図を線分で構成される図形にモデル化する (図 2(a))．そして，その図をセグメント単位に分解しそれらを並べる (図 2(b))．

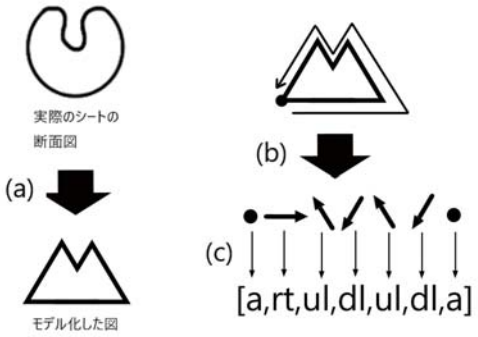


図 2: 細胞シートの形から記述言語への変換

シートの断面図をモデル化した後，各セグメントをそれぞれに対応する記号に置き換える (図 2(c))．そのようにしてできた記号列が，線の形状をあらわしていることになる．記号については以下で説明する．

2.3 記述言語

形状を表現するための記述言語を定義する．表現の基本要素である *dline* および *point*，それらの列で構成される *exp* は以下のとおりである．

$$
\begin{aligned}
&exp ::= seg | seg, exp \\
&seg ::= dline | point \\
&dline ::= \mathrm{rt}|\mathrm{ur}|\mathrm{ul}|\mathrm{lt}|\mathrm{dl}|\mathrm{dr} \\
&point ::= \mathrm{a}|\mathrm{b}|\ldots \ (\mathrm{a,b,}\ldots \text{ は定数})
\end{aligned}
$$

dline は方向をつけた線分をあらわすもので，6 種類存在する．長さは考慮しない．図 3 において，(1) から (6) はそれぞれ rt, ur, ul, lt, dl, dr に対応している．*point* は閉じた部分をつくるための点をあらわす．

2.4 特徴の判定

この記述言語を使って形状の特徴がどのように抽出されるかについて説明する．

e を exp とする．e が以下の条件のどれかを満たすとき，e は凹部をもつと判断する．

条件 1 e が以下のいずれかを部分列として含む．

$[\mathrm{rt}, p, \mathrm{dl}, \mathrm{rt}, \mathrm{ul}, p, \mathrm{rt}]$ ただし，p は任意の *point*

$[\mathrm{lt}, p, \mathrm{dr}, \mathrm{lt}, \mathrm{ur}, p, \mathrm{lt}]$ ただし，p は任意の *point*

条件 2 e から *point* を除いた列が以下のいずれかを部分列として含む．

[rt または ur, dr, ur, rt または dr]

[lt または ul, dl, ul, lt または dl]

e を exp とする．e が以下の条件のどれかを満たすとき，e は接点をもつと判断する．

p を *point*，e を exp とする．このとき，p, e, p の形であらわされる列を $s\_point(p)$ とよぶ．$s\_point(p)$ は直観的には p で閉じている線分に対応する．

条件 1 p を *point* とする．$s\_point(p)$ を部分列としてもち，かつ，その $s\_point(p)$ の直前または直後に *dline* がある．

条件 2 p を *point* とする．$s\_point(p)$ を部分列としてもち，かつ，$s\_point(p)$ が $s\_point(q)$ を部分列として含むような p と異なる q が存在する．

条件 3 同一の *point* を三つ以上含む．

e を exp とする．e にあらわれる *point* の集合を P_e とする．$occur(e, p)$ を e 中にあらわれる p の数とするとき，e に対応する図形に含まれる空洞の数は $n = \sum_{p \in P_e} |occur(e, p) - 1|$ である．

3. 状態遷移

正常な形状変化のプロセスを考えると，形状と形状の間の遷移は以下の四つになる．

遷移 1 $\neg D \wedge \neg T \wedge N(n) \rightarrow D \wedge \neg T \wedge N(n)$

遷移 2 $D \wedge \neg T \wedge N(n) \rightarrow D \wedge T \wedge N(n+1)$

遷移 3.1 $D \wedge T \wedge N(2n) \rightarrow (\neg D \wedge \neg T \wedge N(n)) \wedge (\neg D \wedge \neg T \wedge N(n))$

遷移 3.2 $D \wedge T \wedge N(2n+1) \rightarrow (\neg D \wedge \neg T \wedge N(n)) \wedge (\neg D \wedge \neg T \wedge N(n+1))$

ただし n は任意の自然数である

例えば遷移 1 は凹部が形成されるという変化をあらわしている．この遷移 1 は，凹部がなく自分との接点がなく空洞の数が n であるようなオブジェクトは，凹部があり自分との接点がなく空洞の数が n であるようなオブジェクトにのみ直接遷移可能であることをあらわしている．

2 次元平面上で実現可能であり，実際にみられる変化を考えて得られる形状は八つのクラスに分類される．遷移条件に従った，八つのクラスに関する可能な状態遷移を図 4 に示す．

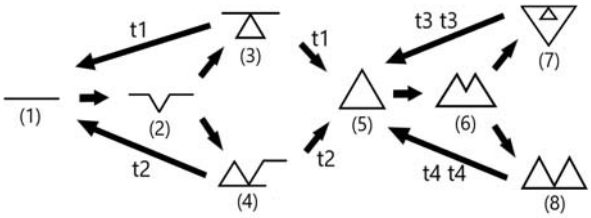


図 4: 可能な状態遷移

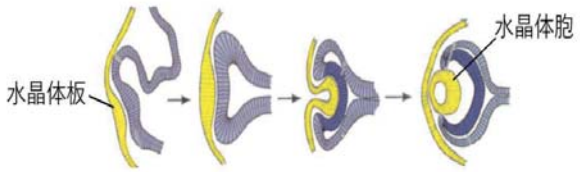


図 5: 眼の形成 [6]

図 4 において，矢印は状態間で直接遷移可能であることを示し，矢印に付加された記号 $t1$ から $t4$ は，それぞれ同時に起こる遷移であることをあらわしている．例えば (3) であらわされる形状のオブジェクトは，(1) と (5) であらわされる形状の二つのオブジェクトに分裂したことを意味する．

この状態遷移図を使って，生命科学で実際にみられる形状の変化をシミュレートすることができる．例として，人間の眼の形成について取り上げる．水晶体板とよばれる器官から，水晶体胞とよばれる器官が形成される様子 (図 5 の黄色部分) は，図 4 の状態遷移図上では (1)→(2)→(3)→(1)+(5) という経路をたどっている．

この状態遷移図を使ってある状態からどのようなプロセスで変化をしてどこに至るか，あるいは，ある状態に至るにはどこからどのようなプロセスで変化したかについて推論することができる．

4. 結論

発生過程における正常な形状変化のプロセスをモデル化する QSR の言語を提案した．この言語で，今まで表現できなかった凹部の有無，オブジェクト自身との接点の有無，空洞の数の三点に着目した記述が可能になった．また，それを用いて細胞シートが正常に変形していく様子を定性的にシミュレートできていることを示した．

本研究では細胞シートの断面を線としてみており，扱える対象が限られるため，今後は中身のつまった球体に凹部や空洞が形成される様子なども扱えるようにしていく．

また，任意の与えられた記述言語に対応する 2 次元平面上の図形が存在するとは限らない．今後は 2 次元平面上の図形が存在するための条件について考える必要がある．そのほか，記述言語に関する数学的な性質についても考察する予定である．

参考文献

[1] Chen, J. Galton, A. Cohn, A. G. et al. A survey of qualitative spatial representations. *The Knowledge Engineering Review*, 30:106-136, 2013.

[2] Cohn, A. G. Bennett, B. Gooday, J. Gotts, N. M. Qualitative spatial representation and reasoning with the region connection calculus. *GeoInformatica*, 1:275-316, 1997,

[3] Galton, A. Meathrel, R. C. Qualitative outline theory. *Proceedings of the Sixteenth International Joint Conference on Artificial Intelligence*, 1061-1066, 1999.

[4] 上野直人，野地澄晴. 発生物学がわかる. 羊土社, 2004.

[5] Wolpert, L. Tickle, C. ウォルパート 発生生物学. メディカル・サイエンス・インターナショナル, 2016.

[6] RAIN ON BEGINNING-眼の発生-. http://rainonbeginning.blog.fc2.com/blog-entry-63.html

[7] バイオメディカルシリーズ. 医用画像処理: 細胞数の自動カウント. https://www.mathworks.com/videos/medical-image-processing-cell-counting-120734.html, accessed March 3,2018.

[1E2] [General Session] 6. Web Mining

座長:池田 和史（KDDI綜合研究所）

Tue. Jun 5, 2018 3:20 PM - 5:00 PM Room E (4F Queen)

[1E2-01] Deep Reinforcement Learning for Recommendation System

○Takashi Kawashima[1], Syunyo Kawamoto[1], Daisuke Tsumita[1], Syo Simoyama[1], Isshu Munemasa[1], Yuta Tomomatsu[1], Kunioki Hayashi[2], Tomohiro Takagi[1] （1. Meiji University, 2. DesignOne Japan, Inc）

3:20 PM - 3:40 PM

[1E2-02] Proposal of Route Recommending Method based on Formulation using Edge Vector

○Hiroki Shibata[1], Yasufumi Takama[1] （1. Tokyo Metropolitan University）

3:40 PM - 4:00 PM

[1E2-03] Churn Prediction using Deep Learning

○Kunihiro Miyazaki[1], Natsuki Murayama[2], Yuki Yamamoto[1], Fumiaki Ushiyama[3], Shohei Ohsawa[1], Yutaka Matsuo[1] （1. School of Engineering, The University of Tokyo, 2. Dept. of Arts and Science, The University of Tokyo, 3. WealthNavi Inc.）

4:00 PM - 4:20 PM

[1E2-04] Targets Recommendation Considering After M\&A Performance by Content based Neural Collaborative Filtering

○Masanao Ochi[1], Yasuko Yamano[1], Kimitaka Asatani[1], Akira Kitauchi[2], Tomoyuki Ota[2] （1. The University of Tokyo, 2. UZABASE Inc.）

4:20 PM - 4:40 PM

[1E2-05] Mathematical model for search action on the Internet

○Akira Ishii[1], Noboru Ashida[1], Yasuko Kawahata[2] （1. Tottori university, 2. Gunma University）

4:40 PM - 5:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

深層強化学習による推薦システム

Deep Reinforcement Learning for Recommendation System

川島 崇 *1 Takashi Kawashima
川本 峻頌 *1 Syunyo Kawamoto
積田 大介 *1 Daisuke Tsumita
下山 翔 *1 Syo Shimoyama
宗政 一舟 *1 Isshu Munemasa
友松 祐太 *1 Yuta Tomomatsu
林 邦興 *2 Kunioki Hayashi
高木 友博 *1 Tomohiro Takagi

*1明治大学大学院理工学研究科情報科学専攻 Department of Computer Science, Meiji University
*2DesignOne Japan DesignOne Japan,Inc

Services that introduce stores to users on the Internet are increasing in recent years. Each service conducts thorough analyses in order to display stores matching each user's preferences. When sufficient data cannot be obtained, a multi-armed bandit algorithm is applied. Bandit algorithms advance learning by testing each of a variety of options sufficiently and obtaining rewards (i.e. feedback). It is practically impossible to learn everything when the number of items to be learned periodically increases. In order to solve this problem, we propose a recommender system based on deep reinforcement learning. In deep reinforcement learning, a multilayer neural network is used to update the value function.

1. はじめに

近年, インターネット上でユーザに対して店舗の紹介を行うサービスが増えてきている. 各サービスでは同時に, ユーザの嗜好に合った店舗を表示させる分析が幅広く行われてきている. 推薦の分野ではユーザのクリック情報が十分に存在する時には協調フィルタリングが高い性能を誇る. 一般的にユーザ×アイテムの行列を作成した際, データスパースの問題が発生するので新規ユーザに対応することが難しい. また十分にデータが得られなかった場合, バンディットアルゴリズムなどを応用しているケースが見られる. バンディットアルゴリズムは各アームを十分に試行してそれぞれから報酬を得ることで学習を進めていくため, アイテム数が多くなった場合に全てを学習するのは実質的に不可能である. 新たなユーザが出てきた時に十分にデータを集める必要性は協調フィルタリングと同様の問題がある. 上記の問題を解決すべく本稿では強化学習の価値関数の更新に多層ニューラルネットを用いた深層強化学習による推薦システムの提案を行う.

2. 関連研究

バンディットアルゴリズムではランダムで広告の配信を行う探索と期待値の高い広告を配信する活用の 2 つのフェーズが存在する. 探索, 活用のフェーズどちらにおいてもクリックされた場合 1, クリックされなかった場合 0 というフィードバックを受け取る. これを一般的に報酬と呼ぶ. バンディットアルゴリズムにおいて有名な手法として ϵ-greedy 法, softmax 法 [Richard 98], UCB 法 [P. Auer 02], そして Thompson Sampling[William 33] がある (Non Contextual-Bandit). Contextual なバンディットとして linUCB[Lihong 10] も提案されている.

バンディットアルゴリズムは強化学習の枠組みで議論することができる. 強化学習ではエージェントと環境を定義し, ある状態においてエージェントが行動したことによるフィードバック (報酬) と次の状態を環境から受け取る. また行動価値を定義し, この価値を最大化するようにエージェントの学習を進める (Q-learning)[Christopher 92]. 行動価値は即時報酬ではなく, 将来もらえる報酬を考慮して行動を選択する. バンディットアルゴリズムでは環境は行動によって変化せず, 広告表示後のフィードバックを直ぐに反映させるような即時報酬を最大化する. 対して Q-learning では一連の行動を行った結果得られた累積報酬を最大化する.

近年, 価値関数を多層ニューラルネットワークで表現する深層強化学習の研究が盛んに行われている.Deep Q Net(DQN)[Volodymyr 13] は深層強化学習でも有名な手法であるが, 行動空間と状態空間が連続値である場合に使用することが難しい. Deep Deterministic Policy Gradient(DDPG)[Timothy 16] はエージェントの状態空間や行動空間が連続値の場合でも高い性能を誇る手法であり本研究の推薦システムに用いた.

3. 問題設定

店舗情報サイト「エキテン」では, ユーザがエリアとジャンルをキーワードとして検索を行うと, キーワードにマッチする店舗が表示される. ユーザは表示される店舗の紹介文, 口コミ, 写真や評価を基に訪れたい店舗に問い合わせや予約ができる. 本研究ではエキテン内で検索が行われた際, ユーザに最適な店舗を表示する. その際, 表示した店舗がユーザの嗜好に近づくようにモデルの更新を行う. ユーザから得られる入力情報としてはエリアとジャンルであるが, ユーザが探しているエリアから離れすぎた店舗を推薦することは現実的ではない. よって推薦対象となるのは, エリアの周辺に存在する店舗である. 店舗の推薦は過去の店舗情報の詳細ページへのクリックログを基に深層強化学習の枠組みで学習が進められる. 本研究では DDPG を用い状態空間及び行動空間が連続の問題に対応する. エージェントの出力する店舗の学習が進むにつれてユーザの嗜好に近づいていくかを本研究では確認する.

連絡先: 川島崇, 明治大学大学院理工学研究科情報科学専攻, 〒 214-8571 神奈川県川崎市多摩区東三田 1-1-1, t_kawashima@cs.meiji.ac.jp

4. 深層強化学習による店舗推薦

店舗推薦をするために 深層強化学習を用いた. 深層強化学習では Q learning などの強化学習と同様, 行動, 状態, 報酬, エピソードの定義をする必要がある. エキテンが扱う店舗のレビューをコーパスとして LDA を用いて分散表現にする. エージェントの学習は行動ベクトルとして店舗の分散表現を出力するように進められる. 以下, 本節では店舗ベクトルの表現方法 (4.1 節), 深層強化学習に必要な要素の定義 (4.2 節), 本研究で用いる深層強化学習のアルゴリズム (4.3 節) を順に記述する.

4.1 店舗ベクトルの分散表現

店舗ベクトルを分散表現にするために Latent Dirichlet Allocation(LDA) を用いる. LDA は文書の確率的言語モデルとして, 単語の共起性を統計モデルとして数理的に扱うために提案された. 文書中の単語の順序は無視し, Bag of Words(BoW) と呼ばれる単語と出現頻度のペアの集合をモデル化する. LDA では 1 つの文書が N 個のトピックから成ることが仮定されているため, 各トピックの値が確率値になっている. よって各トピックの和は 1.0 になる. 本研究では店舗ごとのレビュー群を 1 文書として LDA を行い, 文書を推論した際の各トピックの確率値を要素とするような N 次元の分散表現を店舗ベクトル $\boldsymbol{item}$ とする.

4.2 強化学習の構成要素

本節では強化学習の構成要素であるエージェント, 環境そしてエピソードをどのように定義したかの説明を記述する.

4.2.1 エージェント

エージェントは時刻 t に環境から状態 $\boldsymbol{s}_t$ を受け取った時に N 次元の店舗ベクトルを行動 $\boldsymbol{a}_t$ を出力し, フィードバックとして報酬 $\boldsymbol{r}_t$ を受け取りモデルの更新を行う. $\boldsymbol{a}_t$ は行動空間 $\boldsymbol{A} \in [0,1]^N$ 上の要素である. 状態 $\boldsymbol{s}_t$ と報酬 $\boldsymbol{r}_t$ については後述する. 時刻 t に店舗を推薦する際, ユーザが入力したエリアとジャンルを基に推薦対象になる店舗集合 $\boldsymbol{Item}_t$ が決まる. エージェントが出力した行動 $\boldsymbol{a}_t$ と推薦対象になる店舗 $\boldsymbol{item}$ 間の類似度を算出する. 類似度計算には以下の方法を用いる.

$$\mathrm{sim}(\boldsymbol{a}_t, \boldsymbol{item}) = \frac{\sum_{n=1}^{N} a_{t,n} item_n}{\sqrt{\sum_{n=1}^{N} a_{t,n}^2}\sqrt{\sum_{n=1}^{N} item_n^2}} \tag{1}$$

推薦対象の店舗集合 $\boldsymbol{Item}_t$ をそれぞれ行動ベクトル $\boldsymbol{a}_t$ と式 (1) で定義した類似度を算出して, 類似度が最大となるような店舗 $\boldsymbol{recommend\_item}$ をユーザに対して表示する.

$$\boldsymbol{recommend\_item} = \underset{\boldsymbol{item} \in \boldsymbol{Item}_t}{\arg\max}\ \mathrm{sim}(\boldsymbol{a}, \boldsymbol{item}) \tag{2}$$

4.2.2 環境

環境はエージェントから受け取った店舗をユーザに対して表示した後, クリックしたか否かを基に計算した報酬 r_t と次の状態 $\boldsymbol{s}_{t+1}$ をエージェントに渡す.

報酬 r_t はエージェントが出力した行動ベクトル $\boldsymbol{a}_t$ と推薦対象になる店舗集合 $\boldsymbol{Item}_t$ の中で実際にクリックされた店舗 $\boldsymbol{clicked\_item}_t$ の類似度とする.

$$r_t = \frac{\sum_{n=1}^{N} a_{t,n} clicked\_item_{t,n}}{\sqrt{\sum_{n=1}^{N} a_{t,n}^2}\sqrt{\sum_{n=1}^{N} clicked\_item_{t,n}^2}} - 0.5 \tag{3}$$

上記のように報酬を定義する. 式 (3) の前半部分はコサイン類似度である. 行動空間は $\boldsymbol{A} \in [0,1]^N$ であるためコサイン類似度は 0 から 1 の間の値を取る. クリックされた店舗との類似度が低い推薦をした場合, 負の報酬を与えたい. そこでコサイン類似度から 0.5 を差し引くことで報酬 r_t は $r_t \in [-0.5, 0.5]$ になる. 本研究では報酬の与え方として 2 通りある. 1 つめは DDPG が出力した N 次元のベクトルとクリックされた店舗の類似度を報酬として与える方法である (r_{action_vec}). 2 つめは式 (3) における行動ベクトルを式 (2) で求めた $recommend\_item$ に置き換えて計算したものである (r_{item_vec}).

状態はユーザが時刻 $t-1$ までに閲覧した店舗と時刻 t に入力したエリアとジャンルを基に表現する. エリアは緯度経度の情報 $\boldsymbol{area}_t$ の 2 次元のベクトルで表現をする. 本研究ではグルメジャンルを対象に推薦を行う. グルメジャンルには 40 種類の小ジャンルがあり, ジャンルについては 40 次元の one-hot ベクトル $\boldsymbol{genre}_t$ とする. 過去の閲覧店舗ベクトルを $\boldsymbol{history}_t$ として, ユーザが直近で閲覧した店舗ベクトル j 件を加算して表現する. ただし, 直前に閲覧した店舗とそれよりも前に閲覧した店舗を比べた時に直前の方がユーザのリアルタイムな嗜好が反映されていると考えることができるため割引和 $\gamma \in [0,1]$ を採用する. この時, ユーザの閲覧履歴 $\boldsymbol{history}_t$ を以下のように定義する.

$$\boldsymbol{history}_t = \sum_{i=1}^{j} \gamma^i \boldsymbol{clicked\_item}_{\boldsymbol{t-i}} \tag{4}$$

店舗ベクトルは確率値で表現される. 閲覧履歴も確率値で表現することにする. 以下の式のように $\boldsymbol{history}_t$ を正規化する.

$$\begin{aligned}\mathrm{Normalized}(\boldsymbol{history}_t) &= \boldsymbol{normalized\_history}_t \\ &= \frac{\boldsymbol{history}_t}{\|\boldsymbol{history}_t\|}\end{aligned} \tag{5}$$

上記で定義した $\boldsymbol{area}_t$, $\boldsymbol{genre}_t$, $\boldsymbol{normalized\_history}_t$ を用いて状態ベクトル $\boldsymbol{s}_t$ を以下のように定義する.

$$\boldsymbol{s}_t = \mathrm{concat}\big(\boldsymbol{area}_t, \boldsymbol{genre}_t, \boldsymbol{normalized\_history}_t\big) \tag{6}$$

concat はベクトルを連結させるような関数とする.

4.2.3 エピソード

エピソードはユーザが最初にグルメジャンルの店舗が表示されるページに訪れた時に開始する. エピソード内の各ステップすなわち状態遷移はユーザがグルメジャンルの店舗が表示されるページに訪れる度に発生する. ユーザのページの遷移が 30 分間なかったらエピソード終了とする. その後, 同ユーザが新たに訪問した場合, 新たなエピソードとして開始させる. このようにエピソードを定義したのは同ユーザでも時間が空いた後の検索は目的や嗜好が異なる可能性が考えられるためである.

4.3 深層強化学習アルゴリズム

本研究では DDPG を用いて店舗推薦システムを作成した.DDPG は DQN と Deterministic Policy Gradient(DPG)[David 14] を組合せた手法である. DQN からは experience replay でサンプル間の相関を最小にし, ターゲット関数を用いることで学習を安定させる方法を取り入れている. DPG からは状態の価値を評価するクリティック関数と状態に応じて確率的に行動を選択するアクター関数を用いることで行動空間が連続値な場合でも扱える方法を取り入れ

ている．DDPG では時刻 t で replay buffer に格納されている現在の状態, 行動, 報酬, 次の状態を含むタプル集合から B_t 個のミニバッチをランダムにサンプリングしてきたものを使ってクリティック関数とアクター関数の更新を行う．B_t 個のサンプルに含まれるタプル集合の要素を $(s_{t,i}, a_{t,i}, r_{t,i}, s_{t,i+1})$ とする．また行動価値関数を $Q(s_{t,i}, a_{t,i})$ とするとクリティック関数は以下に示す損失関数 L を最小化するように更新される．

$$L = \frac{1}{B_t}\sum_i (y_{t,i} - Q(s_{t,i}, a_{t,i}|\theta^Q))^2 \tag{7}$$

ここでクリティックとアクターのターゲットネットワーク $\theta^{Q'}, \theta^{\mu'}$ より算出される行動価値と報酬 $r_{t,i}$ を用いて教師信号 $y_{t,i}$ を以下のように表す．γ は割引率で $\gamma \in [0, 1]$ である．

$$y_{t,i} = r_{t,i} + \gamma Q'(s_{t,i}, \mu'(s_{t,i+1}|\theta^{\mu'})|\theta^{Q'}) \tag{8}$$

アクター関数については以下の式で表される勾配を基に更新される．

$$\nabla_{\theta^\mu} J \approx \frac{1}{B_t}\sum_i \nabla_a Q(s, a|\theta^Q)|_{s=s_{t,i}, a=\mu(s_{t,i})} \nabla_{\theta^\mu}\mu(s|\theta^\mu)|_{s_{t,i}} \tag{9}$$

バッチ内では先程記述した 2 つのターゲットネットワークを固定し, クリティックネットワーク θ^Q とアクターネットワーク θ^μ を常に更新するパラメータにして学習を進めることで安定させている．

5. 実験

本節では実験に関する記述を行う．実験ではエキテンで過去10ヶ月分の配信データを用いる．具体的には, ユーザが検索をして店舗が表示された際, クリックが発生したログを対象とする．クリックが発生しなかったログについては実験の対象外とする．5.1 では DDPG の実験設定の説明を行う．5.2 では比較手法の種類と実験設定の説明を行う．5.3 では評価方法について説明を行い, 5.4 で実験結果を示し, 5.5 で考察を行う．また, 本実験では店舗の分散表現の次元数を $N = 50$ としている．

5.1 提案手法

DDPG を使用する． 報酬の与え方を 4.2.2 で説明した r_{action_vec} と r_{item_vec} の 2 パターンで実験を行う．

5.2 比較手法

提案手法の優位性を検証するために推薦を Random に行う方法とバンディットアルゴリズムによる方法と比較する．

コンテキスト情報を用いないバンディットアルゴリズムとして ϵ-greedy($\epsilon = 0.1, 0.3$), UCB, thompson Sampling, softmax($\tau = 0.05, 0.2$) アルゴリズム, コンテキスト情報を使うバンディットアルゴリズムとして LinUCB($\alpha = 1.0, 1.4$) を採用した．報酬は比較手法では店舗を直接推薦するため,r_{item_vec} で与える．

5.3 評価方法

推薦アルゴリズムの評価に Mean Reciprocal Rank(MRR) と Recall@k を用いる．MRR は各ステップでクリックされたアイテムの逆順位を平均したものである．Recall@k は各ステップでクリックされたアイテムを上位 k 件以内に推薦できた割合である．実験では,k の値を 3 として評価する．

表 1: DDPG における報酬変更時の MRR と Recall@3 のスコア

method	reward_type	MRR	Recall@3
ddpg	r_{action_vec}	0.302	0.327
	r_{item_vec}	0.295	0.317

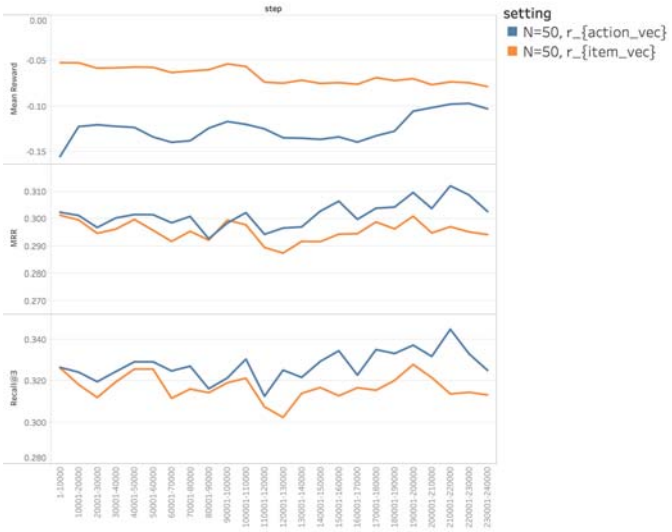


図 1: DDPG における報酬を変えたときの 10,000 ステップごとの平均報酬,MRR,Recall@3

5.4 実験結果

5.4.1 報酬の与え方による性能比較

DDPG に適した報酬の与え方を求めるための事前実験を行う． 報酬を r_{action_vec} と r_{item_vec} とした場合の比較実験を行った．表 1 では 2 種類の報酬で実験を行ったときの MRR と Recall@3 のスコアを示す．MRR と Recall@3 のスコアはどちらも r_{action_vec} が r_{item_vec} を上回っている．図 1 では DDPG アルゴリズムにおいて報酬を変えて実験を行ったときの 10,000 ステップごとの平均報酬, MRR, Recall@3 である．平均報酬に関して r_{action_vec} では増加傾向, r_{item_vec} では減少傾向が見られる．以上のことから報酬は r_{action_vec} を与えることによって学習が安定し, 各ステップで MRR,Recall@3 ともに高いスコアとなることがわかる．

5.4.2 既存手法との性能比較

5.4.1 節では DDPG の報酬設計の比較を行った．ここでは, DDPG と従来手法を比較することによって DDPG の優位性を示す．表 2 は各手法の全実験設定の結果である．提案手法の DDPG(r_{action_vec}) は MRR=0.302,Recall@3=0.327 でありバンディットアルゴリズムとランダム推薦の全ての条件の中で最も良いスコアであった．バンディットアルゴリズムで最もスコアが高かったのは softmax($\tau = 0.2$) であり, MRR=0.292, Recall@3=0.311 であった．図 2 では DDPG が他の手法に比べて学習初期段階から高い MRR 値と Recall@3 を示している．また, DDPG は学習が進んでもほぼ全てのステップにおいて MRR, Recall@3 ともに最大のスコアである．

5.5 考察

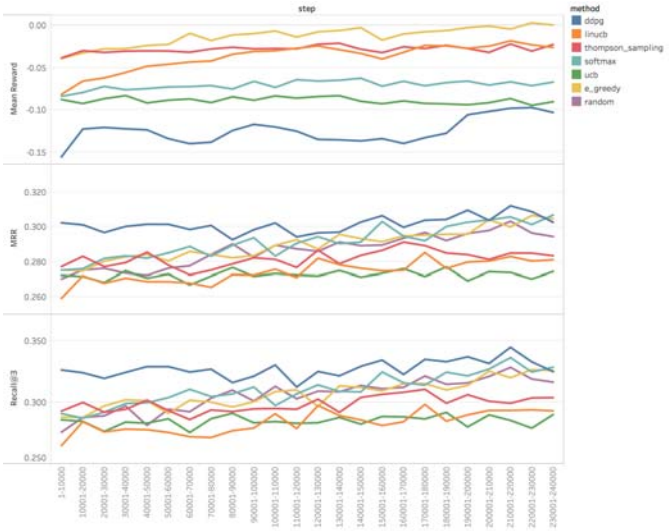
実験の結果から考察を行う．

まず, DDPG とバンディットアルゴリズムを比較すると, DDPG では学習初期段階から高い MRR と Recall@3 であった．DDPG では行動として店舗ベクトルを分散表現で出力している．その為, ある店舗を推薦した際に得られる報酬を他の店舗の推薦の際も活用できる．対して, バンディットアルゴリ

表 2: 各実験設定における MRR と Recall@3 のスコア

method_	hyper_parameter	reward_type	MRR	Recall@3
ddpg	-	r_{action_vec}	0.302	0.327
		r_{item_vec}	0.295	0.317
linucb	$\alpha = 1.0$		0.271	0.280
	$\alpha = 1.4$		0.268	0.276
thompson_sampling	-		0.281	0.296
softmax	$\tau = 0.2$		0.292	0.311
	$\tau = 0.05$		0.288	0.304
ucb	-		0.273	0.285
ϵ_greedy	$\epsilon = 0.1$		0.288	0.303
	$\epsilon = 0.3$		0.290	0.306
random	-	-	0.287	0.306

図 2: 各手法で最もスコアの高かった実験設定の 10,000 ステップごとの平均報酬,MRR,Recall@3



ズムでは各店舗に対してそれぞれ探索を行わなければならないため学習の速さに大きな差がある．これはシステムに深層強化学習を適用した効果であると考えられる．

最後に，報酬設計に関して r_{action_vec} が r_{item_vec} よりも安定した学習ができた．報酬設計を r_{item_vec} としたときに学習が安定しなかった理由としては，報酬を求める際に，出力した行動ベクトルを店舗ベクトルに置き換えていることに原因があり，行動ベクトルと店舗ベクトルの乖離が大きい場合に適切な報酬が与えられない可能性がある．特に学習初期段階では行動ベクトルがランダムに出力されるため発生しやすい．そのため 4.2.2 節で，r_{item_vec} によって報酬がうまく与えらず，ステップが増えるに連れて平均報酬が減少していったと考えられる．一方で r_{action_vec} ではステップが増えるに連れて平均報酬が増加し，それに伴い MRR と Recall@3 のスコアも増加した．

6. おわりに

本稿では，深層強化学習を用いた推薦システムのフレームワークを提案し従来手法よりも高い推薦精度を実現することができた．強化学習を用いることで状態遷移を考慮した推薦を行うことができた．さらに，以下の貢献がある．

まず，深層強化学習によって推薦する店舗を N 次元の分散表現のベクトルとして出力することができた．そのため，店舗を直接推薦するバンディットアルゴリズムと比較して効率よく学習を行うことを可能にし，結果として高い MRR 値と Recall 値となった．また本システムでは報酬がクリックされた店舗ベクトルとの類似度で与えられるため，推薦した店舗以外の店舗がクリックされた場合も報酬を与えることができた．そのためオフラインでも学習することが可能となった．3 つ目に店舗ベクトルはレビューから作られているため，新規店舗が出現した場合にもその店舗に対して LDA のベクトルを作ることが出来れば新規店舗も推薦可能である．

本稿では，状態に使う特徴や DDPG の細かいハイパーパラメータ等を検証できていない．将来これらを含めて深層強化学習による推薦手法について検証していく必要がある．

参考文献

[Richard 98] Richard S. Sutton, Andrew G. Brato: Reinforcement Learning, The MIT Press (1998)

[P. Auer 02] P. Auer, N. Cesa-Bianchi, P. Fischer: Finite-time analysis of the multiarmed bandit problem, Machine Learning (2002)

[William 33] William R. Thompson: ON THE LIKELIHOOD THAT ONE UNKNOWN PROBABILITY EXCEEDS ANOTHER IN VIEW OF THE EVIDENCE OF TWO SAMPLES, Oxford University Press on behalf of Biometrika Trust, Vol.25 (1933)

[Lihong 10] Lihong Li, Wei Chu, John Langford, Robert E. Schapire: A Contextual-Bandit Approach to Personalized News Article Recommendation, World Wide Web (2010)

[Christopher 92] Christopher J.C.H. Watkins: Q-Learning, Machine Learning (1992)

[Volodymyr 13] Volodymyr Mnih, Koray Kavukcuoglu, David Silver, Alex Graves, Ioannis Antonoglou, Daan Wierstra, Martin Riedmiller: Playing Atari with Deep Reinforcement Learning, NIPS Deep Learning Workshop (2013)

[Timothy 16] Timothy P. Lillicrap, Alexander Pritzel, Nicolas Heess, Tom Erez, Yuval Tassa, David Silver, Daan Wierstra: CONTINUOUS CONTROL WITH DEEP REINFORCEMENT LEARNING, International Conference on Learning Representations (2016)

[David 14] David Silver, Guy Lever, Nicolas Heess, Thomas Degris, Daan Wierstra, Martin Riedmiller: Deterministic Policy Gradient Algorithms, International Conference on Machine Learning, JMLR (2014)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

辺ベクトルを用いた定式化による経路推薦手法の提案

Proposal of Route Recommending Method based on Formulation using Edge Vector

柴田 祐樹
Hiroki Shibata

高間 康史
Yasufumi Takama

首都大学東京大学院システムデザイン研究科
Graduate School of System Design, Tokyo Metropolitan University

In the domain of tourism navigation, tourist spots as well as route visiting them are important information to be presented to tourists. However, it is difficult to determine tourist spots to visit and the route all at once. This is a challenging problem. While an existing study has tried to solve such a tourism navigation problem by extending Traveling Salesman Problem (TSP) with introduction of weight for nodes (spots), its formulation became complicated. This paper proposes more simple formulation of the tourism navigation problem, which assigns all factors needed for a solution to only edges. The solution using Simulated Annealing method is also proposed.

1. はじめに

交通手段, 情報収集手段の発達に伴い, 個人が自ら観光地の情報を集めて旅行計画を立てることが容易になってきている. しかし, 個人の趣味嗜好というよりも知名度の高い場所が選択肢へ上がりやすい傾向があり, 当該の観光地が混雑する状況を招き, より個人の趣味に一致した場所や経路の選択機会を喪失している. このような状況が続けば, 観光地としての価値を追求するために, その土地本来の良さよりも宣伝性の良さを狙った街作りに重点が置かれる等の弊害も想定され, 訪問者, 現地民双方にとって損失があると考える. また, 居住地付近の散歩やテーマパーク訪問時においても, 好みのスポットを最短時間でより多く回れば個人の満足度が高くなるわけでは必ずしもなく, 途中通過する街並みや景観等も重要な要素である. 従って, 個人の嗜好や時間的制約などに基づく, 画一的ではない経路推薦手法が必要と考える.

目的地を巡回する問題については巡回セールスマン問題 (TSP: Traveling Salesman Problem) として多くの研究がなされている [Gutin 2006] [Feillet 2005] が, 事前に決定したスポット全てを通る経路を発見するため, 所要時間とのバランスを見ながら訪問スポットを選択するような調整を行いにくい. また, TSP を拡張した最適観光経路問題[松田 2004] が定式化されているが, 途中通過する街並みや, 道の景観等を考慮できず、また辺に基づく定式化である TSP にノードの重みを導入するため定式化を複雑にする要因になっている.

本稿では訪問する観光スポットおよびその経路を決定するために必要な情報をすべて辺の重みとして定式化する手法を提案する. 提案手法では, 経路を辺ベクトルにより表し, Boltzmann 分布に従う確率場として定式化する. これにより従来行われていたノードを用いた定式化に比べ, 簡素な表現が得られる. 確率場による定式化は各種統計, 機械学習手法を適用可能とする. 提案手法で用いる 焼きなまし (SA: Simulated Annealing) 法 [Kirkpartrick 1983], 局所最適化法の導出が Markov Chain Monte Carlo (MCMC) 法を適用する過程で自明に行えることを示し, また, 目的関数の形を工夫することで, 複雑な地図上の問題においても局所最適化法を適用できることを示す. 局所最適化法は極値の少ない目的関数を持つ問題の効率的解法として知られており, これを用いることは大規模な問題に対して有効であると考える. 評価実験では、これら提案手法が観光案内で想定される問題に対して有効に動作することを示す。

連絡先:柴田祐樹, 首都大学東京大学院システムデザイン研究科, 東京都日野市旭が丘 6-6, 04258598606, shibata-hiroki@ed.tmu.ac.jp

2. 関連研究

2.1 観光案内に関連する経路問題

与えられたノードをすべて巡回する最短経路を求める問題は TSP として広く知られている. TSP では各ノード間の負荷 (コスト) を定義し, すべてのノードを巡回する経路のみを解として求める. また, 近似解法の一つとして, 局所最適化法に属する 2-opt 法 (k-opt 法) が存在する. 2-opt 法を用いた最適化では局所最適解へ収束する可能性があるが, 焼きなまし法を併用することで大域的最適解へ近づくことが示されている [Kirkpartrick 1983]. しかし, 観光案内では, すべてのノードを巡回する経路が求められるわけではないので, TSP として定式化することはできない.

松田らは TSP を拡張し, ノードに価値を与え, 既定の時間内で価値の総和を最大化する問題を, 最適観光経路問題として定式化している [松田 2004]. しかし, この定式化は辺に対する重み (負荷) に基づく TSP に対し, ノードの価値 (重み) を導入したことが要因となり複雑となっている. また, ノード間の移動経路は実在の経路から切り離されて抽象化されており, 道に対する個人の好みなどを考慮することができない.

2.2 Boltzmann 分布と焼きなまし法

状態集合 $\mathcal{X}$ に属する多次元確率変数 $\mathbf{x} \in \mathcal{X}$ についての目的関数$\phi(\mathbf{x})$ を最小化する問題において, (1)式で与えられる Boltzmann 分布を考える.

$$p(\mathbf{x}) = \frac{\exp\left\{-\frac{1}{T}\phi(\mathbf{x})\right\}}{\sum_{\mathbf{x}\in\mathcal{X}} \exp\left\{-\frac{1}{T}\phi(\mathbf{x})\right\}} \tag{1}$$

$\phi(\mathbf{x})$ の最適解を与える$\mathbf{x}$ の集合を$\mathcal{X}_t$とする時, (1)式は温度 $T \to 0$ の極限で(5)式となることがわかる.

$$p(\mathbf{x}) = \begin{cases} \frac{1}{|\mathcal{X}_t|} & \text{where } \mathbf{x} \in \mathcal{X}_t \\ 0 & \text{where } \mathbf{x} \notin \mathcal{X}_t \end{cases} \tag{2}$$

(1)式の分布を解析的に求め，直接最適解を得ることは困難であり，一般に焼きなまし法を用いて近似解が求められる．焼きなまし法では(3)式を用いて表される条件付き確率を用いて，温度 T を徐々に低下させながら MCMC 法を適用し，$T \to 0$ での分布を近似する．ただし，$\mathbf{y} \in \mathcal{Y}$ は$\mathbf{x}$ の部分集合であり，$\mathcal{Y}$ は$\mathbf{y}$ が取りうる状態の集合を示す．

$$p(\mathbf{y}|\mathbf{x} \setminus \mathbf{y}) = \frac{\exp\left\{-\frac{1}{T}\phi(\mathbf{x})\right\}}{\sum_{\mathbf{y}\in\mathcal{Y}} \exp\left\{-\frac{1}{T}\phi(\mathbf{x})\right\}} \tag{3}$$

3. 提案手法

本稿で対象とする問題は，総移動時間及び目標総移動負荷の制約がある中で，ユーザの経路に対する満足度を最大化する経路を推薦することである．2.1 節で述べた最適観光経路問題と異なり，スポットの価値も含め解の発見に必要な情報をすべて辺に与えることで定式化する．

3.1 節では，経路を辺のベクトルとして表現し，経路に対する目的関数をエネルギー関数とする Boltzmann 分布から生成されるとモデル化する．これにより経路の拡張縮小，最適化を確率的に扱うことができる．3.2 節では MCMC 法により経路最適化法を導出する，3.3 節で非存在辺の概念を導入し，対応する目的関数を定式化することで複雑な地図上においても局所最適化法を適用可能とする．3.4 節で目標移動負荷，辺に対する好みをモデル化した目的関数を示す．

3.1 経路の表現と Boltzmann 分布による定式化

地図を構成するノード集合を $\mathcal{N}$ とする．各ノードを結ぶ辺から構成される，終始点を通る有効な経路を含むベクトルを，$\boldsymbol{e} = (e_i|e_i = (a_i, b_i), a_i \in \mathcal{N}, b_i \in \mathcal{N})$ と表す．辺の方向は始点 a_iから，終点 b_iへ向かうものとする．経路への辺の追加などに対応するため，辺ベクトルに経路に含まれない自己ループ辺を持たせておく．例えば，Fig. 1 (a) において，青い辺を要素として持つ辺ベクトル $\boldsymbol{e}$ は以下のようになる．

$$\boldsymbol{e} = ((1,2),(2,7),(3,3),(4,4),(5,5),(6,6),(7,8))$$

また，Fig. 1 (b) に示す例では以下となる．

$$\boldsymbol{e} = ((1,2),(2,3),(3,6),(4,4),(5,5),(6,7),(7,8))$$

辺ベクトルに経路および自己ループ辺が含まれるとすることにより，経路長が変化してもベクトル長を固定できる．これにより経路を含む辺ベクトルを確率場として取り扱うことができる．

$\boldsymbol{e}$の確率変数を$\mathbf{e}$とし，その分布$p(\mathbf{e})$を(4)式で与える．

$$p(\mathbf{e}) = \frac{\exp\left\{-\frac{1}{T}\phi(\mathbf{e})\right\}}{\sum_{\mathbf{t}\in\mathcal{E}} \exp\left\{-\frac{1}{T}\phi(\mathbf{t})\right\}} \tag{4}$$

ここで，$\mathcal{E}$ は$\mathbf{e}$ の取りうるすべての状態の集合とする．また，$\phi(\mathbf{e})$ は経路 $\mathbf{e}$ に対する目的関数であり，$\phi(\mathbf{e})$の値が小さいほど$p(\mathbf{e})$の値が高まり，そのような経路が選択される確率が高くなることがわかる．$\phi(\mathbf{e})$ についての最適解集合を $\mathcal{E}_\mathrm{t}$ とする時，(1)式は温度 $T \to 0$ の極限で(5)式となり，$p(\mathbf{e})$ に従う辺ベクトル$\mathbf{e}$は最適経路を与えることがわかる．

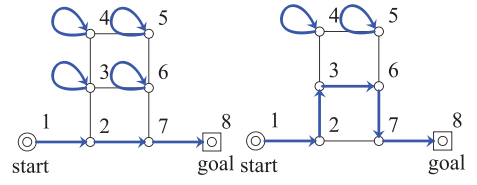


Fig. 1 An example of self loop edges and route extention.

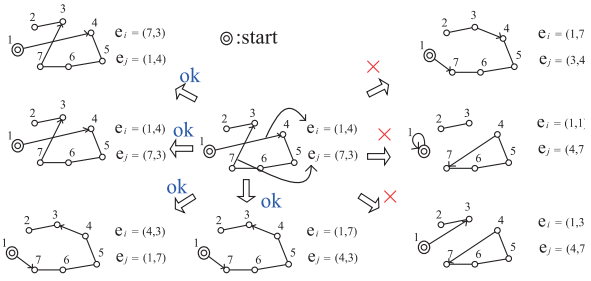


Fig. 2 The edge's status of $\mathcal{E}_{ij}^{S_2}$ to swap 2 edges.

$$\lim_{T\to 0} p(\mathbf{e}) = \begin{cases} \frac{1}{|\mathcal{E}_\mathrm{t}|} & \text{where} \quad \mathbf{e} \in \mathcal{E}_\mathrm{t} \\ 0 & \text{where} \quad \mathbf{e} \notin \mathcal{E}_\mathrm{t} \end{cases} \tag{5}$$

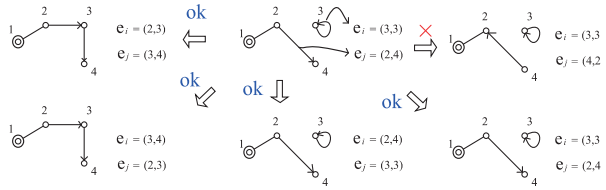
3.2 Markov Chain Monte Carlo 法と局所最適化

(4)式で定義された分布を MCMC 法により求めることは，$\phi(\mathbf{e})$ の最適解を与える $\mathbf{e}$ を k-opt 法により求めることに等しい．本稿では 2 辺について最適化を繰り返す 2-opt 法を用いる．最適化対象の 2 辺を確率変数 $\mathbf{e}_i, \mathbf{e}_j \in \mathbf{e}$ で表し，これらを除いた辺ベクトルの部分空間を $\mathbf{e} \setminus \{\mathbf{e}_i, \mathbf{e}_j\}$ とすると，$\mathbf{e}_i, \mathbf{e}_j$ の条件付き分布は(6)式となる．

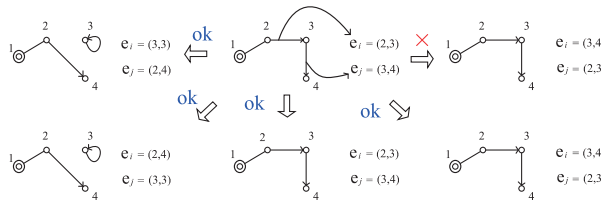
$$p(\mathbf{e}_i, \mathbf{e}_j|\mathbf{e} \setminus \{\mathbf{e}_i, \mathbf{e}_j\}) = \frac{\exp\left\{-\frac{1}{T}\phi(\mathbf{e})\right\}}{\sum_{(\mathbf{e}_i,\mathbf{e}_j)\in\mathcal{E}_{ij}} \exp\left\{-\frac{1}{T}\phi(\mathbf{e})\right\}} \tag{6}$$

ここで，$\mathbf{e}_i, \mathbf{e}_j$ の状態は互いに独立ではなく経路が途切れたり，逆行したりしないようなもののみが許され，そのような状態の組を$(\mathbf{e}_i, \mathbf{e}_j)$，その集合を $\mathcal{E}_{ij}$ とする．2 辺が隣接せず，ともに自己ループ辺でない場合，それらの接続先を入れ替えるための状態組集合 $\mathcal{E}_{ij}^{(S_2)}$ として，Fig. 2 に示す例では，“ok” と書かれた 4 通りのみが含まれる．k 番目の辺 $\mathbf{e}_k$ の要素を $\mathbf{e}_k = (a_k, b_k)$ のように表したとき，$\mathcal{E}_{ij}^{(S_2)}$ は(7)式で与えられる．

$$\mathcal{E}_{ij}^{(S_2)} = \begin{Bmatrix} \big((a_i, b_i), (a_j, b_j)\big), \big((a_j, b_j), (a_i, b_i)\big), \\ \big((b_i, b_j), (a_i, a_j)\big), \big((a_i, a_j), (b_i, b_j)\big) \end{Bmatrix} \tag{7}$$



(a) Adding



(b) Removing

Fig. 3 The edges' status of $\mathcal{E}_{ij}^{(A_2)}$ to add or remove an edge from the route.

また, 経路を拡張縮小するための状態組集合 $\mathcal{E}_{ij}^{(A_2)}$ については, 1 辺が経路に含まれ, 1 辺が自己ループ辺の場合に, 自己ループ辺を追加することによる経路拡張 (Fig. 3 (a)), 隣接する経路上の 2 辺のうち 1 つを自己ループ辺へ変化させ経路から取り除く経路縮小 (Fig. 3 (b)) を考える. Fig. 3 より, 経路拡張, 縮小がともに同じ状態組集合となることがわかり, これらをまとめて (8) 式で与えることができる.

$$\mathcal{E}_{ij}^{(A_2)} = \left\{ \begin{matrix} \big((a_i,b_i),(a_j,b_j)\big),\big((a_j,b_j),(a_i,b_i)\big), \\ \big((a_j,b_i),(a_i,b_j)\big),\big((a_i,b_j),(a_j,b_i)\big) \end{matrix} \right\} \tag{8}$$

3.3 非存在辺の導入

2 辺の操作だけで一般の経路生成に対応するためには, 経路拡張縮小途中において, 非存在辺が経路に含まれることを一時的に許可する必要がある. Fig. 4 に示す例では (b) の中で赤により示される非存在辺を一時的に許可することで, (a) から (c)の状態まで 2 辺の操作だけで経路を拡張可能となる. もし (b) を認めず, (a) から (c) へ直接遷移させる場合, 3 辺についての状態を考えなければならず、より複雑な操作が必要となる. $\mathbf{e}_i$ が非存在辺の時は罰則$f_p(\mathbf{e}_i)$ が, 存在辺の時は負荷 $f_c(\mathbf{e}_i)$ がそれぞれ与えられるとして, 目的関数$\phi(\mathbf{e})$ を (9) 式で与えることを考える.

$$\phi(\mathbf{e}) = \sum_{\mathbf{e}_i \in \mathbf{e}} f_c(\mathbf{e}_i) + \sum_{\mathbf{e}_i \in \mathbf{e}} f_p(\mathbf{e}_i) \tag{9}$$

定数$C_{pb} > 1, C_{pc} > 0$ を用いて, $\mathbf{e}_i$が非存在辺の場合に $f_p(\mathbf{e}_i)$ を (10) 式で与えると, $T \to 0$ となるとき, 状態組集合$\mathcal{E}_{ij}^{(S_2)}$, $\mathcal{E}_{ij}^{(A_2)}$ による状態の変更は必ず非存在辺を存在辺へ置き換えるように働く.

$$f_p(\mathbf{e}_i) = C_{pb}\left(\sum_{s_j \in \boldsymbol{s}} f_c(s_j)\right) + C_{pc} \tag{10}$$

ここで, $\boldsymbol{s}$ は $\mathbf{e}_i$ の始点と終点を結び, (10)式を最小化する実在最短経路とする. Fig. 5 (a)において, すべての辺の負荷が同じ場合は $\mathbf{e}_i = (2,7)$ に対する $\boldsymbol{s}$ は以下となる.

$$\boldsymbol{s} = \big((2,9),(9,10),(10,7)\big)$$

3.4 目標移動負荷と好みの反映

ユーザの辺に対する好みを$f_d(\mathbf{e}_i)$ で与える. 既存研究 [松田 2004] ではノードに対してスポットを表現する値が付加されていたが, 本稿では経路負荷を辺に対する関数$f_c(\mathbf{e}_i)$として与えており, これとの一貫性を取るために辺に対してスポットを割り当てる. 同一ノードを複製した 2 ノード間に距離が 0 の辺を考えることで, ノードに対して割り当てたものと等価な問題を考えることができる.目標移動負荷値$\mathrm{C_c}$も考慮した目的関数を(11)式で与える.

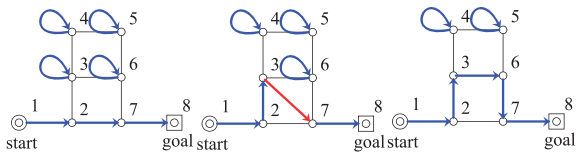


Fig. 4 An example of route extention using non-existing edges.

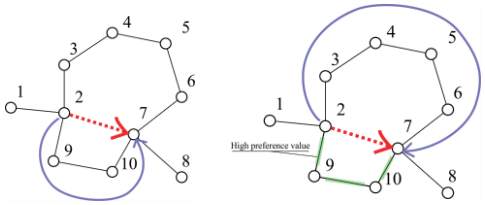


Fig. 5 An example of existing shortest route. The Black edges denote existing while red is non existings. The green one have high $f_d(\mathbf{e}_t)$ value.

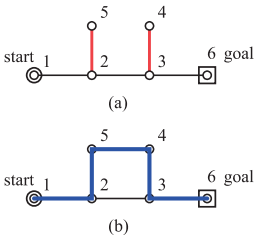


Fig. 6 An example where we have to add $f_d(s_j)$ to $f_p(e)$.

$$\phi(\mathbf{e}) = \frac{\beta}{2\sigma^2}\{F_c(\mathbf{e})\}^2 + (1-\beta)\left\{F_c(\mathbf{e}) - \frac{\sigma^2}{2}\right\} - \sum_{\mathbf{e}_i \in \mathbf{e}} f_d(\mathbf{e}_i) + \sum_{\mathbf{e}_i \in \mathbf{e}} f_p(\mathbf{e}_i) \tag{11}$$

ただし, 条件変数 β, 総移動負荷$F_c(\mathbf{e})$は(12)式で与えられる.

$$F_c(\mathbf{e}) = \left| C_c - \sum_{\mathbf{e}_i \in \mathbf{e}} f_c(\mathbf{e}_i) \right|, \quad \beta = \begin{cases} 1 & where\ \sigma^2 > F_c(\mathbf{e}) \\ 0 & where\ \sigma^2 \le F_c(\mathbf{e}) \end{cases} \tag{12}$$

なお, (11)式は(12)式の条件のもと, $\sigma^2 \to 0$ の極限で(13)式となる.

$$\lim_{\sigma^2 \to 0} \phi(\mathbf{e}) = F_c(\mathbf{e}) - \sum_{\mathbf{e}_i \in \mathbf{e}} f_d(\mathbf{e}_i) + \sum_{\mathbf{e}_i \in \mathbf{e}} f_p(\mathbf{e}_i) \tag{13}$$

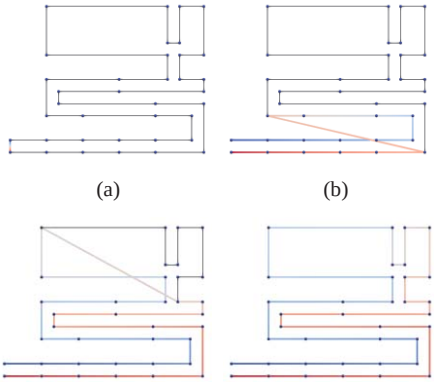
(12)式は総移動負荷$F_c(\mathbf{e})$に対して最小値を持つ目的関数となっており, また, 移動負荷の増加に見合う $f_d(\mathbf{e}_i)$の値が得られるスポットに対し経路の拡張を許可する. σ^2は拡張規模の許容範囲を表現する. また, $f_p(\mathbf{e}_i)$の定義式を(10)式から(14)式に変更する.

$$f_p(\mathbf{e}_i) = C_{pb}\left(\sum_{s_j \in \mathbf{s}} \{f_c(s_j) + f_d(s_j)\}\right) + C_{pc} \tag{14}$$

$\boldsymbol{s}$ は $\mathbf{e}_i$ の始点と終点を結び, (14)式を最小化する実在経路とする. 例えば, Fig. 5 (b)において, 黒と緑の辺はどちらも実在辺であるとし, 黒の辺で$f_c(\mathbf{e}_i) = 1, f_d(\mathbf{e}_i) = 0$ とし, 緑色の辺では $f_c(\mathrm{e}_i) = 1, f_d(\mathrm{e}_i) = 1$ とする. この時, $\mathbf{e}_i = (2,7)$ に対し, $\boldsymbol{s}$ は (10)式の場合と異なり, 以下のように与えられる.

$$\boldsymbol{s} = \big((2,3),(3,4),(4,5),(5,6),(6,7)\big)$$

(14)式は 非存在辺を通ってでも, 好みの辺を通った方が目的関数の値を小さくできるような状況を避けるために必要な定義である. そのような状況が起こりえる例を Fig. 6 に示す. (a)に示す赤い辺において$f_d(\mathbf{e}_i)$が十分に高い値を持てば, 非存在辺



(a) (b) (c) (d)

Fig. 7 The result of edge adding and removing. $T = 0$

(5,4) を通る(b)に示す経路が最適なものとして選ばれる状況が, (11)式を用いている場合にあり得ることがわかる.

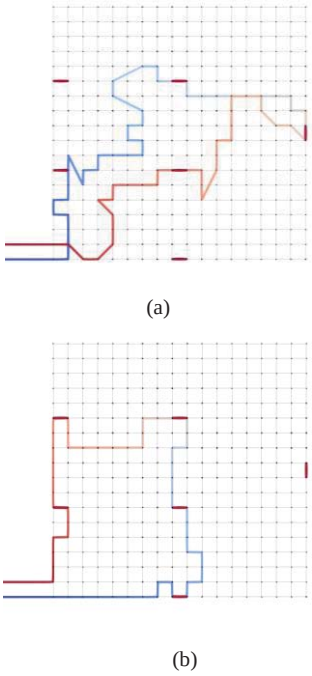
4. 評価実験

Fig. 7 に辺の追加と除外の仕組みが機能している様子を示す. 実在辺は黒で表示されており, これら以外のノード対を結ぶ辺はすべて非存在辺である. 開始点と終止点が設定されており, 開始点と終止点がつながる経路のうち目的関数(9)式が最小となる経路を求める. この問題の最適解は, 37 ノードすべてを実在辺のみで通る経路である. (a)に初期状態を示しており, 初期経路として開始開始点と終止点を直接結ぶ非存在辺からなる経路を与えている. $f_p(e)$ を定義する(10)式のパラメータとして, $C_{pb} = 1.1, C_{pc} = 0.1$ を用い, $T = 0$ とした. Fig. 7 の(b), (c), (d) はそれぞれ 40, 200, 400 ステップにおける経路である. 開始点に近い辺を赤, 終止点に近い点を青で, グラデーションを用いて可視化している. 局所最適化を繰り返すうちに非存在辺と実在辺の追加と除外を繰り返し, 最終的に実在辺のみが残っていることがわかる.

Fig. 8 に(11)式の目的関数で表される目標移動負荷と辺に対するユーザの好みを考慮した問題を解いた結果を示す. ここでは問題を簡潔にするため, 18 行 18 列の等間隔におかれたノードからなるマス目上の地図を想定した. ノード数は終始点を含め 326 である. $\sigma = 5, C_c = 60$ とし, 赤く表示されている部分は $f_d(e) = 2, f_c(e) = 1$, そのほかの薄い灰色で描画された辺は $f_d(e) = 0, f_c(e) = 1$ としている. これら以外のノード間をつなぐ辺はすべて非存在辺である. (a)は計算開始直後の状態であり, 温度T が高いことにより発見的な経路探索を行っていて, 非存在辺も含んでいる. 斜めの辺はすべて非存在辺である. (b)は計算終了時の状態であり, 非存在辺はなくなっており, 負荷の目標値として妥当な経路でスポットを巡回する経路を生成していることがわかる.

5. 結論

観光経路推薦に要求される, 目標移動負荷および時間に関する制約の中で, 訪問すべきスポットとその経路の両方を求める問題に対して, 辺のベクトルに対する確率場を Boltzmann 分布を用いてモデル化し, 局所最適化法により経路を生成する方法を示した. 提案手法は, 辺に対するユーザの好みに応じた経路生成が可能なこと, ノードであらわされるスポットに対しても仮想的な辺を配置することで経路推薦が行えることを示した. 局所最適化法により効率的に解の探索が行える提案手法は, スケーラビリティに優れるため, 広域を対象とした観光案内や, 経路上のユーザの好みまで反映させる大規模な問題にも適用可能と考



(a) (b)

Fig. 8 The result of reducted STSP. The red edges have the weight of $f_d(e) = 2, f_c(e) = 1$ while graies have $f_d(e) = 2, f_c(e) = 1$ of it.

える. 今後の展望としては棄却サンプリング [Bishop 2006] を導入し, 近傍辺同士の条件付き分布の評価を重点的に行い, 遠方への辺検索に要する無駄な探索を抑制することを検討している. また, 現在 2 辺の組み合わせによる最適化だけを考慮しているが, より多くの組み合わせを用いた場合についても検証する. さらに, スポットの価値が時間依存性を持つ場合にも対応できるようにする. 最適化手法だけではなく, 実際の経路推薦に適用された場合のユーザの満足度等, ユーザとのインタラクティブ性を考慮し, 経路推薦手法としての有効性についても評価する予定である.

参考文献

[Gutin 2006] G. Gutin, A. Punnen.: “The traveling salesan problem and its variations,” Springer Science & Business Media, 2006.

[Feillet 2005] D. Feillet, P. Dejax, M. Gendreau.: “Traveling salesman problems with profits, Transportation science,” Vol. 39, No. 2: pp. 188-205, 2005.

[Helsgaun 2009] K. Helsgaun.: “General k-opt submoves for the Lin–Kernighan TSP heuristic,” Mathematical Programming Computation, Vol. 1, No. 2-3: pp. 119-163, 2009.

[松田 2004] 松田善臣, 名嘉村 盛和, 姜 東植, 宮城 隼夫: 最適観光経路問題とその解法, 電気学会論文誌 C (電子・情報・システム部門誌), Vol. 124, No. 7: pp. 1507-1514, 2004.

[Kirkpartrick 1983] S. Kirkpartrick, C. D. Gelatte, Jr., M. P Vecchi.: “Optimization by simulated annealing, Science,” Vol. 220, No. 4598: pp. 671-680, 1983.

[Bishop 2006] C. M. Bishop, (訳) 元田浩, 栗田多喜夫, 樋口智之, 松本裕治, 村田昇.: “Pattern Recognition and Machine Learning, Springer,” 2006.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

深層学習を用いたユーザ離脱予測

Churn Prediction using Deep Learning

宮崎 邦洋 *1 Kunihiro Miyazaki
村山 菜月 *2 Natsuki Murayama
山本 裕樹 *1 Yuki Yamamoto
牛山 史朗 *3 Fumiaki Ushiyama
大澤 昇平 *1 Shohei Ohsawa
松尾 豊 *1 Yutaka Matsuo

*1東京大学大学院工学系研究科 School of Engineering, The University of Tokyo
*2東京大学教養学部 Dept. of Arts and Science, The University of Tokyo
*3ウェルスナビ株式会社 WealthNavi Inc.

The number of companies using subscription business model is increasing, and churn prediction is getting a more important task. In existing research, various type of machine learning models have already been used, but churn prediction has to be trained by combining various data such as time series data and non-time series data, which has not been fully studied. On the other hand, the technique of deep learning is still being developed, and one of its characteristics is that it can learn various data and models from end-to-end. In this research, we propose a churn prediction model with deep learning using data of WealthNavi inc. which manages the service of Robo-adviser. Specifically, we propose a method to learn time series data and non-time series data with one model. In the experiment, the effectiveness of this method was demonstrated by obtaining the result exceeding the accuracy of the classifier of the existing research.

1. はじめに

ユーザ離脱予測はビジネスにおいて重要な課題である．企業にとってユーザの新規獲得コストは大きく，マーケティング領域の研究においては新規顧客に製品を販売するコストは既存顧客に販売するコストの 5 倍程度かかることが明らかになっている [Verbeke 12]．そのため新規顧客の獲得と同様以上のコストを既存顧客のリテンションに割くことは企業にとって経済合理性があり，より効果的に既存顧客を維持するためにも，近い将来での離脱が見込まれるユーザを予測することは重要である．特に昨今では Web 上の音楽や本などのコンテンツ分野においてサブスクリプション方式（製品を購入せずに，ある期間における製品の使用料をユーザが支払う形式）のサービス形態が台頭している．そのようなサブスクリプション方式においては，新規ユーザの獲得とともに既存ユーザにどれだけ継続的に利用されるかがサービスの成否を左右する．ユーザの定着は企業のビジネスを安定させ，企業がサービスの改善や使用料引き下げという形でユーザに還元することでさらにユーザを惹きつけるという好循環が生まれる可能性も見込める．Web サービスを中心にユーザの行動や状態のデータが蓄積されるなど分析の環境も整いつつあり，今後ユーザの離脱予測は企業の重点課題としてより取り上げられていくと思われる．

ユーザ離脱予測は主に通信の分野で研究されている技術であり，その基本的な手法は，ユーザの属性情報や行動データなどの特徴量を機械学習のモデルに読み込ませ，将来の一定期間における離脱をユーザ毎に予測するものである．既存研究では Rondom Forest や SVM などの手法が使われているが，深層学習を用いた研究は多く行われていない．本研究においては，ユーザの離脱にあたり，深層学習における以下 2 点の特徴を活かしたモデルを作成する．

- 再帰型のニューラルネットワークを使用することで，過去の情報を保持したまま時系列の学習ができる点
- 様々なデータを一つのモデルで End-to-end のアンサンブル学習を行わせることにより，効率的な学習ができる点

実験では，サブスクリプション方式である資産運用の Web サービスにおいて実験を行った．具体的にはユーザの非時系列の情報と時系列の情報を組み合わせたデータを使用し，ランダムフォレストや多層パーセプトロンなど時系列性を考慮しないモデルに対し，再帰型ニューラルネットワークを組み合わせた提案モデルの予測精度を評価した．検証の結果，

- 時系列性を持つと思われるデータは時系列モデルを通して学習をさせた場合に予測精度が高いことがわかった
- 様々なデータをインプットとする上で，深層学習のようなモデル構造の自由度が高い手法の有用性が示された

2. 関連研究

ユーザ離脱の研究は多く行われている．主な手法としては，(1) ユーザ行動，(2) 顧客のサービスへの態度，(3) 顧客基本情報，(4) 外部要因の 4 カテゴリの特徴量を素性とし，それらを機械学習モデルに読み込ませて予測しているケースが多い [Kamalraj 13]．使用される機械学習は様々であるが [Ali 14]，深層学習を用いたユーザ離脱予測は多く行われていない．特に，時系列モデルやアンサンブル学習を使用している研究はあるが，それらを組み合わせて予測を行う研究は筆者の知る限り未だかつてない．

3. 提案手法

3.1 Long Short-Term Memory

本研究では時系列データを扱うモデルに Long Short-Term Memory（LSTM）を採用している．LSTM は再帰型ニューラルネットワークの一種であり，学習において過去の時系列相関を取得することが期待される．再帰型ニューラルネットワーク

連絡先: 宮崎邦洋，東京大学工学系研究科技術経営戦略学専攻，miyazaki@weblab.t.u-tokyo.ac.jp

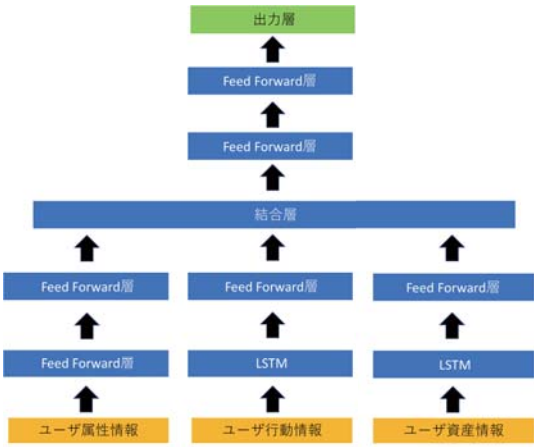


図 1: 提案手法の概要図

は時系列情報を記憶しながら学習できるニューラルネットワークである．再帰的な過程は以下のように表される．

$$z^t = f(W_{in}X^t + W_{z^{t-1}}) \tag{1}$$

ここで，f は活性化関数，W_{in} は入力層から隠れ層への重み行列，W は隠れ層の重み行列，X^t は時刻 t における入力データ，z^t は時刻 t における隠れ層の出力を示す．特に今回の手法においては，過去のユーザのアクセスパターンや資産価格の変動が，ユーザの離脱の意思決定にどれだけ影響を与えるかを捉えることができる．LSTM は再帰型ニューラルネットワークの拡張版であり，より長期的な時間依存を扱える．

3.2 提案モデル

今回提案するモデルでは，複数のニューラルネットワークを組み合わせたモデルを提案している．深層学習の特徴として，ネットワーク構造の自由度が高く，扱うデータに合わせてモデルを改変し易いことがあげられる．特に今回のような時系列データと非時系列データを同時に扱う場合等で利便性が高い．また複数のデータとモデルを一つのネットワークに組み込むことで，人手を介さずに End-to-end でアンサンブル学習をすることも特徴としてあげられる．アンサンブル学習では通常低層の出力をモデルの作成者が人手で設計する必要があり，その場合作成者のバイアスがかかってしまう可能性と設計自体に手間がかかるという問題があるが，複数の入力から出力まで一気通貫して学習できる深層学習はその問題を解決できる．提案モデルの概要図は図 1 である．今回は入力を (1) ユーザの属性情報，(2) ユーザの日次のアクセス回数，(3) ユーザの日次のポートフォリオ資産価格変動とした．それらをまずローカルなネットワークに情報として与え，それぞれの出力を途中で結合し，一つのアウトプット層につなげている．提案手法ではアクセス情報と資産情報は第一層を LSTM とした．

4. 実験

4.1 対象データ

今回，ロボアドバイザーを運営するウェルスナビ株式会社のデータを用いて研究を行った．ロボアドバイザーとは，ユーザの長期にわたる安定的な資産運用をサポートする Web サービスの通称であるが，大きく 2 つのタイプに分けられる．1 つはユーザのリスク許容度などを診断してポートフォリオ（資産の組み合わせ）を提案し，さらには具体的な金融商品の購入やその後のメンテナンスなども全て自動で行うもので「投資一任型」と呼ばれ，もう 1 つはポートフォリオの提案までは行うものの金融商品の購入からはユーザが自ら行う必要があるもので「アドバイス型」と呼ばれる．ウェルスナビ株式会社が提供するのは「投資一任型」のサービスであり，ユーザは自身のリスク許容度などを診断した上で入金すれば，ポートフォリオの構築からその後のリバランスなどの適切なメンテナンスまで自動で行われる．毎月一定額を自動的に投資にまわす自動積立機能もあり，ユーザは必要に応じて運用状況を確認する以外はほとんど手間をかけることなく，長期にわたる資産運用を行うことができる．ユーザが長期間利用を続けることでメリットを最大限に享受できることを狙ったサービス設計となっており，短期での離脱はユーザ自身の利益を損なうケースも少なくないと考えられる．

4.2 実験概要

今回使用したデータは 2017 年 8 月から 12 月のものである．実験では，過去 30 日のデータを用い，将来の 2 週間における離脱を予測する分類問題とした．検証したユーザにおいて，実際に 2 週間で離脱するユーザは約 0.5%である．偏ったデータに対応するため，学習時点では正例と負例が同じ数量になるようアンダーサンプリングによりバランスをさせた．また，学習データ自体を増やすため，過去のデータを 2 週間毎 10 ステップのデータを取得し，それらをつなぎ合わせて学習データとした．提案手法と比較する手法としては，(1) 既存手法で頻繁に使用されている Random Forest，(2) 時系列性を考慮しない深層学習の手法である中間層が 4 層の Multi Layer Perceptron（MLP）とした．

4.3 結果

実験の結果は 1 のようになっている．

表 1: 各手法の比較

手法	Recall	Precision	F 値
Random Forest	1.000	0.090	0.165
MLP	0.994	0.099	0.179
提案手法	0.994	0.104	**0.188**

提案手法が他 2 つの手法を精度で上回っていることがわかる．本研究ではもともとのデータの特性から，ほとんど Recall が 1 に近い精度となっている．離脱が見込まれないユーザに対してメールを打つなどの離脱防止策を施すことはユーザを不必要に煩わせ逆効果になることもありうるので，Recall Rate が高いことは実務上望ましいことである．その中で如何に False Positive を少なくするかが F 値にそのまま効いてきていることがわかるが，提案手法が最も Precision を高く学習できており，的中率が高いことを示している．

5. 結論と展望

今回の結果から，アクセス情報やポートフォリオ情報を時系列モデルで学習させた方が良いことがわかった．また，それら様々なデータをインプットとする上で，深層学習のようなモデル構造の自由度が高い手法の有用性が示された．

今後としては，この度作成したユーザ離脱モデルを基に，より詳細にユーザの行動をモデリングする手法の研究を進めていく．一つは，今回アクセス回数をユーザの行動情報として用いているが，より End-to-end に学習が可能にするため，ページ遷移を含めたアクセス情報を入力として精度向上を目指す．

また，今回は事前実験においてポートフォリオ情報が精度向上をもたらすことが判明しており，ポートフォリオの変動とユーザ行動の関係性の分析を進めることで，よりユーザにとって利便性の高いサービスとなる助けとなるような研究を目指す．

6. 謝辞

本研究は，ウェルスナビ株式会社の支援を受けて行われた，

参考文献

[Ali 14] Ali, Ö. G. and Arıtürk, U.: Dynamic churn prediction framework with more effective use of rare event data: The case of private banking, *Expert Systems with Applications*, Vol. 41, No. 17, pp. 7889–7903 (2014)

[Kamalraj 13] Kamalraj, N. and Malathi, A.: A survey on churn prediction techniques in communication sector, *International Journal of Computer Applications*, Vol. 64, No. 5 (2013)

[Verbeke 12] Verbeke, W., Dejaeger, K., Martens, D., Hur, J., and Baesens, B.: New insights into churn prediction in the telecommunication sector: A profit driven data mining approach, *European Journal of Operational Research*, Vol. 218, No. 1, pp. 211–229 (2012)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

M&A後の業績変化を考慮した買収候補推薦のための内容ベースニューラル協調フィルタリング法

Targets Recommendation Considering After M&A Performance by Content based Neural Collaborative Filtering

大知 正直 *1 Masanao Ochi　山野 泰子 *2 Yasuko Yamano　浅谷 公威 *1 Kimitaka Asatani　北内 啓 *3 Akira Kitauchi　太田 智之 *3 Tomoyuki Ota　坂田 一郎 *1 *2 Ichiro Sakata

*1東京大学技術経営戦略学専攻
Graduate School of Technology Management for Innovation, The University of Tokyo

*2東京大学政策ビジョンセンター
Policy Alternatives Research Institute, The University of Tokyo

*3株式会社ユーザベース
*3UZABASE, Inc.

In this paper, we tackled the recommendation of the M&A candidate considering the change in business performance after M&A. By incorporating the multitask learning framework into the Neural Collaborative Filtering method which is one of recommendation method using Deep Learning, we aimed to propose recommendation method considering the post-conversion change. Experimental results show the similar accuracy as the simple logistic regression method. By using this method, it will be possible to not only recommend M&A targets but also to show to acquirers what kind of benefits they can obtain by acquiring.

1. はじめに

ある商品を顧客に推薦し，購買してもらった後で，顧客がその商品に対し満足したかどうかは重要である．特に購買することで，どのような便益を顧客が得ることができるかを提示することは顧客の商品選択の意思決定をこれまでより効率的にすることができるだろう．本稿では，このように顧客の商品購買のような一つの目的を達成したあとに，顧客が購買した商品によって便益を得たのかどうかを考慮することを「ポスト・コンバージョン」と呼ぶことにする．そしてこの「ポスト・コンバージョン」を考慮した推薦を行うことで，顧客に得られる便益を明示した形での商品推薦を行うことが期待できる．

本稿では，従来の協調フィルタリングを利用した推薦手法に深層学習を適用したニューラル協調フィルタリング法にマルチタスクラーニングを適用することで「ポスト・コンバージョン」を考慮した商品推薦手法を提案する．

また，今回対象とする事象を M&A としている．M&A の意味する事象は様々に考えられるが，本稿では比較的商品の購買のようなものに近い，企業の株式の５０％超の株式を取得する行為を対象とする．企業を商品として考えた場合，決して同一の商品が無い高額で希少な商品に分類できる．不動産がこうした商品の代表だが，このような場合は，商品を商品の持つ様々な属性によって表現し，推薦に用いる方法が取られる [7].

以上のことから，本稿では,「ポスト・コンバージョン」時代の情報推薦の試みとして，M&A 後の業績変化を考慮した買収候補推薦のための内容ベースニューラル協調フィルタリング法を提案する．本稿の貢献を以下にあげる．

- M&A による買収候補の推薦タスクの提案と実験
- M&A 後の変化を考慮した推薦フレームワークの提案.

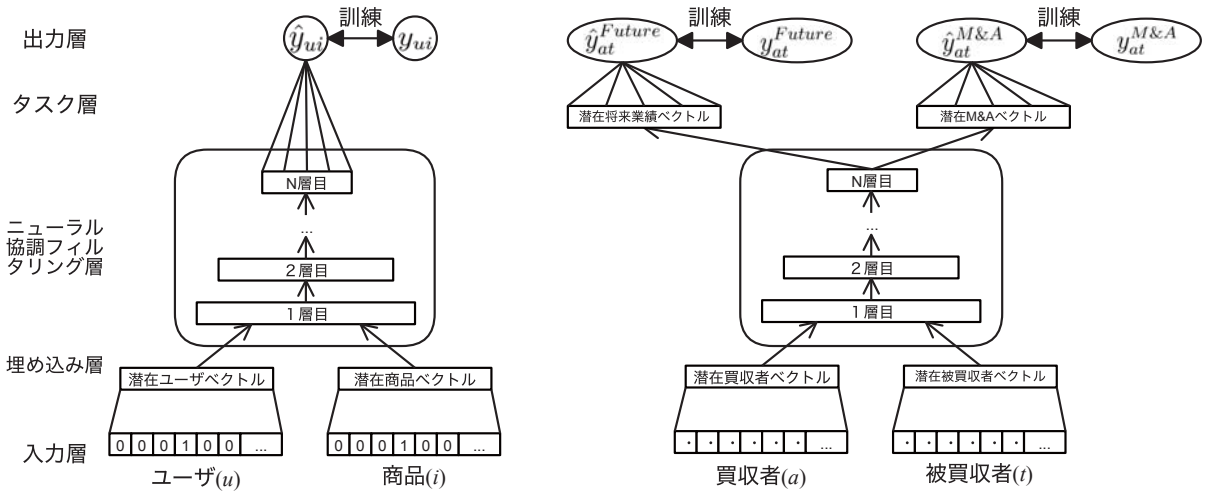
本稿は以下のように構成される．まず，2. 章で関連する研究について述べ，本研究の位置づけを明らかにする．次に 3. 章で本稿で提案する手法について説明する．この手法の評価に用いるデータ，実験の設定について 4. 章で述べ，その実験結果と考察を 5. 章で議論する．最後に結論と今後の展望について述べる．こ

連絡先: 大知 正直，東京大学技術経営戦略学専攻，〒 113-8656 東京都文京区本郷７－３－１，masanao.oochi@gmail.com

2. 関連研究

1990 年代に始まった協調フィルタリングを用いた商品推薦の研究 [2] は，深層学習を用いたものへと発展している [3]．これによって，ユーザと商品の購買の関係性をこれまでの比較的シンプルな類似度を表す関数からより複雑なものをブラックボックス的に演算することが可能になった．また，マルチタスクラーニング (MTL) は，関連する２つのタスクを同時に解決するためにそれぞれのタスクで学習した分散表現を活用する学習方法を指す [1]．そして，協調フィルタリングは，ユーザ・商品間の購買の行列を元に商品の購買履歴の類似しているユーザで対象ユーザが未購買の商品を推薦するものであったが，ユーザをユーザが記述したレビュー文から抽出した嗜好を表す表現で構成した行列でも同等の推薦精度を達成できることが報告されている [4]．本研究では，このような技術を複合し内容ベースニューラル協調フィルタリング法を提案する．

次に，本研究では M&A として買収すべき対象を推薦することを最終的なゴールとしている．しかし，実際の買収者は買収することを目的としているのではなく，買収することによって自社の事業範囲や事業規模を拡大することを目的としているだろう．このようにある対象に目標を達成させた後に，その後実際に対象にとって有益であったかどうかを重視することを本研究では「ポスト・コンバージョン」と呼ぶこととする．ウェブ上の広告における推薦では，表示された広告をクリックした後に実際に購買に至るかどうかを分析するポスト・クリックの分析が行われている [6]．しかし，コンバージョン後に購入した商品がユーザにとって有益であったかということについて分析する研究はほとんど行われていない．



(a) ニューラル協調フィルタリング法　　(b) 提案手法

図 1: 従来手法と提案手法の違いを示した概略図.

3. 提案手法

買収者 (a) となる可能性のある事業者数を M，被買収者 (t) となる可能性のある事業者数を N とする．このとき，買収者 (a) と被買収者 (t) の間に M&A があったかどうかの関係を行列 $\mathbf{Y}^{M\&A} \in \mathbb{R}^{M\times N}$ によって表すことができる．そして，M&A 後，どのような変化があったかをテンソル $\mathbf{Y}^{Future} \in \mathbb{R}^{M\times N\times K}$ によって表すことができる．ここで，K は M&A 後の将来指標 $\mathbf{H}:\{h_1,...,h_K\}$ の多様性を表している．例えばこれは，M&A が成功したかどうかを表しており，田村によると売上高上昇，業界内での寡占度の上昇，コスト削減，新規事業分野への進出などがあげられる [8]．以上のことから買収者，被買収者それぞれの間の関係性を以下のように定める．

$$y_{at}^{M\&A} = \begin{cases} 1 : \text{M\&A をした場合} \\ 0 : \text{それ以外} \end{cases} \tag{1}$$

$$y_{atk}^{Future} = \begin{cases} 1 : \text{将来指標 } h_k \text{において正の変化をした場合} \\ 0 : \text{それ以外} \end{cases} \tag{2}$$

次に予測モデルについて説明する．買収者 (a) の入力を $\mathbf{v}_a \in \mathbb{R}^{D_a}$，被買収者 (t) の入力を $\mathbf{v}_a \in \mathbb{R}^{D_t}$ と表す．D_a, D_t はそれぞれ買収者の入力次元数，被買収者の入力次元数を表している．本稿では，通常の協調フィルタリングでは商品やユーザの購買を表すような疎ベクトルではなく，内容ベースの入力を想定している．例えば M&A 以前の売上高や現金及び同等物の量がそれに当たる．学習すべきパラメータのうち，全てのタスクにおいて共通のものを Θ^{Common}，M&A 予測に必要なパラメータのみを $\Theta^{M\&A}$，個別の将来指標 h_k の予測に必要なパラメータのみを Θ^{h_k} とする．以上のことから予測モデルを以下のように定式化する．

$$\hat{y}_{at}^{M\&A} = f(\mathbf{v}_a, \mathbf{v}_t | \Theta^{Common}, \Theta^{M\&A}) \tag{3}$$

$$\hat{y}_{atk}^{Future} = f(\mathbf{v}_a, \mathbf{v}_t | \Theta^{Common}, \Theta^{h_k}) \tag{4}$$

最後に最適化に用いる目的関数について定式化を行う．本稿では，マルチタスク学習を用いるため以下のように損失を算出する．

$$\begin{aligned} L = & -\sum_{(a,t\in\mathcal{Y}\cup\mathcal{Y}^-)} \Big(\\ & \textstyle\sum_{h_k}^{K} y_{atk}^{Future} \log \hat{y}_{atk}^{Future} + (1-y_{atk}^{Future}) \log(1-\hat{y}_{atk}^{Future}) \\ & + y_{at}^{M\&A} \log \hat{y}_{at}^{M\&A} + (1-y_{at}^{M\&A}) \log(1-\hat{y}_{at}^{M\&A}) \Big) \end{aligned} \tag{5}$$

以上定式化した提案モデルを図 1(b) に概略図として示す．提案手法では，ニューラル協調フィルタリング層部分は M&A 予測でも将来指標予測においても共通で学習する．一方でそれ以降は個別のタスク用に学習を行い最適化を進める．

4. 実験

使用したデータ，実験の条件について説明を行う．

4.1 使用するデータ

株式会社ユーザベース [*1] が提供する企業情報・分析ツールサービスである SPEEDA[*2] 内にある M&A に関するデータを使用した．本データは，2003 年〜2016 年の企業情報，財務情報に関するデータである．M&A には吸収合併，株式の取得・移管，事業譲渡，会社分割，合併などがあるが本稿では，単純に対象企業の株式の５０％超の株式を取得する行為を対象とする．株式を取得した側を買収者，された側を被買収者と呼ぶこととする．

入力する特徴量として，M&A の前の年度の売上高合計，現金及び同等物，有利子負債残高，過去に M&A をしたことがあるかを利用し，M&A 後の成功指標として，売上高合計が M&A 前と比較し上昇しているかどうかを採用した．このようにして取得した M&A を行った企業を正例とした．また，一方で提案アルゴリズムの訓練では負例のデータが必要となる．そこでランダムに M&A をしていない企業ペアを同一年度で選択して作成した．使用したデータの概要を表 1 に示す．

4.2 実験条件

入力した特徴量は買収者，被買収者ともに共通で，各業者の業種，M&A 前の売上高，現金及び同等物，有利子負債残高，過去に M&A の経験があるかを入力として，661 次元とした．

∗1 株式会社ユーザベース：https://www.uzabase.com/
∗2 SPEEDA:https://www.ub-speeda.com/

表 1: 実験に使用する M&A データの概要.

	売上高上昇	それ以外	合計
M&A ペア	104	162	266
非 M&A ペア	2669	1331	4000
合計	2773	1493	4226

提案手法では，これを埋め込み層を 3 層，ニューラル協調フィルタリング層を 3 層，タスク層を 1 層として，出力層にシグモイド関数を用いた．学習率は 0.001，最適化関数として Adam を用いた．テストデータを全体の 30%，バリデーションデータを全体の 10%とし，1,000 エポック実行した．出力は M&A，将来の予測指標として M&A 1 年後の買収者の売上高が上昇したかどうかをそれぞれ採用した．M&A 予測の比較手法として，最も基本的な CTR 予測手法として用いられる，ロジスティック回帰による手法 [5] を用いた．これに買収者，被買収者の特徴量を用いて作成したベクトルを入力した

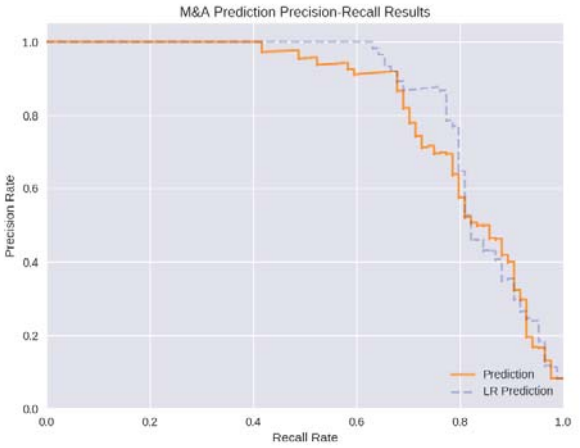


図 2: M&A の予測結果.

表 2: M&A の予測結果

Method	Precision	Recall	F-value
提案手法 ($P_{th} = 0.20$)	0.590	**0.639**	0.613
比較手法 [5]($P_{th} = 0.67$)	0.881	0.514	0.649

5. 結果と考察

M&A の予測結果を図 2 に示す．この図は，出力された M&A の確率 ($\hat{y}_{at}^{M\&A}$) で M&A すると判断する閾値を推移することで変化する，Precision,Recall の曲線を表したものである．全体的に，比較手法のロジスティック回帰モデルと提案モデルで同等の精度を示していることが観察できる．具体的な値は最終段のロジスティック回帰で出力される値の閾値 (以下，P_{th} とする) によって変動するため，提案手法，比較手法の両方で最も F 値の高くなるような P_{th} を選択した結果を表 2 に示す．提案手法は，Recall において比較手法を 12%ほど上回っているが，最終的な F 値において 3.6%ほど下回っていた．

次に，M&A 後の将来予測の精度について結果について説明する．まず，M&A 後の 1 年後に被買収者の売上が下がり，買収者の売上が上昇するという予測に関しては Precision 0.066，Recall 0.875，F-value 0.123 であった．また，M&A 後の 1 年後に被買収者の売上が上がり，買収者の売上も上昇するという予測に関しては Precision 0.003，Recall 0.080，F-value 0.006 であった．個別の正しく予測できたケースについても示すと，例えば, 日立建機による TCM の買収 (2009) 等があげられる．この M&A は，当時の世界的な建設機械の需要落ち込みの中で経営を一体化させることで収益改善を計ることを目的としたものだと報道されている [*3]．実際には M&A 後に被買収者 (TCM) の売上は下がり，買収者 (日立建機) の売上は上昇している．本提案手法によるユースケースを想定すると，これは TCM にとっては大きなメリットの無い買収であった可能性が示唆される．一方で，ゲオホールディングスによるセカンドストリートの買収 (2006) については，双方ともに売上が M&A 後に上昇している．グループ内での顧客 ID の一元化などが行われたこともあり，相乗効果のある M&A であったと言えるだろう．

本提案手法を用いることで，このように M&A 後にどのような変化が双方の企業に起こるかということも含めて予測することが可能になることが示唆されている．

6. 結論と今後の展望

本稿では，M&A 後の業績変化を考慮した M&A の予測手法を提案した．特にニューラル協調フィルタリングの枠組みにマルチタスクラーニングを組み合わせることで，自然な形での「ポスト・コンバージョン」を考慮した推薦モデルが構築できることを示した．一方で深層学習ならではの問題点も指摘される．特に M&A は回数が少ないもので，深層学習の特徴である層を重ねた場合のパラメータ数の増加に耐えるデータ量を揃えることが難しいことがあげられる．また，M&A の成功を表す指標の難しさもあげられる．今回は単に買収者の売上高の M&A 後の増加を成功指標として採用したが，被買収者が買収者と比較し小規模な会社である場合，買収者の売上高の寄与は小規模であり，それ以外の要因による変化が大きい場合が非常に多くみられる．今後は M&A の成功の指標としてより適切なもののデータ取得，開発が必要であると考えられる．

参考文献

[1] Andreas Argyriou, Theodoros Evgeniou, and Massimiliano Pontil. Multi-task feature learning. In B. Schölkopf, J. C. Platt, and T. Hoffman, editors, *Advances in Neural Information Processing Systems 19*, pages 41–48. MIT Press, 2007.

[2] David Goldberg, David Nichols, Brian M. Oki, and Douglas Terry. Using collaborative filtering to weave an information tapestry. *Commun. ACM*, 35(12):61–70, 1992.

[3] Xiangnan He, Lizi Liao, Hanwang Zhang, Liqiang Nie, Xia Hu, and Tat-Seng Chua. Neural collaborative filtering. In *Proceedings of the 26th International Conference on World Wide Web*, WWW '17, pages 173–182, Republic and Canton of Geneva, Switzerland, 2017. International World Wide Web Conferences Steering Committee.

*3 https://jp.reuters.com/article/idJPJAPAN-11265420090831

[4] Masanao Ochi, Makoto Okabe, and Rikio Onai. Rating prediction using feature words extracted from customer reviews. In *Proceedings of the 34th International ACM SIGIR Conference on Research and Development in Information Retrieval*, SIGIR '11, pages 1205–1206, New York, NY, USA, 2011. ACM.

[5] Matthew Richardson, Ewa Dominowska, and Robert Ragno. Predicting clicks: Estimating the click-through rate for new ads. In *Proceedings of the 16th International Conference on World Wide Web*, WWW '07, pages 521–530, New York, NY, USA, 2007. ACM.

[6] Rómer Rosales, Haibin Cheng, and Eren Manavoglu. Post-click conversion modeling and analysis for non-guaranteed delivery display advertising. In *Proceedings of the Fifth ACM International Conference on Web Search and Data Mining*, WSDM '12, pages 293–302, New York, NY, USA, 2012. ACM.

[7] 大知正直, 関喜史, 川上登福, 小野木大二, 野村眞平, 吉永恵一, and 松尾豊. 推薦そのものがユーザに与える影響を考慮した情報推薦. **人工知能学会全国大会論文集**, 28:1–4, 2014.

[8] 田村俊夫. *MBA のための M&A*. 有斐閣, 2009.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

インターネット上の検索行動の数理モデル

Mathematical model for search action on the Internet

石井　晃 *1　　芦田　昇 *1　　川畑泰子 *2
Akira Ishii　　Noboru Ashida　　Yasuko Kawahata

*1鳥取大学　　*2群馬大学
Tottori University　　Gunma University

Mathematical model to analyze search action on the Internet is presented on the sense of sociophysics. As an extension of the mathematical model for hit phenomena, in the present model, we assume that the search action of ordinary people in society is affected not only by mass media campaign, direct communications and indirect communications, but also by Twitter and blog posting.

1. はじめに

人々のインターネット上の検索行動は人々がその時その時に何に興味あるかをよく示していると考えられる．Blog，Twitter，Facebook などへの書込も人々の興味関心を反映させているが，書込まではせずに検索で調べるだけという人も少なくなく，そうした人々の行動は検索行動の方で反映される．Blog，Twitter などに書き込む人々を自らの意見を顕在化させる「顕在層」とすれば，そうした書込をせずに検索をする人々は潜在化している「潜在層」である．本研究はそうした潜在層の興味関心を調べる，人々の検索行動について動力学的な数理モデルを提案する．

Blog，Twitter，Facebook などのソーシャルメディアの普及が進み，インターネット上には様々な話題について書き込まれている．

そうした書込の解析にはヒット現象の数理モデルが有用である [1, 2]．過去の研究として，映画の興行収入の予測や AKB 選抜総選挙の順位予想などエンターテインメントの分野への応用に成功している [3]．従来は人々の興味関心の指標として Blog，Twitter を用いる数理モデルに対し，別の指標でも応用できないかと考え，本研究では検索数を人々の興味・関心の指標として計算する数理モデルを提案する．先行研究でも検索数を人々の興味関心の指標とし，SIR モデルを用いて情報の拡散過程を説明するモデルを構築していたが，本研究で提案するモデルは検索行動の動力学を記述するモデルである [4]．それにより，今までからは読み取れなかった潜在層の人々の動きや，及ぼされる外的影響から新たな知見が得られると考えられる．

本研究で，人々の検索行動は Google Trend を用いて調べた．さらに特定の話題ごとの Blog や Twitter の書込はホットリンク社のクチコミ@係長で調べ，その話題のテレビやネットへの露出はエムデータ社調べを用いた．

2. 数理モデル

本研究はヒット現象の数理モデルにならう形で，社会の人々による検索行動の動力学を記述する新しい数理モデルを構築することを目的とする．その数理モデルでは人々の検索行動に，Blog や Twitter も影響を与えると考え，その影響とマスメディアの影響の比較も行う．本研究で特に注目していることは以下である．

連絡先: 石井晃，鳥取大学工学研究科，ishii@tottori-u.ac.jp

1. 計算が実測の GoogleTrends を説明できるか，その精度を確認，条件を変えて比較する．
2. 従来のヒット現象の数理モデルと各パラメータを比較，考察する．
3. 新たに外力項に追加した Blog，Twitter のパラメータがどのように影響しているのかをみる．

なお，GoolgeTrends で用いている検索数のデータは 1 から 100 に規格化されたものであり，以下，ここでは関心度と呼ぶことにする．(Google はこれを人気度と呼んでいる)

2.1 ヒット現象の数理モデル

ヒット現象の数理モデルでは，社会における人々の 1 人 1 人が抱く興味・関心を定量化する．ある人「i さん」が抱く興味・関心を $I_i(t)$ と定義し，興味・関心（$I_i(t)$）を掻き立てる要員として，

1. メディアによる影響
2. 会話による影響
3. 噂による影響

の 3 つがあると考える．面と向かった会話やインターネットを用いた直接的なやりとりによる影響のことを「直接コミュニケーション」，街中の噂やソーシャルメディア上でのやり取りなどに影響を受けることを「間接コミュニケーション」と呼ぶ．それらについて興味・関心の時間的変化を追う微分方程式を立て，数理モデル化すると，以下の形になる [1]．

$$\frac{\mathrm{d}I_i(t)}{\mathrm{d}t} = \sum_{\xi} c_\xi A_\xi(t) + \sum_{j\neq i}^{N} D_{ij} I_j(t) + \sum_{j}\sum_{k} P_{ijk} I_j(t) I_k(t) \tag{1}$$

ここで D_{ij} は直接コミュニケーションの強さを表す係数，P_{ijk} は間接コミュニケーションの強さを表す係数である．広告宣伝の影響は外力と考える．ある話題に関する日毎のテレビでの露出秒数や，ネットニュースの件数を A_ξ とし，その係数を c_ξ とする．ξ はメディアの種類を表す添え字である．

式 (1) は個々の視点に基づいた式であるが，簡単化のために平均場近似を行う．社会全体の構成員の数を N 人とし，社会

全体で平均化された人々の意欲・関心を I(t) として，以下で定義する．

$$I(t) = \frac{1}{N}\sum_i I_i(t) \tag{2}$$

この平均場近似を用いると， I(t) に従う方程式は次のようになる [1].

$$\frac{\mathrm{d}I(t)}{\mathrm{d}t} = \sum_\xi c_\xi A_\xi(t) + DI(t) + PI(t)^2 \tag{3}$$

実際に計算する際には左辺の微分の箇所を，

$$\frac{\Delta I(t)}{\Delta t} = \sum_\xi c_\xi A_\xi(t) + DI(t) + PI(t)^2 \tag{4}$$

と表す．本研究では 1 日 1 日の動向をこのヒット現象の数理モデルで探るので，$\Delta t = 1$[日] として，

$$\Delta I(t) = \sum_\xi c_\xi A_\xi(t) + DI(t) + PI(t)^2 \tag{5}$$

となる．

マスメディアの影響など広く人々に影響する外部からの影響 $A_\xi(t)$ の時間的減衰が指数関数的に減少するとする．分析日を $t = t_0$ とし，式 3 の A(t) を $\sum_{i=0}^{N}\sum_\xi c_{\xi_i} A_{\xi_i}(t)\exp\alpha_\xi)(t_i - t_0)$ (α_ξ は減衰のパラメータ) と書き換えると，

$$\frac{\mathrm{d}I(t)}{\mathrm{d}t} = \sum_{i=0}^{N}\sum_\xi c_{\xi_i} A_{\xi_i}(t)\exp\alpha_\xi(t_0 - t_i) + DI(t) + PI(t)^2 \tag{6}$$

となる．N 日前の $t = t_N$ と表せる．

2.2 検索行動の数理モデル

本研究ではヒット現象の数理モデルの考え方で検索行動の意欲について数理モデルを立て，さらにブログや Twitter，さらには Wikipedia での当該の話題の検索数も考えて次のように数理モデルをたてる．

$$\begin{aligned}\frac{\mathrm{d}I(t)}{\mathrm{d}t} =& DI(t) + PI(t)^2 \\ &+ \sum_{i=0}^{N} c_{tv_i} A_{tv_i}(t)\exp(t_i - t_0)\alpha_{tv} \\ &+ \sum_{i=0}^{N} c_{news_i} A_{news_i}(t)\exp(t_i - t_0)\alpha_{news} \\ &+ \sum_{i=0}^{N} c_{blog_i} A_{blog_i}(t)\exp(t_i - t_0)\alpha_{blog} \\ &+ \sum_{i=0}^{N} c_{twitter_i} A_{twitter_i}(t)\exp(t_i - t_0)\alpha_{twitter} \\ &+ \sum_{i=0}^{N} c_{wikipedia_i} A_{wikipedia_i}(t)\exp(t_i - t_0)\alpha_{wikipedia}\end{aligned} \tag{7}$$

このモデルでは人々の興味関心の指標である I(t) を Google-Trends の関心度とし，従来のヒット現象のモデルの広告宣伝の項には Tv，ネットニュースの影響しか加味していなかったが，第 5 項の Blog の影響，第 6 項の Twitter の影響，第 7 項に Wikipedia 検索の影響を追加した．実際の計算では話題ごとに Wikipedia 検索は入れる場合と入れない場合がある．

本研究ではこの数理モデルで分析を進める．

2.3 精度の計算方法

また，係数をフィッテイングの際に精度を表す指標として，2 本の曲線の一致度を測る指標である R_factor を用いる [?, ?]. R_factor は物理学の電子線回折で実験と理論計算の曲線の類似度を測る指標として 3 0 年以上用いられている確立された技術である．R_factor は以下の式である．

$$R = \frac{\sum_i (f(i) - g(i))^2}{\sum_i ((f(i))^2 + (g(i))^2)} \tag{8}$$

ここで，例えば本研究では $f(i)$ はターゲット (映画など) に対する関心度の件数，$g(i)$ は検索行動の数理モデルによるシミュレーション結果の値を用いる．

R は，$0 \leqq R \leqq 1$ の範囲で，値が小さいほどフィッティングの精度が良い．

3. 計算結果

3.1 「君の名は.」計算結果

図 1 に 2017 年に公開された映画「君の名は.」の計算結果を示す．分析期間は公開前から公開後 2ヶ月の全体のものである．C,D,P などのパラメータは Google Trend の測定データに合うように，つまり乱数によって変更したパラメータを用いた計算毎に R-factor を計算し，10 万回以上試行して最も R-factor が低い計算結果を採用したものである．図 1 でわかるように最終的な計算結果は Google Trend の測定データをきれいに説明する．

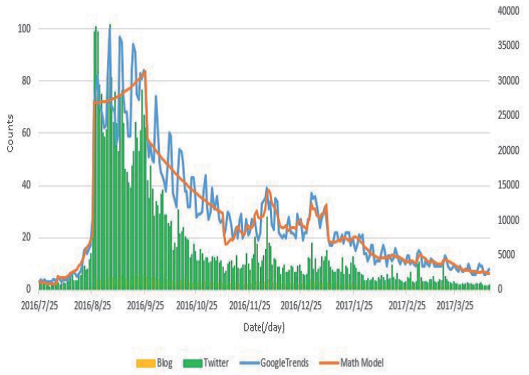


図 1: 君の名は．計算結果．: 青線が関心度，赤線が数理モデルによる再現，緑の impulse が Twitter の件数，橙の impulse が Blog の件数である．横軸は 1 日おきの日付，縦軸は数値であり，左側を関心度のスケール，右側を Blog，Twitter の書き込み件数のスケールで表している．

次に 2016 年に話題になったピコ太郎による PPAP (Pen Pinapple Apple Pen) の動画についての計算を示す．この動画が大人気になったのは 2016 年 9 月であり，ここでは盛り上がりの初期からほぼ終息している 2016 年 9 月 1 日から 2017 年 4 月 30 日を分析期間とした．

次にパラメータを比較していく．以下に毎月の直接コミュニケーション D，間接コミュニケーション P の比較グラフを図 2，図 3 に,Tv の影響 Cadv_t とネットニュースの影響 Cadv_n の比較グラフを図 4，図 5 に，Blog の影響 Cadv_Blog と Twitter の影響 Cadv_twitter の比較グラフを図 6，図 7 に示す．

4. 考察

従来のヒット現象の数理モデルでの D,P を顕在層の人々のみのパラメータ，本研究でのモデルの D,P を潜在層の人々のパラメータが大量に含まれていると仮定して考察を進める．それは Blog や Twitter が自分の考えを外に向けて発信していく人であるのに対し，GoogleTrends による検索行動には発信をしない潜在層の人々の関心も多く含まれているからである．

ピコ太郎のヒットについてのヒット現象の数理モデルによる分析は先行研究 [5] があり，この解析によるとピコ太郎のヒットを 2016 年 9 月ー 10 月で分析すると，ブレイク時に間接コミュニケーションの強さ P は大きな値になり，一方で直接コミュニケーションの強さ D はブレイク後に減っている．

今回の数理モデルで間接コミュニケーションの強さ P は分析区間全部にあたって一定の強さを示している一方，直接コミュニケーションの強さ D はブレイク時と年末年始前後，そして翌年春に大きくなっている．これはブレイク時に特に強い支持があったと言える．なお，年末年始に D が大きいのは紅白歌合戦にピコ太郎が出たことによると思われる．TV やネットニュースの影響はブレイク時に限られ，逆に Blog や Twitter の影響はブレイク後に高まっていることがわかる．

他に季節性のある話題についてこの検索行動の数理モデルを用いた研究もあり [6]，それも顕在層と潜在層の関心の動きの違いなどが示されているので，本論文で提示した検索行動の数理モデルは有用であると思われる．

5. 結論

本研究では人々の検索行動のダイナミクスを数理モデルとして提出した．従来の Blog や Twitter への書込行動を計算するヒット現象の数理モデルと比べ，ピコ太郎の動画の計算で異なる傾向が得られ，書き込む顕在層と検索だけをする潜在層で関心を持つタイミングが異なることがわかった．検索行動の解析や予測にこの数理モデルを用いるのはマーケティング等に有効であり，またバースト現象の解析にも有効であろうと思われる．

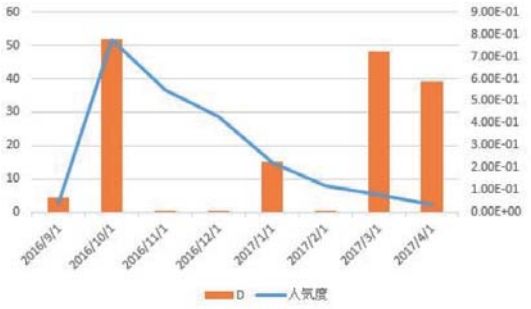


図 2: ピコ太郎における本研究の数理モデルの直接コミュニケーション D 比較．横軸はそれぞれの分析区間，縦軸はパラメータの数値．分析区間は 2016 年 9 月 1 日から 2017 年 4 月 30 日．

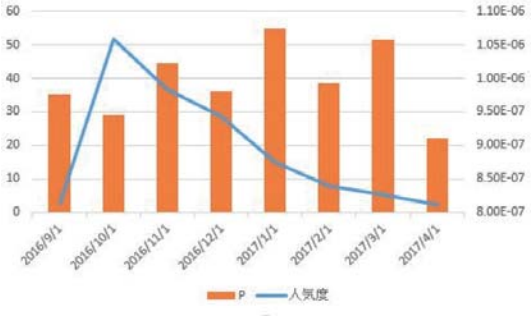


図 3: ピコ太郎における本研究のモデルの間接コミュニケーション P 比較．横軸，縦軸，分析区間は分析区間は 2016 年 9 月 1 日から 2017 年 4 月 30 日．

参考文献

[1] Akira Ishii, Hisashi Arakaki, Naoya Matsuda, Sanae Umemura, Tamiko Urushidani, Naoya Yamagata and Narihiko Yoshida ."The 'hit' phenomenon: a mathematical model of human dynamics interactions as a stochastic process". New Journal of Physics 14(2012)

[2] Ishii A, "Analysis and Predictions of Social Phenomena via social media using Social Physics method", INFORMATION-An International Interdisciplinary Journal 20(10) 7073-7086 (2017)

[3] Ishii A, Ota S, Koguchi H and Uchiyama K, the proceedings of the 2013 International Conference on Biometrics and Kansei Engineer- ing(ICBAKE2013) 143-147 DOI 10.1109/978-0-7695-5019-0/13 (2013)

[4] 大知正直，長濱憲，榊剛史，森純一郎，坂田一郎『口コミ指数による事例類型化に基づく複数メディアのヒット前の露出を先行指標とした情報拡散過程の分析』(2016)

[5] Ishii A, Fukui K, Oda T, Miki A, Fujiwara S, Okano N and Kawahata Y, "Analysis of social epidemic phenomena on Social Media using social physics approach" Adv. Sci. Lett. in press

[6] 少林俊道，岡野のぞみ，川畑泰子，石井晃『ソーシャルメディア上の季節性のある書込の解析』第 2 回計算社会科学ワークショップ (2018)

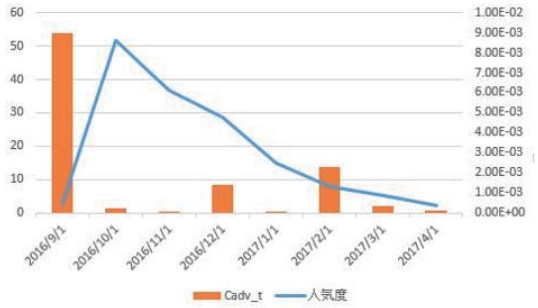


図 4: ピコ太郎における本研究のモデルのテレビの影響 Cadv_t 比較．横軸，縦軸，分析区間は分析区間は 2016 年 9 月 1 日から 2017 年 4 月 30 日．

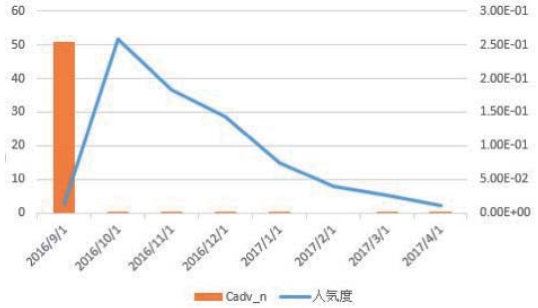


図 5: ピコ太郎における本研究のモデルのネットニュースの影響 Cadv_n 比較．横軸，縦軸，分析区間は分析区間は 2016 年 9 月 1 日から 2017 年 4 月 30 日．

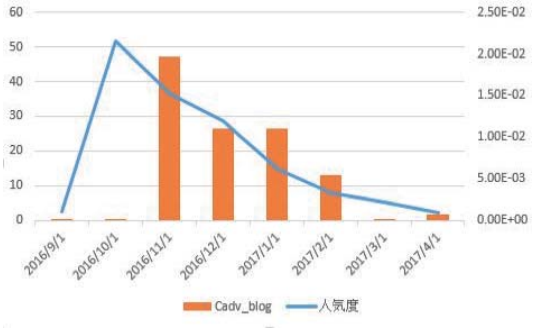


図 6: ピコ太郎における本研究のモデルの Blog の影響 Cadv_blog 比較．横軸，縦軸，分析区間は分析区間は 2016 年 9 月 1 日から 2017 年 4 月 30 日．

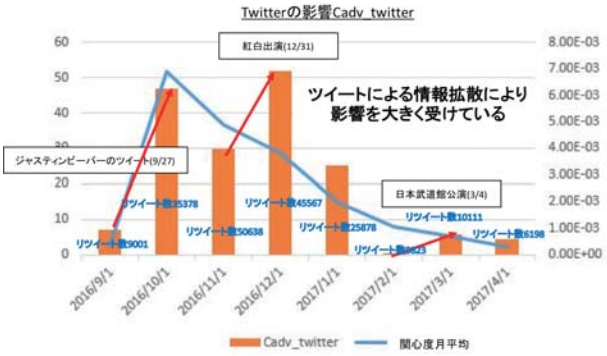


図 7: ピコ太郎における本研究のモデルの Twitter の影響 Cadv_twitter 比較．横軸，縦軸，分析区間は分析区間は 2016 年 9 月 1 日から 2017 年 4 月 30 日．

[1E3] [General Session] 6. Web Mining

座長:伊藤 雅弘（株式会社東芝）

Tue. Jun 5, 2018 5:20 PM - 7:00 PM Room E (4F Queen)

[1E3-02] Extraction of Product and Shop Names of Souvenir from Blog Articles

○Ryuya Ikeda[1], Kazuaki Ando[1] （1. Kagawa University）

5:40 PM - 6:00 PM

[1E3-03] What Can Be Seen from the Prefectural Assembly Minutes?

○Yuzu Uchida[1], Keiichi Takamaru[2], Hokuto Ototake[3], Yasutomo Kimura[4] （1. Hokkai-Gakuen University, 2. Utsunomiya Kyowa University, 3. Fukuoka University, 4. Otaru University of Commerce / RIKEN AIP）

6:00 PM - 6:20 PM

[1E3-04] An Interface of the Collection of Know-How Sites and the Topics aggregated by a Topic Model

○Shuto Kawabata[1], Wenbin Niu[1], Takehito Utsuro[1], Yasuhide Kawada[2] （1. University of Tsukuba, 2. Logworks Co., Ltd.）

6:20 PM - 6:40 PM

[1E3-05] Analysis of Political Party Accounts' Followers in Japan Electoin 2017

○Fujio Toriumi[1], Matsuo Yoshida[2] （1. The University of Tokyo, 2. Toyohashi University of Technology）

6:40 PM - 7:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

ブログ記事からの土産の品名・店名抽出

Extraction of Product and Shop Names of Souvenirs from Blog Articles

池田 流弥 *1
Ryuya Ikeda

安藤 一秋 *2
Kazuaki Ando

*1 香川大学大学院工学研究科
Graduate school of Engineering, Kagawa University

*2 香川大学工学部
Faculty of Engineering, Kagawa University

Demand for souvenirs that can be purchased only at the particular location or area is increasing, because anyone can purchase various souvenirs on online shopping sites. Such souvenirs are called local limited souvenirs in this paper. However, there are no Web sites and services that collected information about local limited souvenirs. The purpose of this study is to construct a system that presents useful information about local limited souvenirs, in order to provide support for selecting souvenirs. This paper proposes a method for extracting names of souvenirs and shops from blog articles using CRF (Conditional Random Fields). The effectiveness of the proposed method was confirmed by evaluation experiments.

1. はじめに

土産に関するアンケート調査[アサヒ 17]により，旅行に行った際，9 割以上の人が土産を購入することが確認されている．また，土産を選ぶ際，その場所でしか手に入らないものが重視されることも確認されている．その理由として，オンラインショップの普及や交通網，運送業などが発達することで，多種多様な商品が手軽に購入できるようになり，現地でしか購入できない土産が注目されるようになったと考えられる．しかし，現地でしか購入できない土産に関する情報を一元的に提供している Web サイトやサービスは存在しない．そこで，本研究では，現地でしか購入できない土産に関する情報を Web 上から自動で収集・整理し，ユーザに提示するシステムの構築を目的とする．

現地でしか購入できない土産の情報は，Web 上に散在している．しかし，全国各地で販売されている土産の品名を網羅したリストは存在しないため，現地でしか購入できない土産に関する情報を抽出する手がかりとして利用できない．そのため，旅行記や口コミなどが書かれたテキストから土産の品名を自動抽出する技術が必要となる．

本稿では，CRF（Conditional Random Fields）を利用して，ブログ記事から土産の品名と店名を抽出する手法を提案し，その性能について評価する．

2. 土産情報提示システム

本研究では，現地でしか購入できない土産に関する有用な情報を提示する土産情報提示システム[Nagao 17]の構築を進めている．本システムは，Q&A サイトやブログ記事から土産情報（土産の品名，販売店舗名，金額，評判など）を収集する．「現地でしか購入できない」という情報については，検索エンジンやオンラインショップを利用して土産の購入難易度（レア度）として判定する．ユーザへの情報提示法は，以下の 2 つがある．

① 地名や品名などから検索する方法
② 地図を利用して検索する方法

①では，リスト形式で情報を提示する．ユーザが最も重視する要素で土産情報を並び替えることにより，土産の選定を手助けできる．②では，地図上に土産の販売場所の位置や現在地をプロットすることにより，土産情報を提示する．この機能により，現地でしか購入できない土産の販売場所までの移動を手助けできる．

また，長尾ら[Nagao 17]は，土産情報のうち，Q&A サイトやブログ記事から土産名を収集する手法として，正規表現による土産名候補の抽出と SVM（Support Vector Machine）による品名の妥当性判定を組み合わせた手法を提案している．評価実験により，土産名候補の適合率は 0.05，再現率は 0.52，SVM による品名の妥当性判定では 0.82 という結果が得られている．

しかし，土産名抽出手法の性能は十分であるとはいえない．土産名抽出の性能が低ければ，他の土産情報を収集する際にも影響が出る．そこで，本稿では，土産名の新しい抽出手法を提案する．

3. 土産名抽出の関連研究

土産名を Q&A サイトやブログ記事から収集する関連研究について説明する．

3.1 川野らの研究

川野らの研究[川野 15]では，Q&A サイトから土産名を地域別に収集するツールの構築を目的に，入手地域と土産名の候補になる形態素 n-gram を抽出する手法を提案している．川野らの手法では，初めに，Q&A サイトの土産名が含まれている質問に対するベストアンサーを取得し，形態素解析する．その後，解析結果の形態素列から 1~5 までの形態素 n-gram 群を生成し，土産名になりえない形態素 n-gram をパターンマッチにより除去する．そして，残った形態素 n-gram に対して残差 IDF で重み付けし，スコアが高いものほど土産の可能性が高いと判断する．評価実験では，スコアが高いもののみを土産名として抽出した場合，適合率が約 0.1，再現率が約 0.5 という結果が得られている．

3.2 石野らの研究

石野らの研究[石野 10]では，旅行ブログエントリから自動的に観光情報を収集するための手法を提案している．観光情報としては，土産名と観光名所を対象としている．石野らの手法では，旅行ブログを検出した後，観光情報を抽出する．旅行ブログの判定および観光情報の抽出には，CRF による系列ラベリングを用いている．評価実験により，旅行ブログの検出性能は，適合率 0.87，再現率 0.38，観光情報の抽出性能は，出現頻度に

連絡先：池田流弥，香川大学大学院工学研究科
〒761-0396 香川県高松市林町 2217-20 安藤研究室，
rikeda71@gmail.com

より 100 位までにランク付けされた土産名において精度 0.74, 観光名所において精度 0.71 が得られている.

4. 土産の品名・店名抽出手法

本研究では, 土産の品名が固有表現であること注目し, 固有表現抽出により, Q&A サイトやブログ記事から土産の品名を抽出する手法を提案する. 固有表現抽出には, 石野らの研究を参考に, CRF による系列ラベリングを採用する. また, 土産の販売店舗名も固有表現であることから, 提案手法では, 土産の品名と販売店舗名を抽出対象とする. なお, 抽出対象とする品名は, 菓子類の土産のみとする.

4.1 学習データの作成法

CRF に用いる学習データは次の手順で作成する.

① Q&A サイトやブログから土産について書かれたテキストを収集し, 1 文ずつ形態素解析する.

② 各形態素に対して, 以下のルールでタグ付けする. タグの形式には IOB2 タグ形式を用いる.

- 食品名に品名のタグ(PRO)を付与
- 食品を販売している店に店名のタグ(SHO)を付与
- 「」などの記号を含めて品名, 店名のタグを付与
- 品名, 店名でないものに O タグを付与

ここで, 食品名に品名タグを振る理由は, 食品が土産を包含しているからである. 土産でない食品も将来的には土産になる可能性があるため, 土産と商品は区別せずにタグを付与する.

IOB2 タグ形式での各タグの意味を表 1 に示す. 固有表現の始まりである系列には B タグを付与する. 系列が固有表現の途中であれば I タグを付与する. 固有表現でない系列には O タグを付与する.

表 1. IOB2 タグ形式でのタグの意味

タグ	意味
I	系列で固有表現が継続している
O	系列が固有表現でないことを示す
B	系列が固有表現の始まりであることを示す

4.2 ラベリング手法

系列ラベリングの手法として, 矢野らの研究[矢野 17]を参考に, 単語ベース手法(word 手法)と文字ベース手法(char 手法)の 2 種類を提案し, 性能を比較する. word 手法のラベリングのイメージを図 1 に, char 手法のイメージを図 2 に示す. 図 1, 2 に示すように, word 手法は形態素単位で, char 手法は文字単位でラベリングする. word 手法では, 品詞情報をラベリングに活用できるといる利点がある. char 手法では, 形態素解析の誤りに影響されないという利点がある.

友達	に	白い	恋人	を	貰い	まし	た
O	O	B-PRO	I-PRO	O	O	O	O

図 1. word 手法でのラベリングイメージ

友	達	に	白	い	恋	人	を	貰	い	ま	し	た
O	O	O	B-PRO	I-PRO	I-PRO	I-PRO	O	O	O	O	O	O

図 2. char 手法でのラベリングイメージ

4.3 ベースライン素性

本稿では, 以下の 3 つを形態素(文字)に対する CRF のベースライン素性とする.

- 表記
- 文字種
- 品詞細分類

文字種は, アラビア数字, 英字小文字, 英字大文字, ひらがな, カタカナ, 漢字, その他の 7 種類とする. 品詞細分類は形態素解析で獲得できる品詞を利用する. word 手法では, 参照している形態素と前後 2 形態素について, 上記 3 つの素性を利用する. char 手法では, 品詞情報は活用できないため, 参照している形態素と前後 2 形態素について, 表記と文字種のみを素性として利用する.

4.4 追加素性・前処理・ラベリングの変更

ベースライン素性に, 以下の(1)〜(3)の素性と(4), (5)の前処理, (6), (7)のラベリングの変更を個別に追加し, 有効性を確認する.

(1) 店名のみをラベリングした後, 店名を含む文にフラグを立て, 品名のみのラベリングの素性に利用(2exec)
(2) チョコ, クッキーなどの一般的な食品名になりえる単語にフラグを立て, 素性に利用(comName)
(3) 括弧内の単語にフラグを立て, 素性に利用(inBracket)
(4) 括弧のタグを O タグに変更する(exBracket)
(5) 形態素解析の品詞間違いを修正する(correct)
(6) 文末からラベリングする(backward)
(7) BIOES タグ形式に変更する(BIOES)

(1)は, 文中で店名が出現したとき, 品名が共起しやすいことを利用した素性である.

(2)は, 一般名と商品名を区別した学習を期待した素性である.

(3)と(4)は, ブログ記事で品名や店名が「」や()などの括弧中に書かれやすいことに注目した素性と前処理である.

(5)の前処理は, 品詞の素性をより正確に利用できると考えて導入する.

(6)の変更は, 文末から文頭に向かってラベリングすることにより, 動詞の情報を活用して学習することを期待して導入する. 例えば, 「食べる」や「貰う」といった動詞が出現する前には, 商品が出現しやすいという傾向を活用できると考える.

(7)の変更は, 先行研究[Ratinov 09]で, BIOES タグ形式の有効性が報告されており, タグ形式による違いを確認するため導入する. BIOES タグ形式でのタグの意味を表 2 に示す. 表中の B, I, O タグは, IOB2 タグ形式と同様の意味を持つ. IOB2 タグ形式との差異は, 固有表現の終わりと単一の系列(1 形態素もしくは 1 文字)で成立する固有表現を区別できる点である.

なお, char 手法では, (2)と(5)を素性として組み込むことができないため, それら以外を用いて評価する.

表 2. BIOES タグ形式でのタグの意味

タグ	意味
B	系列が固有表現の始まりであることを示す
I	系列で固有表現が継続している
O	系列が固有表現でないことを示す
E	系列で固有表現が終わることを示す
S	系列1つで1つの固有表現であることを示す

5. 評価実験

提案手法の性能を評価するために, 評価実験を行う.

5.1 実験環境

本実験において, 形態素解析器には MeCab[*1] を用い, 辞書は IPADIC を利用する. CRF の実装には CRFsuite[*2] を用い,

*1 http://taku910.github.io/mecab/

*2 http://www.chokkan.org/software/crfsuite/

ハイパーパラメータはデフォルト値を用いる．実験データは，土産名をクエリとして，Yahoo!ブログの菓子・デザートカテゴリ内でヒットしたブログ記事の本文とする．収集した 373 エントリ，6,177 文に対して人手で固有表現タグを付与し，文として成立していないもの（土産の品名や店名のみの文など）を除いた 5,170 文を実験データに用いる．なお，実験データ内の固有表現数は，品名が 1,603，店名が 990 となった．

5.2 評価方法

適合率，再現率，F 値を評価尺度とし，10 分割交差検証で抽出性能を評価する．人手でタグ付けした結果とラベリングされた結果を比較し，完全一致した場合のみを正解と判断する．

本実験では，固有表現の既知/未知（学習データに含まれる/含まれない）を区別して評価する．既知の固有表現の場合，固有表現の表層文字列を学習するため，性能が高くなる傾向がある[福島 08]．本手法では，現地でしか購入できない土産の品名と販売店舗名が主要な抽出対象であるため，学習データに含まれていない未知の固有表現に対する性能が重要になる．

5.3 ベースライン手法の性能

word 手法でのベースラインの実験結果を表 3 に，char 手法でのベースラインの実験結果を表 4 に示す．表 3, 4 の F 値（F1）より，既知/未知を区別しない場合，word 手法の性能が高いことがわかる．同様に，未知の固有表現に対しても単語ベースの性能が高い．既知の固有表現に対しては，2 つに大きな差はない．以上のことから，char 手法より word 手法の性能が全体的に高いといえる．

char 手法の性能が全体的に低くなった原因として，素性として使える情報が word 手法と比べて少ないことが挙げられる．char 手法で使える情報は表記と文字種のみであるため，文脈を word 手法ほど活用できない．ただし，文字の暗記的な学習は強く働く傾向があるため，既知の品名に対する再現率は char 手法のほうが高いという結果も確認できている．

また，CRF でタグ付けされた結果を確認したところ，char 手法は，文字数が 2, 3 文字の店名に対する性能が高いことがわかった．文字数が少ない店名は漢字で書かれたものが多く，「屋」や「庵」，「堂」といった文字が付くことが多い．これらの文字を手がかりにタグ付けをしているということが予想できる．

表 3. word 手法のベースラインの性能

		precision	recall	F1
区別なし	PRO	0.774	0.621	0.688
	SHO	0.855	0.683	0.759
未知のみ	PRO	0.635	0.526	0.573
	SHO	0.619	0.457	0.524
既知のみ	PRO	0.930	0.724	0.813
	SHO	0.985	0.825	0.897

表 4. char 手法のベースラインの性能

		precision	recall	F1
区別なし	PRO	0.719	0.611	0.659
	SHO	0.830	0.665	0.737
未知のみ	PRO	0.533	0.479	0.510
	SHO	0.547	0.430	0.476
既知のみ	PRO	0.918	0.769	0.836
	SHO	0.975	0.822	0.891

5.4 単一の素性・前処理・変更を追加した実験

word 手法に対して各素性・前処理・変更を 1 つだけ追加した手法（word+one 手法）と，char 手法に対して各素性・前処理・変更を 1 つだけ追加した手法（char＋one 手法）の性能を比較し，有効な素性を確認する．本手法では，未知の固有表現に対する性能が重要になる．そのため，未知の固有表現に対する性能が向上したものを有効な素性・前処理・変更と判断する．

未知の固有表現に対して，word+one 手法，char+one 手法，word 手法の結果を比較したグラフを図 3, 4 に示す．両図において，青い棒グラフが word+one 手法の性能，オレンジ色の棒グラフが char+one 手法の性能，緑色のラインが word 手法の性能である．

図 3 より，word 手法に，(3)inBracket または(7)BIOES を追加したとき，未知の品名に対して性能が向上したことがわかる．また，図 4 より，word 手法に，(5)correct を追加したとき，未知の店名に対して性能が向上したことがわかる．そのため，未知の固有表現に対しては，これら 3 つが有効であるといえる．

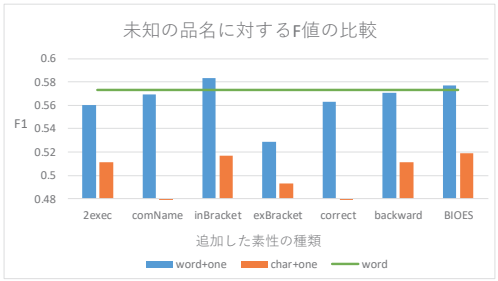


図 3. word+one 手法，char+one 手法，word 手法の未知の品名に対する F 値（F1）の比較

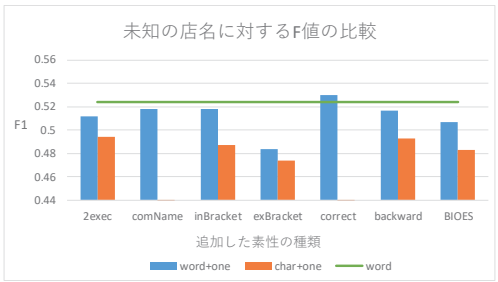


図 4. word+one 手法，char+one 手法，word 手法の未知の店名に対する F 値（F1）の比較

5.5 素性・前処理・変更の組み合わせによる実験

先の実験で未知の固有表現に対する有効性を確認した，(3)inBracket と(5)correct，(7)BIOES を組み合わせた場合の性能を確認する．なお，char 手法にこれらを追加しても，word 手法のベースラインの性能を超えられないため，word 手法にのみ追加し，性能を確認する．

本実験での組み合わせパターンは，以下の 2 つとする．

(a) inBracket + BIOES
(b) inBracket + BIOES + correct

最優先で抽出すべきは未知の品名であるため，未知の品名の抽出性能が向上する(3)inBracket と(7)BIOES の 2 つを両方のパターンに組み込む．また，図 3 から，(5)correct を追加することで，未知の品名の抽出性能が低下することがわかっているため，(a)と(b)により，(5)correct を追加する/しない場合の性能差も確認する．

word 手法に，(a)を追加したときの性能を表 5 に，(b)を追加したときの性能を表 6 に示す．表 5, 6 において，赤いセルは word 手法と比べて性能が向上した部分，青いセルは低下した部分である．表 5, 6 より，word 手法に(a), (b)を追加することで，未知の品名に対するすべての評価指標の値が word 手法より向上することが確認できた．(a)と(b)には大きな性能差はないが，

未知の品名の抽出性能を優先すべきであるため，(b)が優れているといえる．また，(b)の既知/未知の区別をしない場合の品名の F 値（F1）は，本稿での実験において最も高い値となった．

word 手法のベースラインと比べて性能が向上した理由について考察する．(3)inBracket によって，固有表現が“「」”などの記号とともに出現しやすいことが学習でき，(7)BIOES によって，固有表現の終わりを学習できる．“「」”とともに固有表現が出現するとき，必ず固有表現の終わりは“」”となるため，BIOES タグ形式によって“」”が固有表現の終わりを学習できるようになり，性能が向上したのではないかと考える．

表 5. word 手法+(a)の性能

		precision	recall	F1
区別なし	PRO	0.795	0.642	0.709
	SHO	0.858	0.680	0.758
未知のみ	PRO	0.670	0.544	0.597
	SHO	0.631	0.460	0.528
既知のみ	PRO	0.930	0.746	0.827
	SHO	0.986	0.817	0.893

表 6. word 手法+(b)の性能

		precision	recall	F1
区別なし	PRO	0.802	0.643	0.713
	SHO	0.857	0.679	0.757
未知のみ	PRO	0.682	0.548	0.605
	SHO	0.624	0.452	0.519
既知のみ	PRO	0.931	0.745	0.827
	SHO	0.986	0.820	0.895

6. エラー分析

6.1 品名・店名と判定できない系列

抽出誤りの約 6 割が，文中に品名・店名が存在するが，品名・店名のタグが付与できないものであった．以下に，タグ付けできなかった品名・店名系列の傾向を示す．

- 手がかり語（買う，貰う，食べる等）が参照系列と前後 2 形態素の中に存在しない
- 固有表現の文字種が 3 種類以上ある
- 固有表現の文字種がアルファベットのみである
- 固有表現の中や付近に空白が含まれている

1, 2 番目の系列は，参照する系列範囲を広げることでタグ付けできる可能性がある．そこで，参照範囲を広げて実験した結果，逆に性能が低下することを確認した．これまで正しくラベリングできた系列に対応できなくなったことが原因と考える．3 番目の系列は，学習データ内にアルファベットの品名や店名の固有表現が少ないことが理由として考えられる．また，形態素解析した際，単一形態素になること，文字数が多いことなどもアルファベットの固有表現を抽出する難しさとして挙げられる．4 番目の系列は，ブログ記事内での空白の使われ方の多様性が問題として挙げられる．ブログ記事内では，“_うなぎパイ_”のように固有表現の周辺に空白が出現するものや，“マウントバーム_しっかり芽_生タイプ”のように，空白自体も固有表現の一部となるもの等がある．パターンマッチなどによって余分な空白を削除できれば，空白の使われ方を絞り，その構造について学習できる可能性がある．

6.2 誤って品名・店名と推定される構造

品名・店名ではない系列に誤って品名・店名のタグが振られる場合や，品名・店名のタグが途中で途切れる場合のエラー分析を行う．

以下に，エラー分析により確認できた傾向を示す．

- “「○○”のように，固有表現に余分な系列（括弧）を含む
- 固有表現に余分な系列（括弧以外）を含む
- 品名・店名以外が「」などの記号に囲まれている
- 人を指す言葉や人の名前

1 番目の傾向は「白い恋人 12 枚入り」のように，品名の途中に金額や数量などの数字が入っている場合，「直虎_田舎_みそまん」のように，空白の後ろに品名がある場合に見られる．2 番目の傾向は，“花畑牧場シリーズ”の“シリーズ”や“香雲堂本店前”の“前”という文字列ごと，品名・店名と推定されてしまい誤ってしまうものである．3 番目の傾向は，菓子・デザートカテゴリのブログ記事では，品名や店名が“「」”や“（）”などの中に書かれることが多いことが影響している．4 番目の傾向は，“店名+さん”という構造を学習することで誤る例である．人の苗字や名前は漢字で書かれることが多いため，参照系列の範囲からは，店名か人の名前かを判断することは難しい．

これらの傾向のうち，1, 2 番目についてはパターンマッチを用いて文字列の一部を削除することで，正解として扱うことができる．しかし，これらの構造の出現数は少なく，パターンマッチを適応してもほとんど性能は向上しなかった．

7. まとめ

本稿では，CRF を用いて，ブログ記事から土産の品名と店名を抽出する手法を提案し，実験により提案手法の有効性を確認した．最終的に，品名に対する F 値が 0.713，店名に対する F 値が 0.757 という結果を得た．エラー分析により，品名・店名を抽出できない場合の系列や固有表現の構造を明らかにした．

今後の課題として，品名・店名手法の性能向上，品名・店名以外の土産情報の抽出手法の提案，レア度の計算方法について検討する．そして，土産情報をまとめたデータベースを構築し，システムの実装を目指す．

参考文献

[アサヒ 17] アサヒグループホールディングス ハピ研: 毎週アンケート第 641 回 (http://www.asahigroupholdings.com/company/research/hapiken/maian/201707/00641/)（アクセス日：2018 年 3 月 1 日）

[Nagao 16] Noriyuki Nagao and Kazuaki Ando: Extraction of Product Names for Constructing a Database of Souvenir Information, Proc. of the fifth International Conference on Informatics and Applications, pp.88-16,（2016）.

[川野 15] 川野 覚，溝渕 昭二: Q&A サイトを対象にした地域別土産物情報収集ツール，FIT2015 講演論文集，No.2，pp.221-222,（2015）.

[石野 10] 石野 亜耶，難波 英嗣，竹澤 寿幸: 旅行ブログエントリからの観光情報の自動抽出，知能と情報（日本知能情報ファジィ学会誌），Vol22，No.6，pp.667-679,（2010）.

[矢野 17] 矢野 憲，若宮 翔子，荒牧 英治: 医療テキスト解析のための事実性判定と融合した病名表現認識器，言語処理学会第 23 回年次大会 発表論文集，pp.242-245,（2017）.

[Ratinov 09] Ratinov, L. and Roth, D.: Design challenges and misconceptions in named entity recognition, Proceedings of the Thirteenth Conference on Computational Natural Language Learning, CoNLL'09, pp.147-155,（2009）.

[福島 08] 福島 健一，鍛治 伸裕，喜連川 優: 日本語固有表現抽出における超大規模ウェブテキストの利用，電子情報通信学会第 19 回データ工学ワークショップ/第 6 回日本データベース学会年次大会（DEWS2008），（2008）.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

都道府県議会会議録コーパスを用いた議員の議会活動の可視化に向けて

What Can Be Seen from the Prefectural Assembly Minutes?

内田ゆず[*1]
Yuzu Uchida

高丸圭一[*2]
Keiichi Takamaru

[*1] 北海学園大学
Hokkai-Gakuen University

[*2] 宇都宮共和大学
Utsunomiya Kyowa University

乙武北斗[*3]
Hokuto Ototake

木村泰知[*4]
Yasutomo Kimura

[*3] 福岡大学
Fukuoka University

[*4] 小樽商科大学／理研 AIP
Otaru University of Commerce / RIKEN AIP

We created a corpus for prefectural assembly minutes. Each record in the corpus has a field of "speaker's name." This field is manually checked to improve credibility of the corpus. The corpus also has attributes of speakers (namely, electoral district, birth year and gender) in the case of assembly members. We try to analyze the corpus and illustrate activities of all assembly members in Japan. This paper describes: 1) the number of assembly members in Japan, 2) age and gender composition of assembly members, 3) difference in the amount of speech depending on age and gender, 4) difference in the contents of speech depending on gender, 5) difference in the contents of speech depending on age.

1. はじめに

インターネットの普及，および，情報公開の進展に伴い，地方議会の会議録は自治体のウェブサイトに公開されるようになってきた．これまで，日本各地の議会事務局や図書館等へ出向かなければ，閲覧することができなかった議会会議録を居ながらにして，しかもコンピュータ上での分析が行いやすいテキストデータとして入手出来るようになった．著者らは現在新たに，地方政治における議論の過程と結果，およびその背景を関連づけて考えるために，地方議会会議録（議論の過程）と条例（議論の結果）および新聞記事（議論の社会的背景）を結びつけた「地方政治コーパス」の構築を進めている[木村 2016]．このコーパスでは，比較分析を定量的に行うことができるように，収集条件（対象期間・対象自治体）を整えて，都道府県議会会議録を収集している．

収集した会議録コーパスを用いることで，これまで焦点をあてられることが少なかった地方議会における議論を分析することが可能となる．[高丸 2017]では，各都道府県議会で議論される政治課題が TF･IDF に基づいて抽出される特徴語にあらわれることを明らかにした．例えば，医療施設の名称（「ふくしま国際医療科学センター」（福島県），「さいたま赤十字病院」（埼玉県），「東千葉メディカルセンター」（千葉県））は，それぞれの施設の新設や移転にあたり繰り返し議論されたことにより，特徴語として抽出された．このほか，茨城県では「森林湖沼環境税」（期間延長），東京都では「二〇二〇年大会」（オリンピック），長野県では「浅川ダム」「F－V断層」（地震への対応），奈良県では「奈良公園」「平城宮跡」「ホテル誘致」，鳥取県では「環境大学」（公立化），滋賀県では「近江大橋」（無料化）などの語が特徴語として抽出された．これは会議録コーパスを用いて，議会の議論を可視化する研究事例の 1 つである．このほか，議会ごとの発言文字数を計量的に分析することにより，議会の活発さを明らかにする研究を進めている[Kawaura 2018]．

著者らが構築した地方議会会議録コーパスには，収録されているすべての発言文に対して，発言者名の情報が付与されている．さらに，議員については，選挙の際に公開された情報に基づき，属性情報（選挙区・生年・性別）を付与している．これを利用することで，日本のすべての都道府県議会議員を対象に議会活動の可視化を行うことが可能である．

本稿で可視化を試みる都道府県議会議員に対する具体的な問いは以下のとおりである．

Q1: 全国の都道府県議会には何人の議員がいるか？
Q2: 議員の年齢・性別構成はどうなっているか？
Q3: 議会で活発に発言しているのはどの層の議員か？
Q4: 議員の性別によって発言内容に違いはあるか？
Q5: 議員の年齢層によって発言内容に違いはあるか？

これらの問いについて，機械学習などの手法を適用する以前の基礎分析として，発言者情報や単語頻度を単純な方法で集計し，構築したコーパスからの議員活動の可視化について，見通しを示すことを本稿の目的とする．2 章ではコーパスの概要，発言者名および属性情報の付与について述べる．その上で，属性情報を集計し Q1, 2 についての分析結果を述べる．3 章では，発言文字数に基づく分析を行い，Q3 についての分析結果を述べる．4 章では，Q4, 5 に答えるための基礎分析の結果を示す．

2. 地方議会会議録コーパスの概要

2.1 収集方法

都道府県議会はすべて，それぞれの自治体の Web サイトに会議録の全文検索システムを公開している．それらをクロールして，平成 23 年 4 月の統一地方選挙から平成 27 年 4 月の統一地方選挙の前（平成 27 年 3 月）までの 4 年分の全国 47 都道府県議会の本会議会議録を収集した．

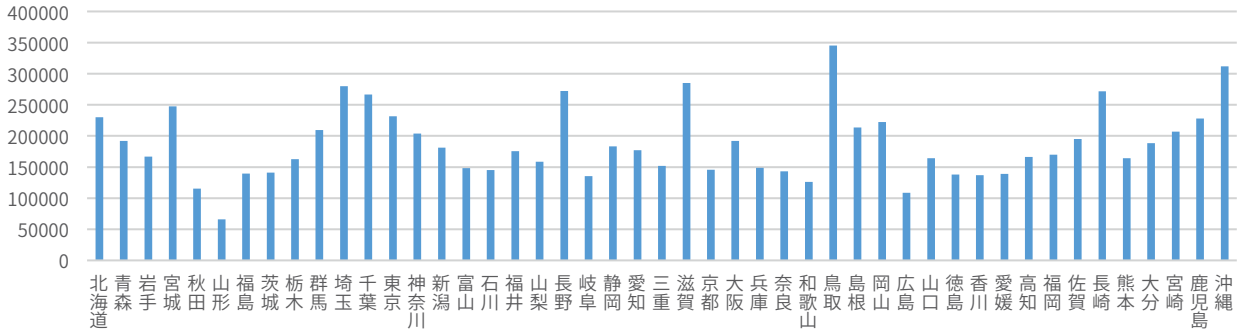


図 1 各都道府県議会における発言文字数

2.2 データ量

会議録を句点で1発言ごとに分割し，それぞれの発言の発言者名を抽出した．そして，会議の開催情報等と併せて 1 発言を1レコードとして格納した．総収録データは 1,651,676 レコードであり，発言の総文字数は 92,290,795 文字である．

各都道府県の本会議における総発言文字数を図 1 に示す．発言量が最も多いのは鳥取県で，最も少ない山形県の約 5 倍に達する．本会議の開催回数が異なるため一律に比較はできないが，発言量は議会の活発さのおおよその目安になる．

2.3 発言者の同定

会議録から抽出した発言者名は，同一人物でも複数の表記をもつことがある．例えば，「梅澤佳一自然再生・循環社会対策特別委員長」「梅澤佳一議会運営委員長」「梅澤佳一委員」「五十番（梅澤佳一議員）」「五十六番（梅澤佳一議員）」はいずれもコーパスに出現し，一人の「梅澤佳一」氏を示している．しかし，これらの発言者名を機械的に処理すると同一人物だとはみなされない．

議会での発言を議員単位で分析するためには，発言者を正確に同定する必要がある．したがって，発言者名が一つに定まらない発言者については，人手で名寄せの作業を行った．具体的には，発言者の氏名に付加された敬称や肩書，議席番号等を正規化した．また，旧字体や通称を用いる議員への対応や，会議録作成者による記載ミス等の修正も行った．名寄せの結果得られた発言者数は合計 2,793 名であった．

2.4 発言者の属性情報付与

会議録には議員の発言の他にも議長の発言（議事進行）や首長の発言，職員の発言，参考人の発言も記録されている．本コーパスには「発言者の役職」フィールドが設けてあり，各発言に役職の情報が付与されている．この情報を利用すると，議会での立場の違いによる発言の特徴を分析できる．

また，議員については生年や性別，対象行政区（選出選挙区）といった属性情報が分かると，発言内容の分析や言語的特徴の分析にとって有益であると考えられる．しかし，これらの情報は会議録中には記載されていないため，選挙の立候補者情報がまとめられたサイト（例えば，選挙ドットコム [1]）から収集し，発言を格納するテーブルとは別のテーブルに格納した（詳細は [高丸 2017]）．

表 1 地方議会会議録コーパス収集期間の議員の構成

発言者	25-44 歳	45-64 歳	65-84 歳	不明	計
男	547	1,616	457	71	2,691
女	51	174	25	5	255
計	598	1,790	482	76	2,946

表 2 議員の属性別平均発言文字数

発言者	25-44 歳	45-64 歳	65-84 歳	不明	全体
男	43,794	44,168	31,888	41,308	41,931
女	43,901	61,465	51,081	39,124	56,496
全体	43,803	45,849	32,884	41,164	43,192

以上の処理により明らかになった都道府県議会議員の構成を表 1 に示す．表中の人数には会議録に発言が記録されていない議員も含まれている．なお，年齢は平成 23 年 12 月 31 日時点のものである．日本では国会の女性議員比率が低い [2]ことが知られている．地方議会においても女性議員は男性議員の 1/10 程度にとどまり，同様の傾向が見られた．

3. 議員活動の分析(1) 発言文字数

各議員がどれほど活発に活動しているのかを知るための指標として，議会での発言量が考えられる．ここでは，発言文字数を属性別，個人別に分析する．

3.1 属性別

議員の属性別に発言の平均文字数を集計した結果を表 2 にまとめる．65～84 歳の男性議員が最も発言文字数が少なく，45～64歳の女性議員が最も多い．また，どの年齢層でも男性議員よりも女性議員の方が多く発言している．ただし，女性議員の人数は非常に少ないため，本会議全体に占める発言の割合は少ない．

ここでは単純に発言文字数のみを比較しているため，この結果から「女性議員の方が活発に発言している」と結論付けることはできない．女性の方が丁寧な表現を使用するため，発言が長くなる傾向があるとも考えられる．今後，属性による文末表現の違いなどを分析したい．

[1] http://go2senkyo.com/articles/

[2] 国会の女性議員比率：衆議院 9.5%，参議院 15.7%（平成 28 年 1 月現在）

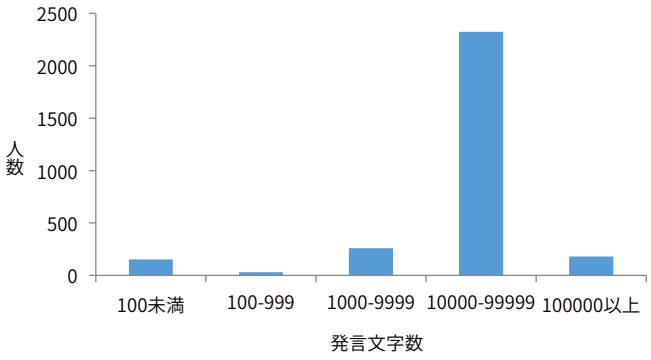


図 2 発言文字数別議員数

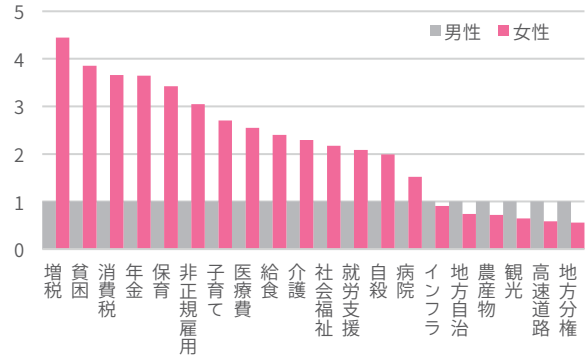


図 4 性別によるキーワードの出現割合の比較

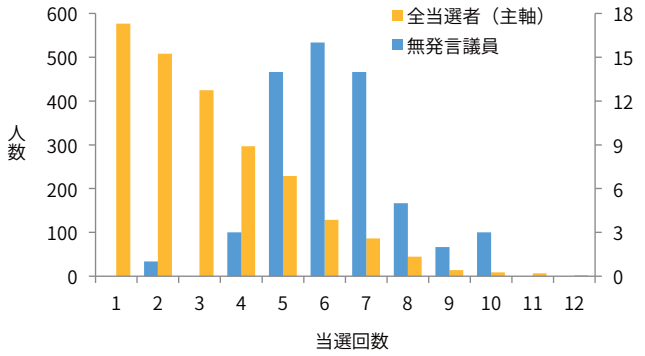


図 3 議員の当選回数

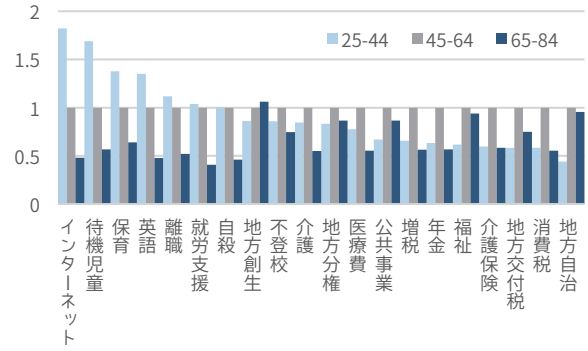


図 5 年層によるキーワードの出現割合の比較

3.2 個人別

発言文字数ごとの議員数を図 2 のヒストグラムに示す．表 2 によると平均発言文字数は 43,192 字であり，多くの議員が 10,000 字以上発言している．一方，発言が少ない議員（1,000 字未満）も 182 名存在する．そのうち，発言文字数が 0 文字，つまり会議録中に発言が全く記録されていない 151 名について詳しく調査したところ，83 名はコーパス収集期間と任期が一致しておらず [3]，10 名は議長として議事進行を行っている期間があった．したがって，それらの 93 名を除いた 58 名は 4 年間の任期中に議員として一度も発言していないことになる．

上述の 58 名の議員について当選回数を調査した結果を図 3 に示す．比較のために平成 23 年の統一地方選挙で当選した議員の当選回数も併せて示している．当選回数のデータは Web サイト「読売オンライン [4]」の選挙情報ページから取得した．

議員全体の当選回数の傾向と比較して，発言のない議員は当選回数が多いことがわかる．発言のない議員のうち 54 名は 5 回以上当選しており，所謂「多選」の議員である．低い投票率や無投票選挙の増加 [5]により議員の固定化が進む中，多選議員は議会活動へのモチベーションが低下している可能性がある．

もちろん，本会議での発言が議員活動のすべてではない．ベテラン議員が若手議員に質問の機会を譲るケースもある．しかし，有権者から見ると議会で全く発言しない議員を評価することは難しいだろう．したがって，このような情報は有権者が投票先を選ぶときに有益だと考えられる．

4. 議員活動の分析(2) キーワードの発言回数

議員によって関心のある政治課題は異なる．ここでは，政治課題に関連するキーワードの出現割合を属性ごとに比較する．キーワードは第 1 著者が選択した．

4.1 性別で比較

図 4 は各キーワードにおいて「男性議員を1とした時の女性議員の発言回数」を示している．女性議員が「増税」というキーワードを発言する回数は，男性議員の 4.4 倍にのぼる．その他，「貧困」「消費税」「年金」「保育」など，生活に密着した問題を取り上げるのは女性議員の特徴である．一方，男性議員は「地方分権」「高速道路」「観光」など，行政や産業分野への言及が多いことがわかる．

経済や産業も重要な政治課題であるものの，市民にとっては健康や子育て，家計のような身近な課題も大きな関心事である．現状では都道府県議会議員の 9 割以上が男性議員であり，政策の決定過程において女性の割合が極端に少ない．この分析結果は，「女性議員を増やすと身近な政治課題が議会で取り上げられ，民意が政策に反映されやすくなる」といった議論の材料になると考えられる．

4.2 年齢層で比較

図 5 は，各キーワードにおいて「45～64 歳の年齢層を1とした時の他の年齢層の発言回数」を示している．たとえば，45～64

[3]期間中に落選，当選，辞任，死亡，長期欠席した，あるいは逮捕，リコールされたため．

[4] http://www.yomiuri.co.jp/

[5]平成 23 年の統一地方選挙の道府県議選での平均投票率は 48.15%，無投票当選率は 17.6%．

歳の議員と比べて 25～44 歳の議員は「インターネット」というキーワードを 1.8 倍発言しており, 65～84 歳の議員は 0.5 倍発言していることがわかる. 「待機児童」「保育」「英語」も若い議員ほど多く発言しているという同じ傾向が見られる. 頻出キーワードをから, 25～44 歳の議員は子育て世代を代表した発言が多いと推測される. 45～64 歳の議員は「年金」「介護保険」「消費税」などのキーワードを発言する回数が多く, 働き盛り世代が関心をもつ話題に言及していることがわかる. 65～84 歳の議員には, 特徴的なキーワードが見つからなかった. 表 1, 2 で示した通り, この年層の議員は人数が少ない上に発言量も少ない. そのため, 発言回数に差が生じるようなキーワードが出現しにくいと考えられる.

5. おわりに

著者らが構築した地方議会会議録コーパスを利用して, 全都道府県議会の議員を対象に議会活動の可視化を目指した分析を行った. その結果, 最も発言量が多いのは 45～64 歳の女性議員であるが女性議員の人数が極端に少ないこと, 本会議で任期中に一度も発言していない議員がいること, 性別や年層によって発言内容に違いがあることなどが明らかになった.

本稿では発言文字数や単語の出現頻度などのシンプルな指標を用いた基礎分析を行ったが, 今後はより詳細な分析を行いたい. 特に, キーワード分析については, 対数尤度比などの指標を用いて, より客観的な分析を行う予定である. さらに, 国会会議録との比較も検討している.

謝辞

本研究は JSPS 科研費 JP16H02912, JP17K02739 の助成を受けたものである.

参考文献

[木村 2016] 木村泰知: 議論の背景・過程・結果を関連づける地方政治コーパスの構築に向けて, 電子情報通信学会言語理解とコミュニケーション(NLC), 思考と言語(TL)合同研究会, 2016.

[高丸 2017] 高丸圭一, 内田ゆず, 木村泰知: 地方政治コーパスにおける都道府県議会会議録パネルデータの基礎分析, 宇都宮共和大学シティライフ学論叢, 18, 136-155, 2017.

[Kawaura 2018] Akihiko Kawaura, Yasutomo Kimura, Keiichi Takamaru, Yuzu Uchida: Elected Officials in the Local Assembly: Analysis of Prefectural Plenary Session Transcripts, 日本経済学会 2018 年度春季大会（発表予定）

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

ノウハウサイト群およびトピックモデルによる話題集約結果の閲覧インタフェース

An Interface of the Collection of Know-How Sites and the Topics aggregated by a Topic Model

川畑 修人[*1] 牛 文彬[*1] 宇津呂 武仁[*2] 河田容英[*3]
Shuto Kawabata Wenbin Niu Takehito Utsuro Yasuhide Kawada

[*1]筑波大学大学院システム情報工学研究科 Grad. Sch. Sys. & Inf. Eng, Univ. of Tsukuba
[*2]筑波大学システム情報系 Fclty. Eng, Inf. & Sys, Univ. of Tsukuba
[*4](株) ログワークス Logworks Co., Ltd.

Since information of various quality are scattered in pieces on the Web, it is necessary to efficiently present useful information to users who are not familiar with the search query. In order to address this request, we propose an interface to present Web pages with aggregated topics extracted through a collection of know-how sites. In the proposed method, we collect the Web pages and aggregate them to topics and subtopics by using a topic model and word2vec. Collected know-how sites are integrated in the top page of the interface which presents the distribution of topics throughout the collection of know-how sites. For each know-how site, the interface has a function of efficiently browsing through aggregated topics and subtopics.

1. はじめに

現在，私たちは，インターネットやソーシャルメディアを活用することで，日常生活に役立つ知識を容易に得ることができる．また，様々な知識をまとめたウェブサイトも多数存在し，Yahoo!知恵袋，OKWAVE 等の質問回答サイトでは，「就活のエントリーシートの書き方」，「結婚式にかかる具体的な費用」などのノウハウ知識が多数掲載されている．しかしながら，このような質問回答サイトやその他の多様なウェブサイトには，多種多様な内容および質の情報が分散しているため，ウェブページのノウハウ知識を集約してユーザに提示することが必要となる．この要求を満たすため，[守谷 15] では，ある決まったクエリ・フォーカス (検索エンジンを利用する際に入力する文字列) において，ノウハウ知識の候補を集約・俯瞰している．さらに，[李 17] では，[守谷 15] において，収集したウェブページ集合にトピックモデルを適用した結果に対し，複数のトピックにまたがってウェブページを保持するドメインはノウハウサイトのドメインである可能性が高いと仮定し，いくつかのクエリ・フォーカスにおいて，収集された候補サイトの半数以上がノウハウサイトであるという結果を得た．

これに対し本論文では，ノウハウサイト群の各ノウハウサイトにどのような話題のウェブページが存在するかの一覧を表示するトップページ，および，それらノウハウサイトのウェブページ群を効率良く閲覧するためのインタフェースを作成する．このインタフェースを用いることで，ユーザは，クエリ・フォーカスについての網羅的な話題と有益なノウハウ知識を効率的に閲覧することが可能となる．

2. 検索エンジン・サジェストを用いたウェブページ収集

検索エンジンには，過去の検索者が検索したときの検索ログを用いることで，次の検索者が入力するクエリ・フォーカスに関係のある語群をサジェストとして検索ワードの隣に誇示するという便利な機能がある．検索者が関心を持つ事柄を収集するため，本論文では，検索者のクエリ・フォーカスに関する関心そのものが反映される，検索エンジン・サジェストを利用する．また，本論文では，クエリ・フォーカス「就活」を対象に，検索エンジン・サジェストを収集する．また，検索エンジンには，Google 社の検索エンジン・サジェストを用いる．サジェスト収集時，一つのクエリ・フォーカスあたり 100 通りの文字列 (五十音，濁音，半濁音及び開やく音を含む) を指定する．一文字列あたり最大 10 個のサジェストを収集可能なため，理論上，最大 1,000 語のサジェストを収集することが可能である．以上の手順で収集したサジェストの数は表 1 に示すとおり，925 となった．ウェブページの収集は，検索語として，「クエリ・フォーカス AND サジェスト」の AND 条件の検索設定の元，Google Custom Search API を用いて行う．収集されたウェブページの数は表 1 に示すとおり，13,222 となった．

連絡先: 川畑 修人，筑波大学大学院システム情報工学研究科，〒 305-8573 茨城県つくば市天王台 1-1-1, 029-853-5427

3. トピックモデルの適用とサブトピックへの話題集約

3.1 トピックモデルの適用およびサジェストの集約

検索エンジン・サジェストを用いることで大規模なウェブページ集合を収集することができるが，収集されるウェブページには重複する話題が多く含まれるため，収集されたサジェストおよびウェブページの集約・俯瞰が必要となる．そこで，潜在的ディリクレ配分法 (LDA; Latent Dirichlet Allocation) [Blei03] を，収集したウェブページ集合に対して適用する．LDA を適用することで，各トピック $z_n (n = 1, \ldots, K)$ における語 w の確率分布 $P(w|z_n)(w \in V)$, および, 各文書 d におけるトピック z_n の確率分布 $P(z_n|d)(n = 1, \ldots, K)$ を得ることができる．LDA 適用時には，語 w の列で表現された文書の集合，および，トピック数 K を入力する．本論文では，トピック z_n に対してウェブページ集合 $D(z_n)$ を割り当てる際，次式を用いる．

$$D(z_n) = \left\{ d \in D \,\middle|\, z_n = \underset{z_u\ (u=1,\ldots,K)}{\operatorname{argmax}} P(z_u|d) \right\}$$

ウェブページは，クエリ・フォーカスおよびサジェストの AND 検索によって収集される．そのため，各ウェブページに対して一つ以上のサジェストが対応づけられている．そこで，各トピックに対してサジェスト集合を割り当てるため，各ト

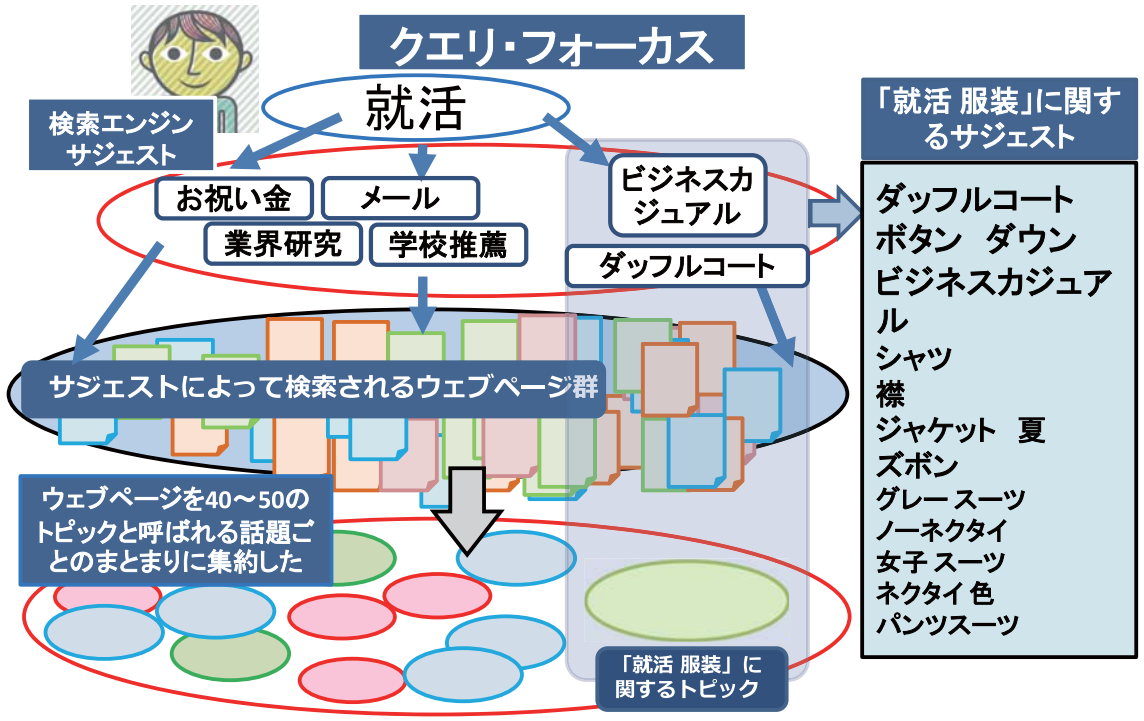


図 1: サジェストおよびトピックモデルを用いたウェブ検索結果の集約 (クエリ・フォーカス「就活」の例)

表 1: クエリ・フォーカス，サジェスト数，ウェブページ数，および，トピック数

クエリ・フォーカス	サジェスト数		ウェブページ数	総トピック数	複数トピックにまたがるドメイン数	A, B, C 群に属するドメイン数
	ウェブページ収集時	頻度下限以上，分散表現を持つサジェスト				
就活	925	671	13,222 (30.8 MB)	50	91	51

ピック Z_n に対応づけられたウェブページ集合 $D(Zn)$ 中の各ウェブページに対応づけられたサジェストを収集する．

3.2 サブトピックへの話題集約

図 1 に示すように，前節までの手順によりウェブページ収集およびその話題集約を行なった．ここで，集約された話題の粒度が粗いという問題があるため，本論分では，トピック単位の粒度の粗い話題集約結果をさらに粒度の細かいサブトピックに分割する手法を提案する．これは，[井上 16] におけるウェブ検索結果の話題集約インタフェースにおける機能を向上させることに等しい．各トピックにおける話題を高精度に集約するには，文書間の類似度が必要不可欠となる．これに対し，本論文では [Zhao17] に従い，word2vec [Mikolov13] を分散表現に基づくアプローチとして用いる． まず，収集した文書集合に対して word2vec を適用する．出現頻度が下限値以上となり分散表現を持つ検索エンジン・サジェストの数は，表 1 に示すとおり，671 となった． このうち，各ウェブページ d に対し，以下の条件を満たすサジェスト $s(d)$ を一つ設定する．

(a) $s(d)$ は，ウェブページ d を検索する際に指定されたサジェストの一つである．

(b) (a) を満たすサジェストのうち，ウェブページ d が割り当てられたトピックにおける頻度が最大となるサジェストが $s(d)$ である．

そして，ウェブページ d および d' に対し，サジェスト $s(d)$ および $s(d')$ の分散表現間の類似度

$$sim(v(d), v(d')) = \frac{v(s(d)) \cdot v(s(d'))}{\| v(s(d)) \| \| v(s(d')) \|}$$

から，ウェブページ d と d' の類似度尺度を定義する．

この，ウェブページ類似度尺度から，トピック z_n に割り当てられたウェブページ集合 $D(z_n)$ は，互いに素な部分集合へと分割される．これらの各部分集合が，各サブトピックに対応する．

$$D(z_n) = D_1(z_n) \cup D_2(z_n) \cup \ldots \cup D_m(z_n)$$
$$D_i(z_n) \cap D_j(z_n) = \emptyset \quad (i \neq j)$$

ここで，各サブトピックに対応するウェブページ集合は，下限値 θ_{lbd} 以上の類似度を持つ組とする．

$$D_i(z_n) = \left\{ d \in D(z_n) \;\middle|\; \exists d' \in D_i(z_n), \; sim(v(d), v(d')) \geq \theta_{lbd} \right\}$$

表 2: ノウハウサイト候補のドメインに対する評価基準

ドメインそのものがノウハウ知識を提示する個別ページへのリンクを一覧するページである			A 群
ドメインそのものがノウハウ知識を提示する個別ページへのリンクを一覧するページではない	ノウハウ知識を提示する個別ページへのリンクを一覧するページが存在する	ドメインのトップからノウハウ知識を提示する個別ページへのリンクを一覧するページに容易に辿り着ける	B 群
		ドメインのトップからノウハウ知識を提示する個別ページへのリンクを一覧するページには容易に辿り着けない	C 群
	ノウハウ知識を提示する個別ページへのリンクを一覧するページが存在しない	ノウハウ知識を提示する個別ページが存在する	D 群
		ノウハウ知識を提示する個別ページが存在しない	E 群

4. 閲覧対象のノウハウサイト

本節では，[李 17] に従い，閲覧対象のノウハウサイトを選定する．[李 17] では，ウェブページ収集した後の文書集合にトピックモデルを適用した結果に対して，複数のトピックにまたがって出現するドメインはノウハウサイトである可能性が高いという仮説を立て，実際に収集された複数のトピックにまたがってウェブページを持つドメインの半数以上が有用なノウハウサイトであるという結果を得ている．この，複数のトピックにウェブページを持つドメインについて，まず，あるドメインを dm_x，異なるトピック z_i および z_j $(i \neq j)$ に割り当てられた文書 d，および，d'，それらの URL を $u(d)$，および，$u(d')$ とする．このとき，$dm(u(d))$，および，$dm(u(d'))$ がともにあるドメイン dm_x と等しい場合，dm_x を複数のトピックにウェブページがまたがるドメインとする[*1]．また，複数のトピックにまたがるドメイン dm_x は，以下の式を満たすものとする．

$$\exists i, \exists j, i \neq j, \exists d \in D(z_i), \exists d' \in D(z_j)$$
$$dm(u(d)) = dm(u(d')) = dm_x$$

ノウハウサイトであるかどうかの評価は表 2 の基準を複数のトピックにウェブページがまたがるドメイン集合に対して人手によって適用し，A，B，C 群に属するドメインをノウハウサイトとする．また，i) 質問回答サイト，ii) ニュースサイト，iii) 販売サイト，iv) ブログホスト以下のブログ，のサイトのウェブページは，トップページのドメイン，あるいは，当該サイト中のいずれかのページにおいて，特定ジャンルのノウハウの一覧が参照できる，可能性が低いと仮定し，ドメインが上記 i) iv) のいずれかのサイトタイプにあたる場合にはそのドメインをドメイン集合から排除する．本研究では，この [李 17] においてノウハウサイトと判断されたドメインを閲覧対象のノウハウサイトとして使用する．表 1 に示すとおり，実際に得られた複数トピックにまたがるドメインの数は 91，そのうち，表 2 の A，B，C 群に属するドメインの数は 51 となった．

5. ノウハウサイト閲覧インタフェース

前節の手順により収集したノウハウサイト群を閲覧するためのインタフェースを作成する．作成したインタフェースの例を図 2 に示す．インタフェースのトップページでは，ノウハウサイト群中の各ノウハウサイトの持つトピックが一目でわかるように，トピックとノウハウサイトの表形式 (図 2 奥) で表示する．ノウハウサイトの表示順としては,「そのサイトに含まれるトピック数の多い順」や「ウェブページ数の多い順」,「ユーザが任意で指定したトピックを持つサイト優先」など様々な方法があるが，本論文では，ユーザに対し多くのトピックを含むサイトを優先的に示すため，[李 18] に従い，トピックの数の多いノウハウサイト順に表示する．また，今回，ノウハウサイトのタイトルは人手で取得する．各ドメインのトピック集合 $Z(dm_x)$ は以下の式で定義する．

$$Z(dm_x) \quad = \quad \left\{ z_i \middle| \exists d \in D(z_i), dm(u(d)) = dm_x \right\}$$

各ノウハウサイトのデモページへのリンク部分をクリックすると，図 2 手前のような，各ノウハウサイトごとのインタフェースが表示される．各ノウハウサイトにおいて，ウェブページを持つトピックは，オレンジ色で示され，クリックすると，トピック中のサブトピックとサブトピック以外に分類されたウェブページを表示するためのバーが表示される．例えば，就活のネクタイに関するウェブページがサブトピックに分類されると，

「就活 ネクタイ に関するサブトピック」

サブトピック以外のクラスタに分類されると，

「就活 ネクタイ に関するウェブページ」

のように表示を行う．ウェブページはサブトピックまたはサブトピック以外またはその両方に存在するので，ユーザはウェブページの存在するオレンジ色で示されたバーをクリックすることで，ウェブページのタイトル，リンクおよびそのスニペット (ウェブページの概略) を閲覧することができる．

6. 関連研究

関連研究として，[井上 16] では，検索エンジン，クエリ・フォーカスを用いて，サジェストおよびウェブページを収集，トピックモデルを用いることで話題を集約，ユーザの入力したクエリ・フォーカスに対し網羅的に話題とそのウェブページを示すためのインタフェースを作成した．[守谷 15] では，[井上 16] に対し，Yahoo 知恵袋などの質問回答サイトおよびウェブページから収集した文書集合を一つの文書集合とし，この混

*1 例えば，$u(d)$ = `http://xxx.com/yyy`，$u(d')$ = `http://xxx.com/zzz` の場合に，$dm(u(d)) = dm(u(d'))$ = `http://xxx.com/` となる．



図 2: ノウハウサイト群閲覧インタフェース

合文書集合に LDA トピックモデルを適用することで，より有用なノウハウ知識を得られることを示した．また，[李 17] では，収集したウェブページにトピックモデルを適用した結果に対し，複数のトピックにウェブページがまたがるドメインは，ノウハウサイトである可能生が高いと仮定し，いくつかのクエリ・フォーカスにおいて実際に評価を行い，候補サイトの半数以上がノウハウサイトであることを確認した．本研究は，[井上 16]，[守谷 15] におけるトピックモデルの適用に加え，さらに，粒度の粗い話題のサブトピック化を行い，ノウハウサイトに限定したウェブページページを示すという点で大きく異なっている．また，[李 17] に対しては，収集したノウハウサイトのウェブページを，話題と小話題に分類し，クエリ・フォーカスに関する網羅的な知識を提供するためのインタフェースを作成したという点で大きく異なっている．

7. おわりに

本論文では，ひとつのクエリ・フォーカスについて，ウェブページを自動収集し，トピックとサブトピックに分類，ノウハウサイトに限定してユーザに示すことで，網羅的な話題と共に，ウェブページ群を効果的に閲覧するためのインタフェースを作成した．

参考文献

[Blei03] Blei, D. M., Ng, A. Y. and Jordan, M. I.: Latent Dirichlet Allocation, *Journal of Machine Learning Research*, Vol. 3, pp. 993–1022 (2003).

[井上 16] 井上祐輔, 今田貴和, 陳磊, 徐凌寒, 宇津呂武仁, 河田容英：検索エンジン・サジェストおよびトピックモデルを用いたウェブ検索結果の集約, 第 8 回 DEIM フォーラム論文集 (2016).

[李 17] 李佳奇, 趙辰, 林友超, 馬場瑞穂, 宇津呂武仁, 河田容英, 神門典子：トピックモデルにおける話題分布特性を手がかりとするノウハウサイトの収集, 第 9 回 DEIM フォーラム論文集 (2017).

[李 18] 李佳奇, 趙辰, 林友超, 丁易, 川畑修人, 宇津呂武仁, 河田容英：トピックモデルおよび分類器学習を用いたノウハウサイトの同定, 第 10 回 DEIM フォーラム論文集 (2018).

[Mikolov13] Mikolov, T., Sutskever, I., Chen, K., Corrado, G. and Dean, J.: Distributed Representations of Words and Phrases and their Compositionality, *Proc. 26th NIPS*, pp. 3111–3119 (2013).

[守谷 15] 守谷一朗, 井上祐輔, 今田貴和, 聶添, 宇津呂武仁, 河田容英, 神門典子：質問回答事例および検索エンジン・サジェストを用いたノウハウ知識の相補的収集, 第 7 回 DEIM フォーラム論文集 (2015).

[Zhao17] Zhao, C., Nie, T., Ding, Y., Li, J., Utsuro, T. and Kawada, Y.: Identifying Major Documents with Search Engine Suggests by Unsupervised Subtopic Labeling, 第 31 回人工知能学会全国大会論文集 (2017).

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

2017年衆議院選挙における政党公式アカウントフォロワーの分析

Analysis of Political Party Accounts' Followers in Japan Electoin 2017

鳥海不二夫 *1　吉田光男 *2
Fujio Toriumi　Mitsuo Yoshida

*1東京大学　*2豊橋技術科学大学
The University of Tokyo　Toyohashi University of Technology

In the election campaign, modern political parties utilize social media to advertise their policies and candidates and to communicate electorates. In the latest election, the 48th general election for the Lower House in Japan 2017, social media, especially Twitter, was actively used. In this paper, we perform a detailed analysis of political tweets of users who retweeted offical political party accounts during the election. Our aim is to obtain how political party followers differs from each other. The results indicate that the largest two political party accounts' followers are quiet similar from view point of political tweets.

1. 緒言

ネット選挙が解禁されて依頼，日本においても選挙時に Twitter や Facebook といったソーシャルメディアを利用することは，支持者への情報発信や，新たな支援者の獲得に欠かせないものとなっている．一方で，ネット選挙の影響は限定的であるという報告も存在し [総務 14]，日本においてどのようなネット選挙の戦略が有効であるかはいまだ明らかになっていない．

ネット選挙では，ソーシャルメディアにおける拡散の強さに期待が集まっている．特に，ソーシャルメディアでは従来メディアとは異なりプッシュ型の情報拡散を行うことが可能であるため，元来当該情報に興味がないユーザに対しても他のユーザのリツイートなどの拡散行動によって情報を伝えることが可能である．そのため，各政党の公式アカウントの発言が他のユーザの協力によってソーシャルメディア全体に拡散し，より多くの人々に情報が伝わることが期待される

そこで，本研究では 2017 年衆議院選挙時の各政党公式アカウントのフォロワーについて，その特徴を明らかにすることを目指し分析を行う．本稿では，公式アカウントのツイートをリツイートするユーザが，政治的関心が高いユーザか一般的なユーザかによって情報拡散の質が異なるであろうことを考慮し，各政党のツイートがどのようなユーザによってリツイートされていたのかを分析する．

もし，日常的には政治的発言が少ないユーザによってもリツイートされている政党公式アカウントのツイートがあれば，それは一般のユーザにまでその情報が波及した可能性が高いと考えられるため，非支持層へのアピールとなるだろう．一方，日常的に政治的発言が多いユーザは，もともと当該政党の支持者である可能性が高いため，そのようなユーザによるリツイートが多いツイートは支持者へのアピールに寄与していると考えられる．

このような仮説の元，各政党の公式アカウントのツイートをリツイートしたユーザを分析することで，ツイッター戦略の違いを明らかにすることを目指す．

連絡先: 鳥海不二夫，東京大学，東京都文京区本郷 7-3-1，tori@sys.t.u-tokyo.ac.jp

2. 関連研究

Tumasjan らは Twitter が政治のためのディスカッションフォーラムとして機能していると報告している [Tumasjan 10]．一方で，ユーザが政治情報へアクセスすることについて分断が存在することが示されている [Adamic 05, Hayat 17, Hyun 14, Iyengar 09]．このような調査は主に，ソーシャルメディア上での政治に関するニュース記事について調査しており，政党のツイートなどを取り扱っているわけではない．

一般的に，フォロワー数はユーザの注目度として用いられるが，フォロワーを詐欺的に獲得するケースも存在し [Stringhini 13]，フォロワー数が必ずしも情報拡散に影響しているとは言えない．実際，政治的なコミュニケーションにおいて，情報のハブはフォロワー数だけでは決まらないことが明らかになっている [Bakshy 11]．

一方で，ユーザのツイート特性に基づいて各政党のツイート戦略について分析した研究はほとんどない．

3. データセット

3.1 収集データ

本研究で利用するために収集したデータの収集期間とその量を表 1 に示す．

主要 6 政党（自民党，立憲民主党，希望の党，公明党，共産党，日本維新の会）の公式アカウントについて，そのツイートをリツイートしたユーザを収集した．さらに，公式アカウントのツイートをリツイートしたユーザについて，過去にさかのぼってのツイートを取得 *1 した．

3.2 公式アカウントの基本データ

各政党の公式アカウントの基本情報を表 2 に示す．

ここで，Tweets は公式アカウントが行ったツイート数，Retweets は公式アカウントのツイートがリツイートされた総数，Follower はアカウントをフォローしているユーザ数，Friends は公式アカウントがフォローしているユーザ数である．

これより，多くの政党アカウントは Follower は多いが，自身はほとんど Follow を行っていないことがわかる．また，ツイート数には最大で 3 倍程度の差があり，ツイッターを積極的

*1　Twitter の API 制限により最大 3200 ツイートまで収集している

表 1: データセット

	内容	収集期間	総数
1	Official Accounts	-	6
2	OA's Tweet	2017/9/27-10/23	2790
3	Retweeted Users	2017/9/27-10/23	84043
4	Users' Tweet	2007/04/10-2017/11/14	197,267,467

に利用していた政党と，あまり積極的には利用していなかった政党があったといえる．

また，リツイートされた総数をみると立憲民主党が極めて多く，自由民主党がそれに続いており，この二つの政党の情報が多く共有されていたことがわかる．

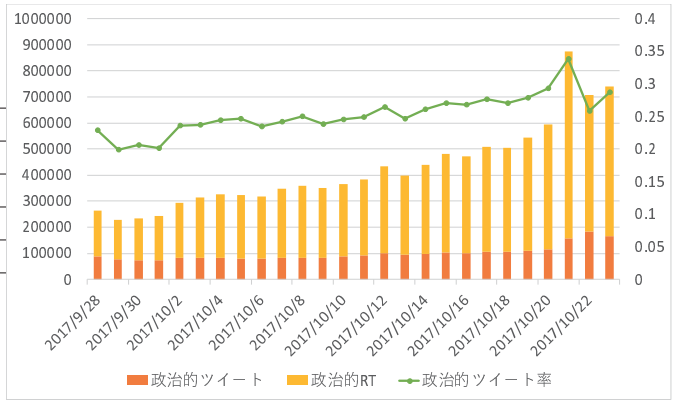


図 1: 選挙期間内の政治的ツイート

4. 政党的発言の判別

4.1 政治的ツイートの学習

各ユーザがどの程度政治的発言を行ったり，政治的発言をリツイートしているかを調べるため，各ツイートが政治的発言かどうかを機械学習を用いて判別する．

まず，人手でランダムに抽出した 9500 ツイートを，政治的ツイートか一般的なツイートかに分類した．次に，分類したツイート群を教師データとし，SVM[Vapnik 63]，ロジスティック回帰 [Cox 58]，CNN[Kim 14] を用いて学習を行った．

SVM, ロジスティック回帰では TF-IDF によって正規化した BugOfWords に変換し学習し，CNN では Tweet 内の単語を FastText により求めた単語分散表現に変換し，畳み込みニューラルネットワークを用いて学習を行った．

4.2 政治的内容を含むツイートの抽出

3 種類の手法について，全体の 70%を学習データ，30%をテストデータとして用い学習を行った．その結果得られた，テストデータに対する精度を表 3 に示す．

これより，CNN を用いた手法によって最も高い精度で政治的発言が抽出できることが確認できたた．

次に，収集した全ツイートに対して政治的発言かどうかの判別を行った．なお，ここで収集した全ツイートとは，公式アカウントのツイートをリツイートしたユーザのツイート群である．その結果，11,635,182 ツイートが政治的ツイートであると判別された．

また，選挙期間中 (9 月 28〜10 月 23 日) において，政治的ツイートおよび政治的ツイートのリツイート，そして全体に占める政治的ツイート，リツイートの割合を図 1 に示す．これより，衆議院解散日から徐々に政治的な発言は増加していき，選挙前日にピークを迎えていることがわかる．ピークが選挙当日ではないのは，選挙当日はネット選挙を行うことができないためである．以上の結果からも，判別結果は妥当であると考えられる．

5. 公式アカウントをリツイートしたユーザの分析

5.1 リツイートユーザの重複

各政党の公式アカウントをリツイートしたユーザは，当該政党の政策になんらかの興味を持っているユーザであるといえる．そのようなユーザの特徴を分析することで，各政党アカウントの情報がどのようなユーザによって拡散されたかを明らかにする．以下，各政党のツイートをリツイートしたユーザを，リツイートユーザと呼ぶ．

まず，どの程度のユーザが複数政党のリツイートユーザとなっていたかを確認するため，二つの政党を同時にリツイートしたユーザの割合を確認した．その結果を表 4 に示す．この表では，左辺の政党リツイートユーザのうち，何パーセントが上辺の政党のリツイートユーザであるかを示している．

この結果から，多くのユーザが単一の政党のツイートしかリツイートしていないことがわかる．例外的に他の政党をリツイートしている割合が高いのは，

- 希望の党，共産党→立憲民主党
- 公明党，日本維新の会→自由民主党

である．立憲民主党の成立過程を考慮すれば，希望の党のリツイートユーザが立憲民主党のツイートをリツイートすることは妥当であろう．また，自由民主党と公明党も連立政権を組んでいることから，双方をリツイートする行動も妥当であると考えられる．

一方で，共産党のユーザの 70% が立憲民主党のツイートをリツイートしている点は興味深い．リツイートユーザの人数比が大きく異なることを考慮すると，この結果は共産党のリツイートユーザの多くが立憲民主党のツイートもリツイートしていたということになる．

以上，リツイートユーザの重複関係を分析することで，政党間のユーザ関係が明らかになる可能性が示唆された．

5.2 政治的発言を用いたユーザのクラスタリング

各政党のリツイートユーザについて，政治的発言の含有率に基づくクラスタリングを行った．これによって，各政党のリツイートユーザの特徴を分析する．

まず，ここでは各ユーザの選挙期間中のツイートについて，

- ツイート数 (TW)
- リツイート数 (RT)
- 政治的ツイート数 (PT)
- 政治的ツイートのリツイート数 (PRT)

から，

- リツイート率 (RT/TW)
- ツイート中政治的ツイート率 (PT/(TW-RT))
- 政治的リツイート率 (PRT/RT)

表 2: 公式アカウント情報・ツイートは 9/28-10/23．Follower,Friend 数は 11 月 10 日に収集

政党	アカウント名	Tweets	Retweets	Followers	Friends
自由民主党	jimin_koho	280	110685	134595	322
立憲民主党	cdp2017	904	506432	191011	77
希望の党	kibounotou	410	21559	13529	152
公明党	komei_koho	289	31072	76743	1259
日本共産党	jcp_cc	347	48203	42508	253
日本維新の会	osaka_ishin	281	13163	15999	177

表 3: 学習機の精度評価

学習機	精度
SVM	0.671
ロジスティック回帰	0.727
CNN	0.839

を求めユーザの特徴量とし，K-Means($k = 7$) によってユーザをクラスタリングを行った．

得られたクラスタを表 5 に示す．この中で特徴的なクラスタである C1,C2,C4,C6 について述べる．

C1 はリツイートが少なく，政治的発言も少ないが，リツイート内には政治的内容が 83.5% 含まれている．C2 はリツイートが少なく，政治的発言も少ないクラスタである．C4 はリツイートが多く，政治的なツイートリツイートともに少ないクラスタである．C6 はリツイートが多い一方で，自身のツイートの中に政治的発言が特に多いクラスタである．

5.3 各政党におけるリツイートユーザのクラスタ

各政党のリツイートユーザが，どのクラスタに所属しているのかを分析した．その結果を図 2 に示す．ここでは，政党ごとに各クラスタのユーザがどの程度の割合で存在しているかを示している．

これを見ると多くの政党で類似した傾向を持っていることがわかる．そこで，政党ごとの特徴を明確にするために，各政党のリツイートユーザ割合の相関を求めた．もし，相関が高ければ類似したユーザ群をリツイートユーザに持っていることになり，相関が低ければリツイートユーザの性質が異なることを意味する．

その結果が表 6 である．これより，まず自由民主党と立憲民主党は相関係数が 0.816 と極めて高いことがわかる．ここから，これら二つの政党のリツイートユーザは類似しているということを意味し，どちらかが突出した特徴を持っているとはいえないことが明らかとなった．

また，自由民主党と日本維新の会が類似しており，立憲民主党と公明党が類似した性質を持つ．表 4 より，これらのペアはいずれもリツイートユーザの重複は少ないことから，全く異なるユーザで構成されているにも関わらず，その性質は類似しているという点は興味深い．

一方，日本共産党のリツイートユーザは日本維新の会以外の政党のリツイートユーザと大きく異なる性質を持っていることがわかった．

ユーザ構成の違いが政党のツイッター戦略とどのように関連するかは今後さらなる分析が必要であるが，フォロワーの多い

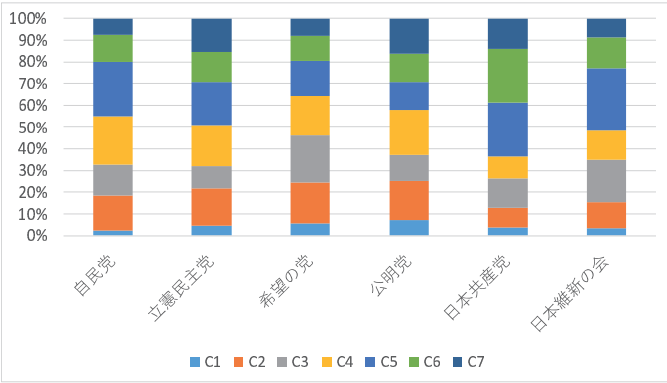


図 2: リツイートユーザの所属クラスタ

二政党の分布が類似している点は興味深い．立憲民主党のフォロワーの増加率は異常であるという言説も見受けられたが，この結果を見る限り，少なくともリツイートを行ったユーザについては，特に異常な値を示しているものではないといえよう．

6. 結言

本研究では，2017 年に行われた衆議院選挙の政党公式アカウントをリツイートしたユーザについて，分析を行った．リツイートユーザのツイートを政治的ツイートかそうではないかに分類し，その割合に基づいて，ユーザのクラスタリングを行った．さらに，各政党のリツイートユーザに各クラスタに所属するユーザがどの程度の割合含まれるかを分析し，その特徴を明らかにした．

その結果，自由民主党と立憲民主党のリツイートユーザの性質は類似していること，日本共産党のリツイートユーザは他の政党とは異なる性質を持つことなどが明らかとなった．

今後，リツイートユーザをさらに分析することで各政党に適したツイート戦略が明らかになると期待される．例えば，政治的ツイートのリツイート率が高い政党であれば，政治的ツイートを数多く行うことで，効率的に情報を拡散できると期待できる．ただし，拡散率はリツイートユーザのフォロワー率などにも影響されるため，フォローフォロワー関係などネットワーク構造についても考慮した分析が必要になると考えられる．

参考文献

[Adamic 05] Adamic, L. A. and Glance, N.: The political blogosphere and the 2004 U.S. election: divided they blog, in *LinkKDD '05*, pp. 36–43 (2005)

表 4: 公式アカウントのリツイート重複率

	自民党	立憲民主党	希望の党	公明党	共産党	維新の会
自民党		0.101	0.032	0.104	0.035	0.033
立憲民主党	0.043		0.021	0.022	0.148	0.005
希望の党	0.187	0.285		0.093	0.110	0.056
公明党	0.222	0.110	0.034		0.042	0.023
共産党	0.070	0.708	0.038	0.040		0.009
維新の会	0.380	0.131	0.111	0.126	0.050	

表 5: 政治的発言に基づくユーザクラスタ

	RT/TW	PT/(TW-RT)	PRT/RT	ユーザ数
C1	0.304	0.402	0.835	1991
C2	0.332	0.110	0.167	7662
C3	0.421	0.576	0.391	4690
C4	0.825	0.094	0.159	8772
C5	0.844	0.425	0.391	9081
C6	0.865	0.809	0.498	6204
C7	0.951	0.032	0.564	6617

表 6: 政治的発言に基づくユーザクラスタの類似性

	自民党	立憲民主党	希望の党	公明党	日本共産党	日本維新の会
自民党		0.816	0.731	0.539	0.470	0.827
立憲民主党	0.816		0.454	0.801	0.471	0.557
希望の党	0.731	0.454		0.455	0.137	0.624
公明党	0.539	0.801	0.455		0.004	0.097
日本共産党	0.470	0.471	0.137	0.004		0.731
日本維新の会	0.827	0.557	0.624	0.097	0.731	

[Bakshy 11] Bakshy, E., Hofman, J. M., Mason, W. A., and Watts, D. J.: Everyone's an Influencer: Quantifying Influence on Twitter, in *WSDM '11*, pp. 65–74 (2011)

[Cox 58] Cox, D. R.: The regression analysis of binary sequences, *Journal of the Royal Statistical Society. Series B (Methodological)*, pp. 215–242 (1958)

[Hayat 17] Hayat, T. and Samuel-Azran, T.: "You too, Second Screeners?" Second Screeners' Echo Chambers During the 2016 U.S. Elections Primaries, *Journal of Broadcasting & Electronic Media*, Vol. 61, No. 2, pp. 291–308 (2017)

[Hyun 14] Hyun, K. D. and Moon, S. J.: News Media's Role in the Issue-Voting Process: News Attention, Issue Proximity, and Vote Choice, *Journalism & Mass Communication Quarterly*, Vol. 91, No. 4, pp. 687–705 (2014)

[Iyengar 09] Iyengar, S. and Hahn, K. S.: Red Media, Blue Media: Evidence of Ideological Selectivity in Media Use, *Journal of Communication*, Vol. 59, No. 1, pp. 19–39 (2009)

[Kim 14] Kim, Y.: Convolutional neural networks for sentence classification, *arXiv preprint arXiv:1408.5882* (2014)

[Stringhini 13] Stringhini, G., Wang, G., Egele, M., Kruegel, C., Vigna, G., Zheng, H., and Zhao, B. Y.: Follow the Green: Growth and Dynamics in Twitter Follower Markets, in *IMC '13*, pp. 163–176 (2013)

[Tumasjan 10] Tumasjan, A., Sprenger, T., Sandner, P., and Welpe, I.: Predicting Elections with Twitter: What 140 Characters Reveal about Political Sentiment, in *ICWSM '10*, pp. 178–185 (2010)

[Vapnik 63] Vapnik, V.: Pattern recognition using generalized portrait method, *Automation and remote control*, Vol. 24, pp. 774–780 (1963)

[総務 14] 総務省：インターネット選挙運動解禁に関する調査報告書 (2014)

[1F1] [General Session] 4. Knowledge Utilization and Sharing

座長:福田 直樹（静岡大学）

Tue. Jun 5, 2018 1:20 PM - 3:00 PM Room F (4F Garreria)

[1F1-01] The First Knowledge Graph Completion Challenge 2018

○Takahiro Kawamura[1], Shusaku Egami[2], Shinichi Nagano[3], Ikki Ohmukai[4], Takeshi Morita[5], Yasunori Yamamoto[6], Koji Kozaki[7] （1. Japan Science and Technology Agency, 2. University of Electro-Communications, 3. Toshiba Corp., 4. National Institute of Informatics, 5. Keio University, 6. Database Center for Life Science, 7. Osaka University）

1:20 PM - 1:40 PM

[1F1-02] Faster Ontology Reasoning with Typed Propositionalization

○Maxime CLEMENT[1], Ryutaro ICHISE[1] （1. National Institute of Informatics）

1:40 PM - 2:00 PM

[1F1-03] Asynchronous Chat System for Dialogue Collection on Crowdsourcing

○Kazushi Ikeda[1], Keiichiro Hoashi[1] （1. KDDI Research, Inc.）

2:00 PM - 2:20 PM

[1F1-04] A data editing support tool for large-sized ontology data with context dependency

○Hiroshi Masuya[1], Kouji Kozaki[2], Riichiro Mizoguchi[3] （1. BRC, RIKEN, 2. ISIR, Osaka Univ., 3. Japan Adv. Inst. of Sci. and Tech. (JAIST)）

2:20 PM - 2:40 PM

[1F1-05] Normalize an academic impact indicator for evaluating interdisciplinary

○Kazuya Tanaka[1], Riku Arakawa[1], Yasuaki Kameoka[1], Junichiro Mori[1], Ichiro Sakata[1] （1. The University of Tokyo）

2:40 PM - 3:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

第1回ナレッジグラフ推論チャレンジ2018

～解釈可能な人工知能を目指して～

The First Knowledge Graph Completion Challenge 2018

– Toward the Interpretable AI –

川村 隆浩 [*1] Takahiro Kawamura
江上 周作 [*2] Shusaku Egami
長野 伸一 [*3] Shinichi Nagano
大向 一輝 [*4] Ikki Ohmukai
森田 武史 [*5] Takeshi Morita
山本 泰智 [*6] Yasunori Yamamoto
古崎 晃司 [*7] Koji Kozaki

[*1]科学技術振興機構 Japan Science and Technology Agency
[*2]電気通信大学 University of Electro-Communications
[*3]東芝 Toshiba Corp.
[*4]国立情報学研究所 National Institute of Informatics
[*5]慶應義塾大学 Keio University
[*6]ライフサイエンス統合データベースセンター Database Center for Life Science
[*7]大阪大学 Osaka University

This paper describes a new challenge for addressing knowledge graph completion held in Japan, 2018. Deep learning techniques have opened a new vista of Artificial Intelligence and promoted applying the AI-related systems to a wide variety of social systems. However, security and safety of such AI systems in addition to the interpretability of AI decision would become extremely important accordingly, as already warned in several communities. Therefore, the Special Interest Group (SIG) on Semantic Web and Ontology of JSAI organized the challenge, in which a knowledge graph showing well-known novels of Sherlock Holmes is openly constructed, and techniques for reasoning or completing the missing information about criminals that was intentionally removed from the knowledge graph are recruited from the general public. The SIG has started the challenge at the 32nd JSAI Annual Conference 2018, and hopes many participants concerned will have an active discussion to this end.

1. チャレンジ開催の背景

近年，Deep Learning を起爆剤として人工知能（AI）技術への関心が高まっている．今後，AI 技術は幅広く普及し，さまざまな社会システムに埋め込まれるようになるだろう．更には，人の手を離れてシステム自身に決定的な判断を任せるようになると予想される．しかし，安全・安心に社会の中で AI を活用していくためには，AI によるシステムが正しく動作しているかを検証する技術や品質保証が必要となる．そのため，AI が判断に至った理由を説明できる，解釈可能性 (interpretability) を有する AI 技術が必須となるだろう．既にこの点は国内外で指摘され，Neural Information Processing Systems (NIPS) など Deep Learning に関する国際会議においても Interpretable Machine Learning といったシンポジウムが開かれている．

そこで，本会セマンティク Web とオントロジー（SWO）研究会では，解釈可能性の高い AI に関する最先端技術の共有と研究開発の促進を図るため，推論に関するチャレンジを開催する．

2. 関連研究

関連する研究動向の一部として，国際会議 International Semantic Web Conference (ISWC) 2017 における推論の動向を紹介する（セッション Reasoning I, II より）．[1] では，工場などで使われているデータ・ドリブンのルールをオントロジーを用いて抽象化し，再利用可能にしたルールシステムを構築し，Siemens でプロトタイプ実証を行った結果について示している．実応用の観点で評価され Best In-Use Paper を受賞した．[2] では，ルールを含めて内部表現を Tensor で統一し，推論から機械学習までを一気通貫する大規模データ処理フレームワーク SANSA を提案し，Apache Spark とも連動させることで Best Demo Paper を受賞している．[3]，[4] はいずれも昨今注目を集めているストリーム推論にフォーカスしており，[3] では表現力 (expressiveness) と実時間性 (runtimes) を両立させた推論エンジン Laser を提案している．また，[4] ではストリーム推論用ベンチマーク環境をオープンソースとして提供している．[5] では，オントロジー（DL）推論エンジンを効率と正確さでランキングするメタ推論エンジンを提案し，1954 セットのオントロジーに基づいて HermiT や FaCT++, Racer，Pellet など 10 の推論エンジンを調査した結果を示している．

上記以外にもナレッジグラフ補完 (completion) に関する研究や，前章で述べた機械学習系における解釈可能性へのアプローチなども注目すべき研究と言えるだろう．しかし，いずれにおいても後述する本チャレンジに類似するプロジェクトは見つかっていない．

3. 推論チャレンジの概要

SWO 研究会では，本チャレンジに関する企画委員を任命し，研究会顧問らを含めて議論を重ねた結果，推理小説を対象とした犯人当てのタスクとして設計することとした．理由としては，犯人は論理によって導かれること，小説が広く一般に知られていること，現実の問題を一部反映していることなどが挙げられる．具体的には，シャーロック・ホームズの短編小説いずれかを対象とし，事件や背景，人物像を知識化したナレッジグ

連絡先: 川村 隆浩，国立研究開発法人 科学技術振興機構 情報分析室，takahiro.kawamura(at)jst.go.jp

ラフ *1 から自動的に犯人を推論（推理）することを目的とする．推論（または推定）する手法は問わない．例えば，以下のような方法が考えられるだろう．

手法 1 クエリー言語 SPARQL でナレッジグラフを検索して探す．例えば，特定の時間に特定の場所に居た人を Union で探す，など

手法 2 一階述語論理に基づくルールを加えて推論する．例えば，ナイフに個人の指紋がある ⇒ 犯人である，など

手法 3 オントロジーに基づいて記述論理で推論する．例えば，犯人クラスを定義し，犯人候補との包摂関係を推論する，など

手法 4 機械学習を用いて分類，クラスタリングして推定する．例えば，他の事件における犯人の特徴群から学習・推定する，など

但し，タスク設定上，人を犯罪者扱いするからには理由をきちんと説明できることを回答の条件とする．

3.1 チャレンジタスク詳細

まず事前準備として，シャーロック・ホームズシリーズの短編小説 *2「白銀号事件」と「赤毛組合」を題材とし，オープンワークショップを 3 回開催 (2017/11/25，12/19, 2018/2/28) した．本ワークショップでは，ナレッジグラフの試験的な記述を通して，本タスクに必要となる知識（ナレッジグラフで記述すべき内容）とその表現方法にいて議論し，その結果をもとにスキーマ設計を行った（参加者の延べ人数は 80 名程度であった）．

第 1 回ワークショップ（2017/11/25）では,「赤毛組合」のあらすじを元に 3–4 名ずつのグループでナレッジグラフの試験的記述を行ったところ，図 1 のように，登場人物間の関係性の記述が多く見られた．その結果を踏まえ，スキーマ設計の基本方針を検討する目的で行った第 2 回ワークショップ（2017/12/19）においては，ナレッジグラフとして記述すべき内容の種類を数え上げることを中心に議論した．その結果，小説内で描かれてる出来事（イベント）を中心とし，それに付随する情報として，それらのイベントに関与した人物，もの，場所，それらの関係性などを記述するという基本方針を決定した．さらに，第 3 回のワークショップにおいて，この方針に沿ったスキーマの詳細設計と，ナレッジグラフを記述する具体的な作業手順に関する議論を行った．

次にスキーマに沿ってナレッジグラフを構築するためのスプレッドシート（表）形式のテンプレートを Google Drive にて作成し，ワークショップ参加者や SWO 研究会 ML を通して広く賛同者を募り，小説に書かれた事実情報，登場人物の証言（虚偽も含む），ホームズの推理により導かれた内容など犯人を特定するに至る全ての情報を含むナレッジグラフ（以下，完全グラフ）を構築した．完全グラフ構築にあたっては 4 回目のオープンワークショップも開催した (2018/3/18，参加者約 30 名)．尚，本来は犯人の特定に直接的には関係しない情報（情景，状況の描写や常識など）もナレッジグラフに含めるのが良いと思われるが，2 年度目以降の課題としたい．

*1 様々な情報・データから抽出した知識をグラフ構造状に整理した知識ベースの一種．Google が検索エンジンの検索結果を拡張するために使用しているものが最も有名であり，2017 年現在，10 億のエンティティ（事象），700 億の属性情報の定義をもつと言われている．セマンティック技術の分野では，Wikipedia の情報を元にした DBpedia や Wikidata が有名である．

*2 https://ja.wikipedia.org/wiki/Category:シャーロック・ホームズシリーズの短編小説

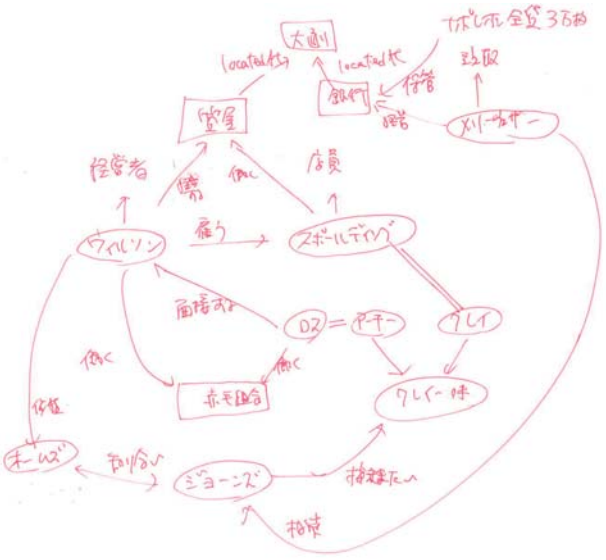


図 1: 第 1 回ワークショップで記述されたナレッジグラフの例

そして，完全グラフからホームズの推理によって導かれた犯人を特定する情報を取り除いたグラフ（以下，不完全グラフ）を作成・公開し，いずれかの手法で削除された情報を推論（推定）し，犯人を特定する手法とその結果を募集するものである．完全グラフから取り除く情報を変えることで，比較的容易に推理できるタスクと高度なタスクなど複数用意した．

応募作品の評価ポイントは，犯人を正しく当てられていること (correctiveness) に加えて，上述の解釈可能性 (interpretability)，推論（推定）手法の技術的な新規性 (novelty)，実用性 (utility)，処理時間 (runtimes) など，いくつかの観点で評価する予定である．また，応募作品を通してセマンティックスによる推論と機械学習による推定，それぞれの手法の特徴を比較，評価，議論する．

3.2 ナレッジグラフおよびスキーマ

本節ではナレッジグラフのスキーマ，および「白銀号事件」に関するナレッジグラフの一部を紹介する．

スキーマ設計にあたっては，題材とする小説を表すための表現力 (expressiveness) に加えて，ナレッジグラフとしての構築のし易さや推論処理にデータとして与える際の利便性を考慮し，結果として各文を意味役割付与 (Semantic Role Labeling) し，事象 ID を中心に主語 (subject) や述語 (predicate)，目的語 (object) など主に 5W1H をエッジとして持つスキーマとした．各文を表すサブグラフの ID を参照することで時系列的な行動や事象の因果関係，さらには人や組織，場所に関する静的な情報も併せて記述できる．但し，一般常識を公理として記述したり，小説内で使用される時刻表のような情報を表すには別途，ルールやテーブル形式のデータも活用する．また，グラフ構築の負担を減らすため，一部，文章内の文字列をリテラル値としてそのまま入力することも許している．

そして，スキーマに沿ってナレッジグラフを構築するにあたり，図 2 のようなシートを一般に公開した．図 2 は事象（event）を記述するためシートの一部であるが，他に静的なオブジェクトを記述するためのシートも作成，公開した．賛同者には小説内の段落を割り振り，該当する項目を埋めてもらい，最後に一括してナレッジグラフに変換した．尚，シートの記載にあたってはクラウドソーシングも活用した．実際に構築されたナレッ

記述内容	必須	説明	ID	Property	Object（原文）	Object（統制ラベル）	展開フラグ	関連ID
ID	○	1文（または，ひとまとまりの述語）単位でユニークなIDを付与 ※IDを記述する行は特別扱い．IDと原文の紐づけ	E-00001	source	Aさんの話によると，白銀号が失踪した晩、予想屋と思われる怪しい男が白銀号の厩舎に，こっそりとやってきた。			
event-type	○	事実の描写や誰かの発言，予想（推理）など		event-type		証言		
infromation-source		事実の描写でない場合は，情報源を明記		information-source	Aさんの話によると	Aさん		
main-predicate	○	主となる述語		main-predicate	やってきた	来た		
5W1H ※必要に応じProperty追加				who	予想屋と思われる怪しい男が	予想屋の男		
		whereはTo,From,ATなど複数定義		to-where	白銀号の厩舎に	白銀号の厩舎		
				when	白銀号が失踪した晩	白銀号が失踪した晩	○	O-00001
				what				
				why				
				how	こっそりと			
event-relation		他のイベントとの関係（same-time, because, thereforeなど）		same-time	その時，番犬は吠えなかった.		○	E-00002
ID			E-00002		その時，番犬は吠えなかった.			
…								

図 2: ナレッジグラフ構築シート（一部）

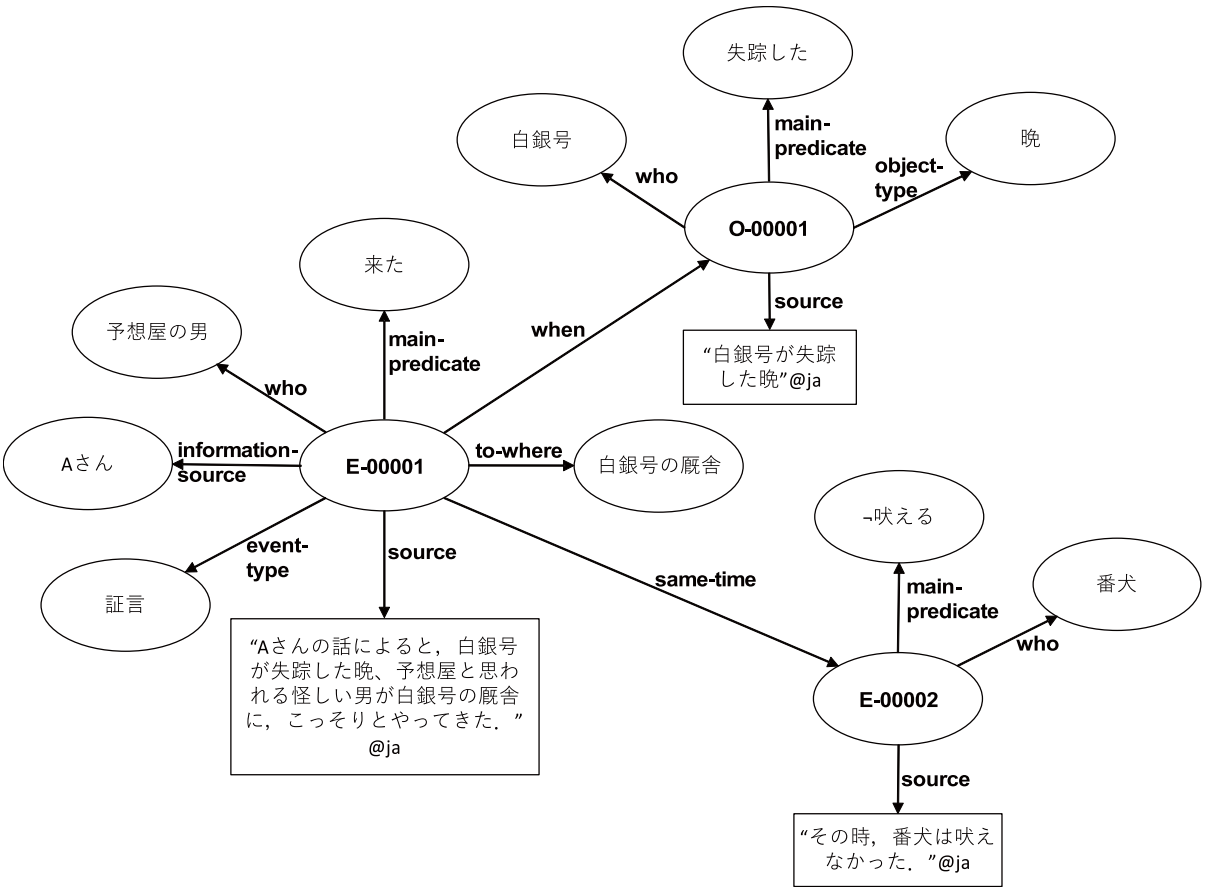


図 3: ナレッジグラフ（一部）

ジグラフの一部を図 3 に示す．

3.3 本タスクの学術的位置付け

本タスクは，ナレッジグラフの補完 (Knowledge Graph Completion)[*3] の一種として一般化することができ，ナレッジグラフを含むさまざまな知識ベースの構築，保守，更新などに適用できる汎用的な問題設定として位置づけることができる．但し，現実問題へのフォーカスを想定し，精度と解釈可能性を重視している点やナレッジグラフに虚偽情報も含まれている点，さらにナレッジグラフが必ずしも大規模ではない点などに独自の難しさがある．

4. 開催スケジュール

上述したように，これまで 4 回のワークショップを通して，スキーマ設計およびナレッジグラフ構築を行ってきた．今後は，本発表を以ってナレッジグラフを公開し，チャレンジをスタートする．詳細は，本チャレンジのサイト [*4] を参照して欲しい．

チャレンジ応募は，2018 年 10 月末日とし，11 月に予定されている国際会議 8th Joint International Semantic Technology Conference (JIST 2018)(11/26–28, 淡路島)[*5] の併設イベントとして授賞式を開催する予定である．また，チャレンジの概要，応募作品の評価等に関しては，本会論文誌に寄稿を予定している．更に，2 年度目以降は国際イベントとし，海外からの参加も募りたい．ナレッジグラフ構築の自動化など，タスクの範囲を広げることも検討している．

5. おわりに

本論文では，解釈可能な AI 技術の深耕を目的として，推理小説を題材としたナレッジグラフから犯人を推理（グラフを補完）するチャレンジの企画・開催について述べた．本チャレンジは本会 SWO 研究会が中心となって進めているものであるが，広く一般から協力を仰いでデータを構築・公開し（オープンデータ），応募された技術を共有することで更なる発展を期待する（オープンサイエンス）の形式で進めているものである．本チャレンジは 2018 年度人工知能学会全国大会開催当日より約半年間の日程でスタートする．是非，チャレンジへの参加をご検討されたい．

謝辞

本チャレンジ開催にあたりまして，これまで 4 回に渡るワークショップ参加者の皆様へ感謝申し上げます．

参考文献

[1] G. Mehdi, E. Kharlamov, O. Savkovic, G. Xiao, E. G. Kalayci, S. Brandt, I. Horrocks, M. Roshchin, T. Runkler: Semantic Rule-Based Equipment Diagnostic, Proc. ISWC 2017.

[2] J. Lehmann, G. Sejdiu, L. Buhmann, P. Westphal, C. Stadler, I. Ermilov, S. Bin, N. Chakraborty, M. Saleem, A.-C. N. Ngomo, H. Jabeen: Distributed Semantic Analytics using the SANSA Stack, Proc. ISWC 2017.

[3] H. R. Bazoobandi, H. Beck, J. Urbani: Expressive Stream Reasoning with Laser, Proc. ISWC 2017.

[4] R. Tommasini, E. D. Valle, A. Mauri, M. Brambilla: RSPLab, RDF Stream Processing Benchmarking made easy, Proc. ISWC 2017.

[5] N. Alaya, M. Lamolle, S. B. Yahia: Multi-Label Based Learning for Better Multi-Criteria Ranking of Ontology Reasoners, Proc. ISWC 2017.

∗3 機械学習問題の 1 つとして知られており，WordNet や Freebase を対象にして実験・評価した研究が多数存在する．

∗4 http://challenge.knowledge-graph.jp/

∗5 http://jist2018.knowledge-graph.jp/

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

Faster Ontology Reasoning with Typed Propositionalization

Maxime Clement Ryutaro Ichise

National Institute of Informatics, Tokyo, Japan

Ontology reasoning is an important but complex problem allowing the discovery of new knowledge and the query and maintenance of complex data. For decision making in real-time systems, faster approach such as decision tables are often used. In this paper, we propose a technique to perform efficient ontology reasoning with decision tables. Our experiments show a significant improvement of the reasoning time compared to a naive approach.

1. Introduction

Ontologies [Staab and Studer, 2010] provide the vocabulary necessary to represent knowledge related to a specific domain by formally defining concepts, relationships between these concepts, and instances of these concepts. In recent years, ontologies have been widely used in many fields such as bioinformatics [Consortium, 2014] or recommender systems [Middleton et al., 2004, Kang et al., 2014], allowing experts to easily exchange knowledge and reason on well-structured data.

Similarly, ontology reasoning has become a well-adopted technique for the maintenance and query of ontologies, or the matching of different ontologies. Thanks for flexible and expressive rule languages [Horrocks et al., 2004] and powerful reasoners [Sirin et al., 2007, Shearer et al., 2008], rules can easily be written and maintained by non-experts and can easily be adapted to changing ontologies. The main downside of this expressiveness and flexibility is its reasoning complexity. Ontology rules, similarly to first-order logic, use variables that can be assigned to the entities of the ontology. Reasoning then consists in evaluating the rules by considering each combination of entities to the variables and checking if the conditions of the rules are true. This is a computationally complex operation which have been shown to limit the applicability of ontologies to real-time systems [Hashimoto et al., 2017].

In some applications, entities are constantly changing and reasoning must be performed as fast as possible, making typical reasoning methods based on first-order logic too slow. Instead, decision tables can be used to rapidly compute decisions but are hard to maintain. It is possible to transform rules used in ontology to decision table through a process known as propositionalization [Krogel et al., 2003]. This process has several downsides, requiring to already know the values for the variables (i.e., the entities of our ontology) and generating a decision table of exponential size.

In this paper, we are interested in allowing efficient reasoning with ontologies through the use of decision tables. We propose a method to transform rules to propositional form using placeholders instead of real entities, allowing us to perform a large part of the computation in advance. Placeholders are generated with classes corresponding to the variables used in the rules, creating a correspondance between placeholders and variables. During reasoning, we only need to map the real-world entities to the placeholders instead of mapping them to all the variables of the rules. In our experiments, we use a car ontology designed for automated-driving where fast reasoning time is critical to avoid accident. We show that our method is much faster than the naive propositionalization used when directly reasoning in first-order logic and that even complex situations can be handled within 122ms.

Contact: maxime-clement@nii.ac.jp

2. Preliminaries

In this section, we first briefly explain how we represent ontologies using first-order logic. We then describe the naive propositionalization necessary to use decision tables to reason with ontology rules.

2.1 Ontologies

An ontology formally defines the vocabulary necessary to describe some specific domain, usually in the form of a set of entities, classes, and properties. Entities are used to represent real-world objects, classes are collections of entities with a common type, and properties are relationships between entities.

We use first-order logic to formally write ontologies such that entities are constants, classes are unary predicates, and properties are binary predicates.

Example 2..1 (Ontology)**.** The knowledge "the car A is in front of the bike B" is written as

$$\textsc{Car}(a), \textsc{Bike}(b), \textsc{InFrontOf}(a, b)$$

where a and b are entities, Car and Bike are classes, and InFrontOf is a property.

In order to reason with an ontology, we use rules of the form $R = body \rightarrow head$ where *body* and *head* are conjunctions of literals. Similary to the logical implication, this means that if the content in *body* is true, then the content in *head* should also be true. In order to have general rules that can be applied to multiple entities, variables that can be replaced with any entity of the ontology are used. We refer to the set of variables used in a rule R as $var(R)$.

Example 2..2 (Rule)**.** The rule "if something is a car, it is a vehicle" is written as

$$\textsc{Car}(X) \rightarrow \textsc{Vehicle}(X)$$

where X is a variable.

2.2 Propositionalization

Propositionalization is the process of converting information from relational form (like in ontologies) to propositional form made exclusively of true or false propositions. Rules in propositional form corresponds directly to a decision table where each rule represents a row such that its body is the set of conditions and its head the set of actions.

To fit rules written in first-order logic into a decision table, each assignment of entities to the variables must be considered. Once an assignment is given, the rules can be converted to propositional form where each predicate is replaced by a proposition corresponding to the assignment. Similarly, knowledge about entities is also propositionalized, giving us a set of true propositions that can be used to determine whether the body of a rule is true or not.

Example 2..3 (Rule Propositionalization)**.** Given a rule $\textsc{Car}(X) \rightarrow \textsc{Vehicle}(X)$ and an assignment $\{X : a\}$ meaning entity a is assigned to variable X, we generate the propositional rule

$$\textsc{Car}_a \rightarrow \textsc{Vehicle}_a$$

Assuming the knowledge $\textsc{Car}(a), \textsc{Bike}(b)$, we generate the propositions

$$\textsc{Car}_a, \textsc{Bike}_b$$

We can now evaluate the previous rule and determine that its body is true since $\textsc{Car}_a$ is true, which means that $\textsc{Vehicle}_a$ is also true.

There exists several limitions with such *naive* propositionalization. First, the rules generated are for some specific entities, meaning that if entities change, then new rules should be generated. Second, each combination of entities to variables need to be considered, which quickly leads to an intractable number of propositional rules.

3. Typed Propositionalization

In order to improve the conversion from ontology rules to decision table, we propose *typed propositionalization* which uses a preprocessing step that performs propositionalization without the need for entities to be defined. The idea of this method is to instantiate the rules in advance, using placeholders instead of the real entities. When reasoning, real entities only need to be assigned to these placeholders, which requires less computation and makes the reasoning faster.

Definition 3..1 (Typed Placeholder)**.** We define $T = \{\mathrm{C}_0, \mathrm{C}_1, \ldots\}$ as a typed placeholder where C_i is an unary predicate (i.e., a class).

For each rule R, a placeholder is associated to each variable using the classes of the variable. For each variable $v \in var(body)$, a placeholder $T_v = \{\mathrm{C} | \mathrm{C}(v) \in body\}$ is generated where *body* is the body of rule R. When all the variables in R have a non-empty placeholder, we say that R is *well-typed*.

The rule R is then converted to propositional form $R_{\mathcal{T}}$ using the assignment $\{v : T_v | v \in var(body)\}$ such that each property $\mathrm{P}(x, y)$ is replaced by a proposition $\mathrm{P}_{T_x T_y}$ and each class predicate in the body is removed.

Example 3..1 (Typed Propositionalization)**.** Given a well-typed rule

$$\textsc{Car}(c) \wedge \textsc{Vehicle}(v) \wedge \textsc{InFrontOf}(v, c) \rightarrow \textsc{Warning}(c)$$

we generate the placeholders:

- $T_c = \{\textsc{Car}\}$ (placeholder for c);
- $T_v = \{\textsc{Vehicle}\}$ (placeholder for v).

We then generate the rule $R_{\mathcal{T}}$.

$$\textsc{InFrontOf}_{T_v T_c} \rightarrow \textsc{Warning}_{T_c}$$

After this preprocessing step, we have the set of all placeholders $\mathcal{T}$ and the generated propositional rules.

4. Reasoning with Typed Propositionalization

Once the rules have been propositionalized using placeholders, we are ready to perform reasoning with real entities. To reason using our typed-rules, we need to match the entities to their corresponding placeholder, generate the corresponding typed-facts, and execute the rules. We thus separate the reasoning into 4 phases.

1. Entity matching: match compatible entities with the placeholder.
2. Knowledge propositionalization: create propositional facts based on the matching.
3. Typed Reasoning: trigger the rules based on the created propositional facts.
4. Interpretation: transpose the new facts for their corresponding entities (instead of the placeholders).

Because several entities can correspond to a same placeholder, there might be several assignment to consider and steps 2-4 need to be repeated for each possible assignment.

4.1 Entity Matching

Entity matching consists in creating, for each placeholder T, the set of entities $E_T = \{e | T \subseteq classes(e)\}$ where $classes(e)$ is the set of classes of the entity e. If for at least one placeholder T there is $|E_T| > 1$, then we need to consider multiple assignments of entities to the placeholders. The number of total assignments to consider is $\prod_{T \in \mathcal{T}} |E_T|$. We refer to an assignment A as a set of pair $(T : e)$ meaning that entity e is mapped to placeholder T.

Example 4..1 (Entity Matching)**.** Given the placeholders $\mathcal{T} = \{T_c = \{\textsc{Car}\}, T_v = \{\textsc{Vehicle}\}\}$, and two entities a and b such that $\textsc{Car}(a), \textsc{Vehicle}(a), \textsc{Bike}(b), \textsc{Vehicle}(b)$, we generate the set of matching entities for each placeholder: $E_{T_c} = \{a\}$; $E_{T_v} = \{a, b\}$. We can thus consider two assignments $A_1 = \{T_c : a, T_v : a\}$ and $A_2 = \{T_c : a, T_v : b\}$.

Entities	Naive Propositionalization		Typed Propositionalization	
	Propositional Rules	Reasoning Time (ms)	Propositional Rules	Reasoning Time (ms)
6	105360	591	300	3
8	616560	6230	300	4
10	2436840	31419	300	4
12	OOM	-	300	7
14	OOM	-	300	13
16	OOM	-	300	35
18	OOM	-	300	70
20	OOM	-	300	122

Table 1: Comparison of the reasoning time and number of propositional rules using naive and typed propositionalization with 26 placeholders and 300 rules. OOM indicates settings where we ran out of memory.

4.2 Knowledge Propositionalization

Given an assignment A, we propositionalize all knowledge by replacing references to an entity e by its assigned placeholder T.

Example 4..2 (Knowledge Propositionalization)**.** Given the assignment $A_2 = \{T_c : a, T_v : b\}$, and the knowledge $\textsc{Car}(a), \textsc{Vehicle}(a), \textsc{Bike}(b), \textsc{Vehicle}(b), \textsc{InFrontOf}(b, a)$, we generate the propositional knowledge $\textsc{Car}_{T_c}, \textsc{Vehicle}_{T_c}, \textsc{Bike}_{T_v}, \textsc{Vehicle}_{T_v}, \textsc{InFrontOf}_{T_v T_c}$,

4.3 Typed Reasoning

Now that we converted facts expressed for our entities to facts expressed for the placeholders, we can evaluate each propositional rule $R_{\mathcal{T}}$.

Example 4..3 (Reasoning)**.** Given the propositional rule from Example 3..1, and the propositional knowledge $\textsc{Car}_{T_c}, \textsc{Vehicle}_{T_c}, \textsc{Bike}_{T_v}, \textsc{Vehicle}_{T_v}, \textsc{InFrontOf}_{T_v T_c}$, we obtain the new knowledge $\textsc{Warning}_{T_c}$ since the body of the rule ($\textsc{InFrontOf}_{T_v T_c}$) is part of our knowledge base.

4.4 Interpreting the Results

Once all rules have been evaluated for an assignment A, we need to convert the resulting predicates which are expressed for the placeholders $\mathcal{T}$ into first-order predicates expressed for the real-world entities. This conversion is the reverse of the knowledge propositionalization where we now replace each placeholder T by its corresponding entity e in the assignment A.

Example 4..4 (Interpretation)**.** Given the new knowledge $\textsc{Warning}_{T_c}$ obtained with the assignment $A_2 = \{T_c : a, T_v : b\}$, we interpret it as $\textsc{Warning}(a)$.

Once this interpretation has been done for the results obtained with each possible assignment, we obtained all the possible implications for the current state of the ontology.

5. Experimental Results

We now present results obtained using the ADAS ontology*1 [Zhao et al., 2017] written in OWL2 [Grau et al., 2008, Motik et al., 2009] and rules written in SWRL [Horrocks et al., 2004]. We compare the naive propositionalization presented in Section 2.2 and typed propositionalization presented in Section 3. and 4.. Both methods were implemented in Java using the OWLAPI [Horridge and Bechhofer, 2011] to interact with the ontology, using an Intel Core i7-7700K running at 4.20GHz and with 1GB of memory dedicated to the JVM. We use a set of 300 SWRL rules with the number of variables ranging from 2 to 6. This set was previously used for testing the speed of ontology reasoners [Hashimoto et al., 2017] and we manualy made minor modifications to ensure all rules are well-typed. This dataset generated 26 placeholders using our typed-propositionalization.

Table 1 shows the reasoning time (average over 10 runs) and number of propositional rules for the naive and typed propositionalization varying the number of entities. For naive propositionalization, we first observe the very high number of propositional rules generated, going from 105360 with 6 entities to more than 2 millions with 10 entities. Generating and evaluating such high number of rules also leads to a high reasoning time, taking 591ms with 6 entities and more than 30s with 10 entities. This leads the naive propositionalization to require more memory than available with more than 10 entities.

For typed propositionalization, we see that the number of propositional rules is always 300, thanks for our approach using placeholders which always produces one propositional rule per SWRL rule. Even if the number of propositional rules does not change, we observe that the reasoning time increases exponentially with the number of entities. This is due to the evaluation of the rules needing to be repeated for each possible assignment of entities to the placeholders. Despite the exponential increase of the reasoning time, our proposed approach allows to obtain runtimes that are appropriate for real-time reasoning, reaching only 122ms with 20 entities.

These results show that it is possible to convert rules for ontology reasoning into the format of decision tables. With typed propositionalization, little memory is required to store the rules in propositional form and the reasoning remains fast enough for real-time decision making in situations of medium complexity (up to 20 entities).

*1 http://ri-www.nii.ac.jp/ADAS/index.html

6. Conclusion and Future Works

Reasoning with ontologies is a complex problem which can limit its use with real-time applications. In this paper, we proposed a typed propositionalization technique to efficiently represent ontology rules as decision tables, allowing a faster reasoning better suited for real-time applications. Our experiments showed that our proposed approach leads to a much better reasoning time and memory complexity compared to a naive approach.

In future works, we will extend our technique to also define placeholders based on some relations, in addition to using the classes of the variables. Furthermore, we plan on studying ways to compress and decompose the rules once in propositional form. We believe methods based on Binary Decision Diagrams [Akers, 1978] or Zero-Suppressed Decision Diagrams [Minato, 1993] to be the most promising.

Acknowledgements

This work was partially supported by the New Energy and Industrial Technology Development Organization (NEDO).

References

[Akers, 1978] Akers, S. B. (1978). Binary decision diagrams. *IEEE Transactions on computers*, (6):509–516.

[Consortium, 2014] Consortium, G. O. (2014). Gene ontology consortium: going forward. *Nucleic acids research*, 43(D1):D1049–D1056.

[Grau et al., 2008] Grau, B. C., Horrocks, I., Motik, B., Parsia, B., Patel-Schneider, P., and Sattler, U. (2008). Owl 2: The next step for owl. *Web Semantics: Science, Services and Agents on the World Wide Web*, 6(4):309–322.

[Hashimoto et al., 2017] Hashimoto, K., Ishida, Y., Ichise, R., Wagatsuma, H., and Tamukoh, H. (2017). A fundamental study on the performance of the logical reasoning system by using the semantic web techniques when it is applied to real vehicle automated driving to detect possible dangers predictively. In *Proceedings of the 61st Annual Conference of the Institute of Systems, Control and Information Engineers*, volume 324, pages 681–684. In Japanese.

[Horridge and Bechhofer, 2011] Horridge, M. and Bechhofer, S. (2011). The owl api: A java api for owl ontologies. *Semantic Web*, 2(1):11–21.

[Horrocks et al., 2004] Horrocks, I., Patel-Schneider, P. F., Boley, H., Tabet, S., Grosof, B., Dean, M., et al. (2004). Swrl: A semantic web rule language combining owl and ruleml. *W3C Member submission*, 21:79.

[Kang et al., 2014] Kang, Y.-B., Pan, J. Z., Krishnaswamy, S., Sawangphol, W., and Li, Y.-F. (2014). How long will it take? accurate prediction of ontology reasoning performance. In *Proceedings of the 28th AAAI Conference on Artificial Intelligence*, pages 80–86.

[Krogel et al., 2003] Krogel, M.-A., Rawles, S., Železnỳ, F., Flach, P. A., Lavrač, N., and Wrobel, S. (2003). Comparative evaluation of approaches to propositionalization. In *Proceedings of the 13th International Conference on Inductive Logic Programming*, pages 197–214. Springer.

[Middleton et al., 2004] Middleton, S. E., Shadbolt, N. R., and De Roure, D. C. (2004). Ontological user profiling in recommender systems. *ACM Transactions on Information Systems (TOIS)*, 22(1):54–88.

[Minato, 1993] Minato, S.-i. (1993). Zero-suppressed bdds for set manipulation in combinatorial problems. In *Proceedings of the 30th international Design Automation Conference*, pages 272–277. ACM.

[Motik et al., 2009] Motik, B., Patel-Schneider, P. F., Parsia, B., Bock, C., Fokoue, A., Haase, P., Hoekstra, R., Horrocks, I., Ruttenberg, A., Sattler, U., et al. (2009). Owl 2 web ontology language: Structural specification and functional-style syntax. *W3C recommendation*, 27(65):159.

[Shearer et al., 2008] Shearer, R., Motik, B., and Horrocks, I. (2008). Hermit: A highly-efficient owl reasoner. In *OWLED*, volume 432, page 91.

[Sirin et al., 2007] Sirin, E., Parsia, B., Grau, B. C., Kalyanpur, A., and Katz, Y. (2007). Pellet: A practical owl-dl reasoner. *Web Semantics: science, services and agents on the World Wide Web*, 5(2):51–53.

[Staab and Studer, 2010] Staab, S. and Studer, R. (2010). *Handbook on ontologies*. Springer Science & Business Media.

[Zhao et al., 2017] Zhao, L., Ichise, R., Liu, Z., Mita, S., and Sasaki, Y. (2017). Ontology-based driving decision making: A feasibility study at uncontrolled intersections. *IEICE Transactions on Information and Systems*, E100.D(7):1425–1439.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

クラウドソーシングを利用した 非同期チャットによる対話シナリオ収集方式の提案

Asynchronous Chat System for Dialogue Collection on Crowdsourcing

池田 和史[*1]
Kazushi Ikeda

帆足 啓一郎[*1]
Keiichiro Hoashi

[*1] KDDI 総合研究所
KDDI Research, Inc.

In this paper, we design a crowd-powered system to efficiently collect data for training dialogue systems. Conventional systems assign dialogue roles to a pair of crowd workers, and record their interaction on an online chat. In this framework, the pair is required to work simultaneously, and one worker must wait for the other when he/she is writing a message, which decreases work efficiency. Our proposed system allows multiple workers to create dialogues in an asynchronous manner, which relieves workers from time restrictions. We have conducted an experiment using our system on a crowdsourcing platform to evaluate the efficiency and the quality of dialogue collection. Results show that our system can reduce the necessary time to input a message by 68% while maintaining quality.

1. はじめに

Siri や Google Assistant などの対話エージェントは，高度化するシステムの入力インターフェースとして重要性を高めている[McTear 2002]. 一部の人手によるエージェントシステム[Lasecki 2013a, Huang 2016]を除いて，多くの対話エージェントシステムは，事前に作成したルールに基づいて応答したり [Weizenbaum 1966, Bennacef 1996] ，機械学習によって応答を決定する[Raymond 2007, Henderson 2013]. そのため，網羅的かつ正確な対話を実現させるためには，想定される対話のやり取り(シナリオ)を記述した大規模な文章データ(コーパス)が必要となる.

質問応答システムのように既存のデータをコーパスとして利用できる場合もあるが[Kiyota 2002]，雑談のような一般的な対話を行うには網羅性の観点で課題がある. 適切な応答が既存のコーパス中に見つからない場合，クラウドソーシングなどを利用して不足するシナリオを補う処理が必要となる[Bessho 2012].

クラウドソーシングで募集した 2 名のワーカペアにチャットを行わせることで，コーパスを構築する手法[Lasecki 2013b, Tsukahara 2015]が提案されている. 用途に応じた高品質なシナリオを構築可能なメリットがある一方，2 名のワーカが同時刻に作業をする必要があるという時間的な拘束や，相手の入力中はワーカが待ち状態になるという効率面での課題があった. 所要時間の削減はコストの削減に重要であり[Krishna 2016]，時間単価が上がれば多くのワーカを獲得できる [Mason 2009].

我々はクラウドソーシングに適した対話コーパスの構築システムを設計した. 提案システムでは，従来と同様にチャット形式でシナリオを入力するが，同一のシナリオを複数人で非同期に作成することが可能なため，ワーカを拘束する必要がなくなり，作業効率を向上させることが可能となる.

提案システムの有効性を確認するため，シナリオ作成の所要時間やコストといった効率，および作成されたシナリオにおける話題の多様性や会話のしやすさといった品質について評価した. 提案システムは，既存の 2 名のペアにチャットを行わせる方式と比較して，同程度の品質を保ちつつ，作成に要する時間を68%削減することが確認された.

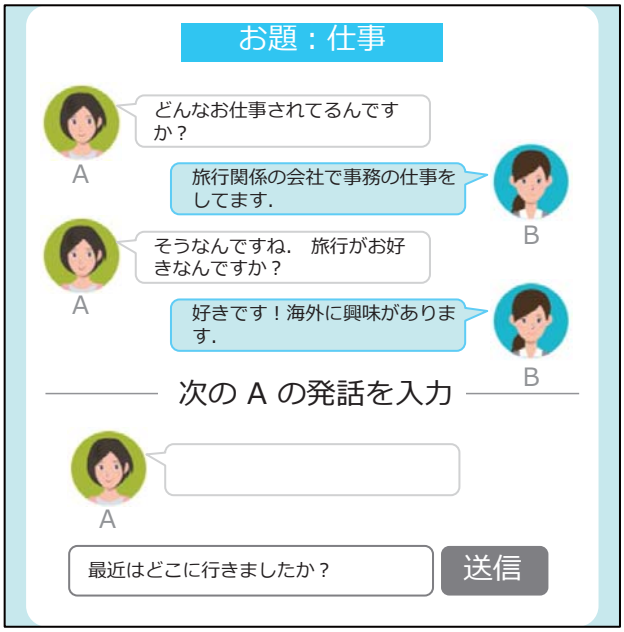


図 1 提案システムのインターフェース

2. 提案手法

本稿で提案するシナリオ作成システムの画面を図 1 に示す. チャット形式のインターフェースに 1 つのシナリオが表示される. 従来手法では 2 名のワーカがペアとなって会話を行うことでシナリオを構築する. 提案手法では，クラウド上の複数のワーカを 2 名の発話者(図 1 の A または B)のいずれかに割り当てる. ワーカがタスクを実施するためにシステムにアクセスすると，途中まで入力された会話が提示される. 図 1 では，役割 A のワーカがシステムにアクセスしている.「仕事」というテーマで A と B がそれぞれ 2 発話を入力しているが，この 4 発話はそれぞれ別の

ワーカが入力したものである. ワーカはこれまでの発話の流れを読んだ上で, 次の発話を入力し, 送信を押す. 入力が完了すると, ワーカには次の別のシナリオが提示される. これを繰り返すことで, ワーカは相手の発話を待つことなく, 次々とシナリオを入力することが可能となる.

シナリオにおける発話が長くなるにつれて, 過去の会話を確認するために要する時間が増加することが想定される. 会話の流れを把握するために必ずしも全ての発話を提示する必要はないため, 直近 N 件の発話(例えば図 1 の場合は 4 件)を提示するものとし, 最適な N の値については実験により評価する.

3. 実験設計

提案手法の有効性を評価するため, クラウドソーシング上で対話シナリオを構築する実験を行う. 以下ではシナリオ作成タスク, 比較手法, 評価指標, ワーカについて説明する.

3.1 シナリオ作成タスク

本稿では, ユーザとの雑談が可能な対話システム用のシナリオ作成を目的とする. 雑談を行う上では, 話題や対話システムの属性(見た目が人間風かロボット風か, など), ユーザとの関係性などを具体化する必要がある. これらは対話システムのコンセプトや利用シーン, 想定するユーザに応じて決定される. 一例として本実験では, 女性のユーザを想定し, ユーザと親しく会話が可能な, 女性の見た目を持つ対話システムをデザインする.

このような対話システムに適したシナリオを収集するため, 知人程度の関係の女性同士で, お互いに良好な関係を構築したい, という設定で 2 名の女性の役割をワーカに割り当てる. 対話システム役は, 年齢, 性別, 家族構成, 職業など 75 項目からなる詳細なペルソナを設定し, ワーカはその役割になり切って会話を行う. ユーザ役は, 同世代の女性という設定のみとし, 会話する上で属性情報が必要となる場合は, ワーカの属性を基準とするよう指示する. これにより, 属性の異なるユーザを想定した対話シナリオを収集できる. また, このような関係においてよく話される話題を 4 名の女性の被験者から募集し, 代表的な 50 のテーマ(休日の過ごし方, 好きなスポーツ, 料理など)について, 30 シナリオずつ, 計 1500 シナリオを構築する.

雑談では, 完了状態を明確に定義することは困難なため, 作成するシナリオの長さは固定長で 16 発話とする. 各発話の入力文字数は 10 文字以上とし, 既存の Web 文章のコピーを行わないこと, などその他の詳細な条件をワーカに指示する.

3.2 比較手法

提案手法と従来手法の比較評価を行う. 加えて, ワーカが一人で二人分の発話を入力する手法も考えられる. これを参考手法と呼び, 提案手法, 従来手法と参考手法の 3 条件で評価を行う. 各手法の特徴を表 1 に示す.

従来手法は, 二人のワーカがペアとなり, 同期して作業を実施する. 各ワーカは役割 A または役割 B のいずれかが割り当てられる. 報酬は待ち時間に対する固定報酬と, 1 発話を入力するごとに出来高報酬が提供される.

提案手法では各ワーカは非同期的にシナリオを入力する. 各ワーカは役割 A または役割 B のいずれかが割り当てられる. 報酬は出来高報酬のみを提供する. 過去 N 発話を表示するが, N=2,6,16 の 3 条件について評価を行う.

参考手法では各ワーカは非同期的にシナリオを入力する. 各ワーカは役割 A と役割 B の両方を実施し, 1 つのシナリオに対して連続して 16 発話分の入力を行う. 報酬は出来高の報酬を提供する.

表 1 比較手法の特徴

手法	同期/非同期	役割	報酬
従来	同期	A または B のいずれか	固定報酬 4 円/分 出来高報酬 4 円/発話
提案	非同期	A または B のいずれか	出来高報酬 4 円/発話
参考	非同期	A と B の両方	出来高報酬 4 円/発話

3.3 評価指標

シナリオ作成の効率とシナリオの品質について評価を行う. 効率の指標として, 1 発話当たりの入力に要する時間を評価する. 従来手法では, 相手の待ち時間を含める. 加えて, 待ち時間に対する報酬を含めた 1 発話当たりのコストを評価する.

品質の指標として, 発話長とシナリオの情報量, 一貫性, 回答しやすさを評価する. 発話長は最低 10 文字以上と指定しているが, ワーカが作業を短時間で終わらせるために, 短い文章を入力する可能性がある. 情報量については, 相槌ばかりの文章や同一の発話を繰り返すよりも, より多様な話題を取り入れた会話が望ましい. シナリオの形態素解析を行い, 一定量の形態素中に含まれる形態素の種類数に基づいて情報量を評価する. 一貫性はシナリオ内の前後の発話に矛盾がないか, 担当する役割のペルソナと比べて矛盾がないか, を 4 名のアノテータに評価させる. 回答しやすさは, システムとの対話を活性化させる上で重要な指標である. シナリオの一部をアノテータに提示し, 次の発話の入力しやすさを 5 段階で評価させる.

3.4 ワーカ

従来手法, 提案手法(N=2,6,16 の 3 条件), 参考手法の計 5 条件について, それぞれ 60 名の参加者を国内の大手クラウドソーシングサイトで募集した. 設定した役割とワーカの属性を合わせるため, 20 代～40 代の女性を募集した. 従来手法と提案手法では, 役割 A に 30 名, 役割 B に 30 名をそれぞれ割り当てた. ここで, 従来手法はワーカがペアを構築する必要があり, 24 時間作業可能な状態では, ワーカのシステムへのアクセスが分散し, 待ち時間が増加することが懸念される. このため, 作業時間を 12 時～15 時に限定した. 実験期間は 2 週間とした.

4. 実験結果

4.1 効率

ワーカ当たりの 1 発話の平均入力時間を表 2 に示す. 従来手法における平均入力時間は 133 秒であった. 提案手法では, 平均入力時間は N の値によって異なり, N=16 の時は 52 秒, N=2 および N=6 の時は, 42 秒であった. 参考手法の平均入力時間は 29 秒であった. 従来手法では, 2 名のワーカがペアで作業をするため, 1 名のワーカがシナリオを入力する時間を t 秒とすると, もう 1 名の待ち時間 t 秒が加算され, 計 2t 秒を要する. この点を考慮しても, 従来手法は提案手法の N=2,6 や参考手法と比較して, 3 倍以上の時間を要している.

Kruskal-Wallis test を用いた有意検定において, 比較した 5 条件間で平均入力時間に有意差が確認された($H=7407$, $p<.01$). ${}_5C_2$ 通りの条件間の組み合わせに対し, Bonferroni 法を用いた名義的有意水準($\alpha'=.005$)において, Wilcoxon rank sum test による有意検定を実施したところ, 入力数 n が十分に大きいため, 全ての条件間で有意差が確認された. 以降, 表中で有意差を示している項目については同様の方法で有意検定を実施した.

表 2 ワーカ当たりの平均入力時間

	平均 (秒)	標準偏差	件数 *n*	p 値
従来	133	124	16,704	
提案(N=16)	52	51	22,500	
提案(N=6)	42	43	22,500	$2.2e^{-16}$ **
提案(N=2)	42	47	22,500	
参考	29	38	21,447	

表 3 作成された発話数, シナリオ数と費用(円)

	発話数	シナリオ数	総費用	総費用/発話数
従来	16,704	1,058	175,148	10.5
提案(N=16)	22,500	1,500	90,000	4
提案(N=6)	22,500	1,500	90,000	4
提案(N=2)	22,500	1,500	90,000	4
参考	21,447	1,500	85,788	4

表 4 平均発話長

	平均 (文字)	標準偏差	件数 *n*	p 値
従来	28.3	12.9	16,704	
提案(N=16)	24.2	10.2	22,500	
提案(N=6)	20.7	7.7	22,500	$2.2e^{-16}$ **
提案(N=2)	22.3	8.9	22,500	
参考	19.2	10.5	21,447	

表 3 は作成された発話数, シナリオ数, 総費用, 発話当たりの費用を表す. 提案手法と参考手法では, 2 週間の実験期間内に 50 トピックについて各 30 シナリオを構築することができた. 従来手法では, 作業時間を限定したために, 一部のシナリオは期間内に完成しなかった. 従来手法における 1 シナリオ当たりの待ち時間の平均は 93 秒であった. これに加えて, 相手の入力を待つ時間に対しても 1 分当たり 4 円の報酬が提供されるため, 発話当たりの報酬は平均で 10.5 円となった. 出来高報酬が 4 円であることと比較すると, 高コストといえる.

4.2 品質

表 4 は平均発話長を表す. 従来手法が最も長く 28.3 文字, 参考手法が最も短く 19.2 文字であった. 参考手法では, N の値による顕著な傾向は見られず, 従来手法と参考手法の中間であった.

表 5 は各手法で作成されたシナリオの情報量と一貫性の欠如率を表す. 情報量はシナリオ中の 10 万形態素あたりに出現する形態素の種類数を算出しており, 参考手法が少ない値となった. 参考手法では, 相槌のみの発話や指定されたトピックから逸脱して, 他のトピックと同じ内容を使い回すワーカも見られた.

一貫性の欠如については, 提案手法の N=2 や参考手法でやや増加する傾向が見られた. 前後の文脈と矛盾する場合と, 設定したペルソナと矛盾する場合に分けてアノテーションを実施しており, 提案手法(N=2)では前者が, 参考手法では後者が多く見られた. 提案手法(N=2)では発話の文脈が十分に提示されないために矛盾が生じたと考えられる. 参考手法では, ワーカが一人二役を担うため, 混乱した可能性がある.

表 6 はシナリオの回答しやすさを表す. 各手法で作成したシナリオからランダムに 100 件を選択し, 各シナリオの最初の発話から途中の発話までを 4 名のアノテータに提示し, 次の発話の入力の容易さを 5 段階で評価させた. 参考手法において, 平均スコアの低下が確認された. 参考手法のシナリオを確認したところ, 作成したワーカ以外には継続が困難なシナリオが見られた.

表 5 形態素の種類数(情報量)と一貫性欠如率

	形態素の種類数	一貫性欠如率
従来	1,752	0.07
提案(N=16)	1,759	0.09
提案(N=6)	1,708	0.03
提案(N=2)	1,731	0.14
参考	1,583	0.12

表6 回答のしやすさ

	平均	標準偏差	件数 *n*	p 値
従来	3.13	1.28	400	
提案(N=16)	3.18	1.17	400	
提案(N=6)	3.10	1.20	400	$2.2e^{-16}$ **
提案(N=2)	2.93	1.06	400	
参考	2.79	1.31	400	

5. 考察

提案手法における N の最適値については, N=2, 6 と比べて N=16 の入力時間が増加した. これは過去の発話を読むために時間を要したためと考えられる. 効率面では N=2, 6 が有望であるが, 品質面では N=2 において, 一貫性が低下する課題が見られた. 総合的に判断すると, N=6 が最適と考えられるため, 以降は提案手法(N=6)について考察を行う.

効率面では, 提案手法は従来手法と比較し, 所要時間を 68%, コストを 62%削減可能であることが確認された. これは, 相手の入力を待つ時間を削減したことによる効果が大きい. 実験後に各手法を担当したワーカに(1)報酬の満足度, (2)作業を楽しいと感じたか, (3)もう一度同じ作業を受託したいかをアンケートにより 7 段階で回答させた. 表 7 に回答をまとめる. 提案手法および参考手法における報酬の満足度および再受託を希望する度合いは従来手法よりも高いことが確認された. 本結果は, 提案手法で作業を実施したワーカは十分な報酬を得たと感じていることを示しており, 報酬単価をさらに下げることや従来手法よりも多くのワーカを参加させることも可能と考えられる.

品質面では, 参考手法は情報量や回答しやすさといった対話シナリオに重要な指標において, 従来手法よりも品質の劣化が確認された. 提案手法では, 発話長を除いて従来手法と同等の品質が得られていることが確認された. 表 8 に各手法で作成されたシナリオの例を示す. 従来手法では, 役割 B の 3 発話目において, 直前の発話をさらに掘り下げる発話が見られた. 従来手法では, 同じワーカペアが会話を行うため, 前の発話の情報を補足するような発話が見られた. また, リアルタイムに会話を行うため, 相槌などが多くなる傾向も見られた. 提案手法では, 過去の発話を踏まえた発話が行われるが, 背景となる情報を他のワーカと共有できていないため, 過去の発話を掘り下げるような発話はあまり見られなかった. これらの点が発話長に影響したと考えられる.

一方, 参考手法では, 10 文字以上の制約を満たすために不要な相槌を入力したり, 指定されたトピックを逸脱して同じシナリオを繰り返して入力するワーカが複数見られた. 従来手法や提案手法のように他者との協調作業ではないため, 他者が回答しやすい内容や自然な会話を行うといった意識が低下したものと思われる. ワーカが作業時間を短縮するために入力パターンを定型化した結果, 情報量の欠如や他者にとって回答しにくいシナリオが作成されるといった致命的な問題を発生させている.

表 7　ワーカへのアンケート結果

	従来	提案	参考	p 値
報酬の満足度	**4.63**	**4.99**	**5.45**	**0.047***
作業の楽しさ	5.88	5.92	6.11	0.892
再度受託したい	**6.22**	**6.54**	**6.70**	**0.042***
件数 n	32	39	44	

表 8 トピック「好きな街」で作成されたシナリオの例

従来手法で作成されたシナリオ

A: いつもどのあたりで買い物しますか？
B: だいたいは，勤務先の品川か地元横浜ですねぇ
A: 好きなお店があるのですか？？
B: 服でいえばアースミュージックエコロジーが好きですねっ
A: 私はファッションのことに疎いのですが，どんな系統のファッションですか？
B: ん～～なんていうんだろう‥どんな場所でも対応できるような清楚というかそういった服装です 笑
A: 清楚女子憧れますね～！！何処でも対応できるのは便利ですしね！私はいつもネットで服を買っているので‥
B: ネットでどういった服を買ってらっしゃるんですか？

提案手法で作成されたシナリオ

A: いつもどのあたりで買い物しますか？
B: 勤務先の品川あたりが多いです．
A: そうなんだ．品川辺りでオススメのショップは？
B: 好みがありますからね．何処のお店も良いですよ！
A: そうなんですね．品川はオフィス街のような認識でした．
B: 私も最近は仕事終わりにブラブラしたりしています．
A: 仕事帰りにブラブラできていいですね．私は最近忙しくって．
B: 駅ビルが充実してるので，フラっと行けるのが気楽でいいんですよね．

参考手法で作成されたシナリオ

A: いつもどのあたりで買い物しますか？
B: その時によりますねー
A: へぇ．そうなんですね?
B: A さんはどうですか？
A: 私も似たような感じです
B: なるほど．そうなんですね
A: そうなんですよね?.
B: 私たち，気があいますね

6. まとめと今後の課題

本稿では，クラウドソーシングを利用して効率的に対話シナリオを作成する方式を提案した．従来のリアルタイムチャットによるシナリオ作成手法では，ワーカを時間的に拘束することが課題であった．これに対し，提案方式では同一のシナリオを複数人で非同期に作成可能とすることで，作業効率を向上した．実験の結果，提案手法は方式と同程度の品質を維持しつつ，所要時間を 68%，コストを 62%削減可能なことを確認した．

今後の課題として，他のワーカの作業状況を引き継ぐ仕組みの導入を検討している．これにより，より踏み込んだ内容の雑談や，タスク型の対話シナリオの作成など，多様なシナリオの作成に本システムの適用が可能になると考えられる．

参考文献

[Bennacef 1996] Bennacef, S., Devillers, L., Rosset, S., and Lamel, L.: Dialog in the RAILTEL Telephone-Based System. In Proceedings of ICSLP, pp. 550-553, 1996.

[Bessho 2012] Bessho, F., Harada, T., and Kuniyoshi, Y.: Dialog System Using Real-Time Crowdsourcing and Twitter Large-Scale Corpus. In Proceedings of the 13th Annual Meeting of the Special Interest Group on Discourse and Dialogue, 227-231, 2012.

[Henderson 2013] Henderson, M., Thomson, B., and Young, S. J.: Deep Neural Network Approach for the Dialog State Tracking Challenge. In Proceedings of SIGDIAL Conference, 467-471, 2013.

[Huang 2016] Huang, T. H. K., Lasecki, W. S., Azaria, A., and Bigham, J. P.: "Is There Anything Else I Can Help You With?" Challenges in Deploying an On-Demand Crowd-Powered Conversational Agent. In Proceedings of the Fourth AAAI Conference on Human Computation and Crowdsourcing, 2016.

[Kiyota 2002] Kiyota, Y., Kurohashi, S., and Kido, F.: Dialog Navigator: A Question Answering System based on Large Text Knowledge Base. In Proceedings of the 19th International Conference on Computational Linguistics, 1: 1-7, 2002.

[Krishna 2016] Krishna, R. A., Hata, K., Chen, S., Kravitz, J., Shamma, D. A., Fei-Fei, L., and Bernstein, M. S.: Embracing Error to Enable Rapid Crowdsourcing. In Proceedings of the 2016 CHI Conference on Human Factors in Computing Systems, 3167-3179, 2016.

[Lasecki 2013a] Lasecki, W. S., Wesley, R., Nichols, J., Kulkarni, A., Allen, J. F., and Bigham, J. P.: Chorus: A Crowd-Powered Conversational Assistant. In Proceedings of the 26th Annual ACM Symposium on User Interface Software and Technology, 151-162, 2013.

[Lasecki 2013b] Lasecki, W. S., Kamar, E., and Bohus, D.: Conversations in the Crowd: Collecting Data for Task-Oriented Dialog Learning. In Proceedings of the First AAAI Conference on Human Computation and Crowdsourcing, 2013.

[Mason 2009] Mason, W., and Watts, D. J.: Financial Incentives and the "Performance of Crowds". In Proceedings of HCOMP, 77-85, 2009.

[McTear 2002] McTear, M. F.: Spoken Dialogue Technology: Enabling the Conversational User Interface. ACM Computing Surveys (CSUR), 34(1): 90-169, 2002.

[Raymond 2007] Raymond, C., and Riccardi, G.: Generative and Discriminative Algorithms for Spoken Language Understanding. In Proceedings of Interspeech, 1605-1608, 2007.

[Tsukahara 2015] Tsukahara, H., and Uchiumi, K.: System Utterance Generation by Label Propagation over Association Graph of Words and Utterance Patterns for Open-Domain Dialogue Systems. In Proceedings of 29th Pacific Asia Conference on Language, Information and Computation, 323-331, 2015.

[Weizenbaum 1966] Weizenbaum, J.: ELIZA—A Computer Program for the Study of Natural Language Communication between Man and Machine. Communications of the ACM, 9(1): 36-45, 1966.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

視点依存オープンデータの大規模作成支援ツール

A data editing support tool for large-sized ontology data with context dependency

桝屋 啓志[*1]
Hiroshi Masuya

古崎 晃司[*2]
Koji Kozaki

溝口 理一郎[*3]
Riichiro Mizoguchi

[*1] 理研バイオリソース研究センター
RIKEN BioResource Research Center (BRC)

[*2] 大阪大学産業科学研究所
The Institute of Scientific and Industrial Research (ISIR)
Osaka University

[*3] 北陸先端科学技術大学院大学
Japan Advanced Institute of Science and Technology

We developed a software tool to supprt editing of large-sized data with highly structured data schema representing context dependency of ontology concepts. The software tool provides functions of bulk editing of Hozo-formatted ontology data with spreadsheet program like operation. This tool is also useful for ontology refinement to improve consistency of data structure from upper classes to instances. As the recent progress of open data activity, improvement of data access methodologies to extremely large-sized and variety of open data becomes expected. This study provide a methodology of the efficient construction of large-sized data with complicated structure such as context dependency and viewpoint conversion, which may contribute to improve utility of open data across domains.

1. はじめに

近年、情報のオープン化,ビッグデータ化が進み,RDF やセマンティック Web 技術をはじめ,多種多様な情報へのアクセスを改善するための技術ニーズが高まっている。生命科学分野では、遺伝子オントロジー(Gene Ontology: GO)をはじめとして、概念を共通語彙として共通利用する仕組みを整えたことで,情報統合が大きく加速した。

一方で,分野を超えて知識を共有するためには,GO を含め,いわゆる「ライトウェイトオントロジー」の一義的なツリーによる知識の構造化では限界がある。例えば、生物体の中では、特定の分子が,細胞接着,シグナル伝達、ほかの分子活性の抑制、活性化など、様々な役割を担っている。このような分子を分類する際に、化合物の組成や分子構造に基づいた基本的な分類の他に、生体内の役割に基づいた分類(あるいは役割の分類)を扱うことができなければ、生物内における分子機能の記述は難しい。他の例では,数値データを知識として共有化する際の定性値化において,目的設定に対応した(コントロールの違いによる)データ解釈の違いをどのように処理するかが課題となる。

このような処理は、「考え方や視点の違い」による分類の多重化や、知識表現の「視点転換」と呼べるであろう。今後,オープンデータの大規模化・多様化が進み、多種多様なデータを用いた知識抽出のニーズが高まると考えられるが、異なる視点で作成されたデータを統合することができれば,知識の相互利用をさらに進めることができると期待される。

この問題を解決するため, 我々は「役割(ロール概念)」をオントロジーに導入する溝口らの理論 [溝口 2004] を応用した研究を行なってきた。ロール理論では,オントロジーの分類ツリーを利用しながら,外的状況(コンテキスト)と,コンテキスト内での役割概念の導入により,体系的な「視点の転換」によってオントロジー概念の再利用性を大きく高めることが可能である。ロール理論に基づくオントロジーは, オントロジーエディタである「法造」(http://www.hozo.jp) [古崎 2007] を用いることで視覚的に確認しながら構築できるため, これまで我々はクラスレベルの構造の設計には法造を用いてきた。

また, 先行研究では、性質値記述の理論に従って記述された計測データのインスタンスを対象にして、「考え方や視点の違い」に基づいた情報の提示方法を提案した。これは、上記のクラス構造に準じて記述されたインスタンスについて、法造におけるツリーを基盤とした概念表現を保管する意味で, 表によるインスタンス表示を導入した。かつ, コンテキストを選択することで、そのコンテキストに依存する性質値のみを表示するアプリケーションを開発した[桝屋 2013, 2015]。これにより, 多様な視点に依存して作られた大規模データから、視点に応じたデータの選別の方法、およびデータの表現方法を提案した。

しかしながら、このような高度に構造化されたデータ記述における大きな問題は, 視点依存のクラス構造を定義するプロセスよりも、複雑なクラス構造に準じたインスタンスを大規模に作成する煩雑さであった。しかも,インスタンス作成時に、クラス構造側のエラーや、洗練化を行わねばならない場面も多く見られた。

本研究では、クラスレベルの修正と洗練化と,インスタンス作成を行き来しながら、大規模データを作成できるような支援ツールの作成を試みたので報告する。

2. アプリケーションの要件

本支援ツールの目的は, 視点依存のデータ構造を,ロール概念を用いて記述できる法造形式のインスタンスデータを、バルクで効率良く作成できることである。また,上記のクラス構造の洗練化を同時に行うことを考えると、法造アプリケーションとの連携が容易に行えることが望ましいと考えた。よって、本支援ツールは法造アプリケーションから呼び出して利用できるツールとし,法造のデータ編集を強化するような位置づけで開発することとした。

バルク編集機能は, いわゆる表計算ソフトのように,関連するデータ間の整合性を目で確認でき、ある程度の一括編集が可能になることを目指した。法造の概念は、概念と, “ロール概念”、”個数制約”, “クラス制約”, “ロールホルダー”などの「スロット」と

連絡先:桝屋啓志, 理化学研究所バイオリソース研究センター, 茨城県つくば市高野台 3-1-1, hirshi.masuya@riken.jp



図 1 支援ツールのインターフェース （表編集画面）を法造から呼び出したところ

呼ばれるフィールドの組み合わせで表現されるので、これらのスロット毎に個別の表を表示して編集するコンセプトとした。

本支援ツールにおいて，インスタンスのバルク編集と，クラス構造の洗練化を同じ操作感で扱えることを目指した。つまり，同じクラスに属するインスタンス間でのスロット内容の整合性をと作業と、クラス階層におけるスロット内容の整合性をとる作業を，同じ感覚で同時に行えることを目指した。これにより，インスタンスデータ作成および編集と，クラス階層の洗練化を一度に行えることを目指した。

3. アプリケーション機能の概要

本支援ツールは、法造アプリケーションのオントロジーツリー画面より、編集対象としたい範囲を指定して起動できる仕様となっている。この「表画面を開く」メニューからは、ある階層より下のインスタンスレベルまでを編集する目的での「下位概念を全て開く」と，中間概念のクラス構造洗練化に用いるために、下位概念を指定してから上位概念を指定してその範囲を開く「上位概念を指定して開く」の 2 つが利用できる。

表画面の概要を図 1 に示す。いわゆる Tree table 型の表示となっており、左側のペインに概念階層ツリーを示し、右側のペインにツリーに対応した表が表示される。（つまり、概念およびインスタンスが縦方向に並ぶ。）表ペインにおいて，概念あるいはインスタンスにスロットがある場合は、スロットが横方向に並んでレイアウトされる。この表の上である程度の一括編集が可能である。現時点では下記が利用可能である。

- セルを範囲指定してコピー
- セルを範囲指定してペースト（選択範囲の右上を指定）
- セルを範囲してしてスロット定義および削除

上側のペインでは、表ペインに表示するスロットの種類、法造上で定義されているメイン言語、サブ言語の切り替えができる。

4. 本支援ツールを用いた大規模編集の試行

開発した支援ツールを用いて、先行研究で作成した，異なる実験動物であるマウス，ラットにおける表現型計測データ（8171 データポイント）の読み込みおよび編集を試行した。本データでは、異なる動物種に属する多様な系統に対して，様々な計測データ（体長，体長，外見観察血液検査等）を行なっており、生物種、および測定方法というコンテキストの違いによる判定基準値の違いを、ロール概念を用いてとして明示的に表現することを目的に作成したものである。

このデータを本支援ツールで読み込んで表示させたところ、マウスとラットにおける測定項目の一致と不一致，また、各スロットに付与した文言の不一致等が容易に確認でき，表計算ソフトに近い操作によって，容易に整合性の高いデータを作成することができた。スロットの継承関係は先行研究において,注意深く確認を行っていたため不整合は見つからなかったが，もし不整合があったとしても，容易に修正が可能であったと思われる。

5. 考察と今後の課題

本研究では，コンテキスト依存性の記述や視点転換に対応しうるデータ構造に基づく大規模データを効率的に作成，編集，メンテナンスを効率的に行う目的で、法造形式データを表インターフェースで取り扱うデータ編集支援ツールの開発を試みた。

コンテキスト依存性の記述は、分野横断的に知識を扱う上で普遍的な課題であると考えられる。 今後オープンデータの多様性や分野横断的な利用ニーズの高まりに伴い，このような複雑なデータをいかにハンドリングするかが課題になると考えられる。

5.1 オントロジーを「表」で表現することの課題

本研究では、オントロジーとして高度に構造化されたデータをバルクで編集できることを目指して、法造アプリケーションでは

概念分類ツリーと, 概念に付加されたスロットで表現されているデータを、表型式に落とし込み、その上で、読み出し、データ追加、編集、保存を整合性を持って機能するよう実装を行った。しかしながら、極めて柔軟性の高い法造データを表形式に表現することには限界があり、アプリケーション機能に制限が生じる場合があった。ここではその課題について述べる。

法造において、あるコンテキストに依存する概念(ロール概念)を記述する際には、コンテキストである概念の下に、ロール概念のスロットを付加して表現する。スロットに付くスロット(子スロット)を書くことで、多重にコンテキストに依存する概念を記述することも可能である。さらに、このスロットが付加された構造を下位概念に継承することができるが、このスロットの継承関係も極めて柔軟に記述することができる。

本支援ツールにおいて、スロットの継承関係は、表画面の「列」を用いて表現するようにデザインした。原則的に、セルの縦並びは、概念、またはスロットの継承関係を示している。

しかし、法造自体では、継承関係の分岐や、スキップ、任意の概念からのスロット継承など、表画面では記述の難しい継承関係を自由に作成することができる。このような継承関係のデータを表画面に読み込んだ場合、わかりにくいあるいは誤解を招くような表示にならざるを得なかった。

このような場合に対処するために、我々はすでに法造アプリケーションで実装されている, 上位スロットおよび下位スロットをハイライトする機能を表画上で実装した。

5.2 本ツールを通じたオントロジー洗練化

オントロジーの洗練化に関しては、文法規則に関するエラーの修正、定義内容の観点から様々な検討が行われている。増田らは、上位関係や参照被参照などのオントロジーの構造情報を元にした洗練システムを提唱している[増田 2017, 2018]。このシステムでは、上位概念で定義されたスロットが整合性を持って下位概念に継承されるように編集を促す機能が実装されている。

本支援ツールでは、上位概念から下位概念へのスロットの継承が、表の列に並んで表現され、中間概念のスロットの欠如もグレー表示によって表示されるため、この種の洗練化を目で確認しながら編集できるメリットがある。しかも、表計算ソフトのように複数セルへのコピーペーストが可能なので、継承関係のみならず、各スロットに記入する文言レベルでの整合性を容易にとることが可能である。上に述べたように、表インターフェースを採用したが故の制限があるものの, ある程度の複雑さの範疇であれば、オントロジーの洗練化作業を容易に行えた。

5.3 オープンデータへの展開

オントロジーの記述も含め、オープンデータの世界標準となりつつある Resource Description Framework (RDF)では, 表インターフェースを備えた編集ツールは複数提供されている。しかしながら、rdf:propety(本ツールではスロットに相当)の継承関係を踏まえた洗練化を行えるソフトは見当たらない。

また、本ツールは、コンテキストに依存した概念や, 視点転換を含めたオントロジーの編集を目的としているため, 子スロット, 孫スロットのあるようなオントロジーを主な対象としているところも特徴である。RDF におけるコンテキスト依存性の記述は、RDF に基づくオントロジー言語である Web Ontology Language (OWL)に準じた記述となるが、OWL によるコンテキスト依存の記述を、法造、あるいは本ツールのように容易な操作で行えるツールも存在しない。

法造アプリケーションでは, RDF および OWL との相互変換機能が上記のコンテキスト依存性の記述を含めてすでに実装されており, 本支援ツールで作成したデータも OWL による出力が可能である。しかしながら、法造形式のデータを介在させることが前提であるため、OWL で 1 から記述されたデータの読み込みと出力を繰り返し行えるような、いわゆる OWL エディタとして機能させることには限界がある。今後、RDF の世界においてコンテキスト依存性の記述ニーズが高まった時に、本研究の成果をいかに RDF の世界で生かしていくかが課題である。

謝辞

本研究は JSPS 科研費 15H02755 の助成を受けたものです。

参考文献

[古崎 2007] K. Kozaki, E. Sunagawa, Y. Kitamura and R. Mizoguchi: Proc. of 2nd Workshop on Roles and Relationships in Object Oriented Programming, Multiagent Systems, and Ontologies, Berlin,July 30-31, pp.39-46, 2007.

[増田 2017] 増田壮志, 古崎晃司: 概念階層の比較に基づくオントロジー品質向上支援手法, 人工知能学会論文誌, 32 巻 2 号 E, 2017

[増田 2018] 増田 壮志, 古崎 晃司, 駒谷 和範: 分類観点毎の概念階層の包括的な比較に基づくオントロジー品質向上支援システムの開発, 33 巻 (2018) 2 号 p. B-H82_1-10, 2018

[桝屋 2013] 桝屋啓志, 古崎晃司, 大江 和彦, 溝口理一郎: コンテキストに依存した定性値を扱う生物表現型統合デー タベース 試作, 第 27 回人工知能学会全国大会予稿集, 3I1-2 2013

[桝屋 2015] 桝屋啓志,高山英紀,古崎晃司,今井健,大江和彦, 溝口理一郎: 生物表現型情報と、疾患情報をつなげるデータベース,第 29 回人工知能学会全国大会, 1G5-4, 2015

[溝口 2004] Mizoguchi, R.,Tutorial on ontological engineering Part 3: Advanced course of ontological engineering., New Generation Computing Vol. 22, 198–220, 2004

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

学際性評価のための分野を超えた研究インパクト評価の標準化

— CNCIを応用した新指標による定量的な探索 —

Normalize an academic impact indicator for evaluating interdisciplinary

田中 和哉*1¥ 荒川 陸*2¥ 亀岡 恭昂*3¥ 森 純一郎*1 坂田一郎*1
Kazuya Tanaka Riku Arakawa Yasuaki Kameoka Junichiro Mori Ichiro Sakata
*1 東京大学大学院 工学系研究科
Graduate School of Engineering, The University of Tokyo
*2 東京大学工学部計数工学科
Faculty of Mathematical Engineering and Information Physics, School of Engineering, The University of Tokyo
*3 東京大学大学院 教育学研究科
Graduate School of Education, The University of Tokyo

1. 背景

科学技術政策や科学技術マネジメントの領域においては「学際性 interdisciplinary」の重要性は年々増しており、“interdisciplinary research(IDR)”という研究領域において「学際性」の特徴を明らかにすることを目的とした研究が蓄積されている [WRB+11, for review]。例えば、重要な科学的発見は分野を横断した協働によってもたらされるという知見 [CK14] や、学際性が研究のインパクトに影響を与えるという知見 [CAL15] などがある。したがって、学際性の研究は、理論上も実践上も重大な意義があるといえる。

しかし、「学際性」を十把一絡げに捉えることには危険が伴う。というのも、学際性の特徴は、どの分野とどの分野を越境した場合の学際性なのかによって異なるからである。例えば、学際性の高さが研究のインパクトに与える効果は、当該の論文にどの分野が含まれているかに依存することが指摘されてきた [LG10]。それゆえ、研究と学際性の関係をより厳密に捉えるためには、学際性の内実をより詳細に観ることが必要であり、学際性研究においては、当該の研究にどの分野が含まれているかを突き止めることが重要である。

一方で、計量書誌学や科学計量学の分野においては、分野によって引用の意味や引用の慣行が異なるため、引用を基盤とした研究の特徴は分野ごとに大きく異なることも明らかになってきた。例えば、分野によって、引用ポテンシャルや引用年齢分布が異なること [Gar79]、分野によって研究成果の評価が論文で行われるかどうか、さらには引用サイクルの長さが異なること [Hay14] が指摘されている。したがって、分野を横断して研究の比較をするのは適切ではないことも指摘されている [Neg99, Yam01, Shi04, Ono03]。

以上の考察から、学際性の評価を行うためには、学際性に含まれる分野を特定し、分野による影響を吟味する必要がある一方で、研究分野によって引用のパターンは異なるので、分野間の比較をするのが不適切であることが、学際性研究を厳密に評価することを極めて困難にしている。したがって、学際性の評価を行うためには、分野間の引用パターンを標準化することが必要であることが導かれる。とりわけ、学際性研究の今後の発展を考えると、分野間の引用パターンを標準化することは価値を増していると考えられる。

これまで分野間の引用パターンを標準化するために、数々の指標が提案されてきた。例えば、「ソース規格化指標 SCJIF (Source-Corrected Journal Impact Factor)」は、引用元雑誌の引用傾向（論文あたり参考文献数）の違いを考慮して雑誌間の比較を可能にするインパクトファクターを修正している [Kod14]。また、論文単位の被引用数を標準化するものとしては、トムソン・ロイター社のCategory Normalized Citation Impact (CNCI)[Reu14] や、エルゼビア社の Field-Weighted Citation Impact (FWCI)[CV14] がある。

IDR では、学会誌レベルで分類した上で研究の学際性を評価することが主流であったが[YYRD15, Ley07]、近年では学際性の評価には個々の論文レベルで分析を行う必要性も主張されてきている[BDH16]。また、論文レベルであれ、学会誌レベルであれ、分野間の引用パターンを標準化する指標としてこれまで提案されたものは、理論的に考察されたものであるか、または実証的に検証したものであったとしても、分野間の比較に留まるもので、学際性に言及したものではなかった。

そこで、本論文では、分野間の引用のパターンを標準化した上で算出された論文ごとの被引用数の一例として CNCI に着目する。本研究では、CNCIをそのまま用いることはせず、質の高い論文の集合に焦点をあて、CNCIを援用した指標を提案する。その指標を用いることで、被引用数を標準化して得られる指標に依拠し、学際性の実態について定量的に調査することを目的とする。

2. 手法

2.1 データセット

米国Clarivate Analytics社が提供している論文データベース: Web of Science Core Collectionより論文データを取得した。本研究では、被引用数に依拠せずに世界的に重要な論文であることが保障されたデータセットを母集団とするため、2016年の論文のうちTHE(Times Higher education)が発表した世界大学ランキングTop50校に所属する研究者が産出した全論文のうち、IDと分野の値が存在するものすべてを対象とし、50, 395674件を取得した。全論文は投稿ジャーナルを元に分野が151種類割り当てられている[1]。

2.2 今回使用した指標

The Category Normalized Citation Impact (CNCI)は、Clarivate Analytics社が発刊するInCitesで発表されている指標である[12]。ある文書のCNCIとは、その文書の被引用数を同文書タイプ、同出版年、同分野の全文書に対する被引用率の期待値により割ったものである。当該文書が複数分

[1] 151種類の分野名については下記Webサイトを参照のこと（https://images.webofknowledge.com/WOKRS514B4/help/ja/WOS/hp_subject_category_terms_tasca.html, アクセス日：2018年3月9日）

¥: equal contribution

連絡先：田中和哉、東京大学大学院工学系研究科、kazuya.tanaka@ipr-ctr.t.u-tokyo.ac.jp

野にまたがる時は、それらの分野の期待値の平均値が用いられる。

今回はCNCIを参考に、Top50校の執筆した同文書タイプ(論文)、同出版年(2006年)、同分野(151分野)の論文全体を用いて、各分野ごとの期待値を算出した。その期待値で個々の論文の被引用数を割ることで、分野ノーマライズされたCitation Impactの値を新たに計算した。その値を、本論文ではCNCIと表記する。

一つの分野に割り当てられている論文のCNCIは以下によって与えられる。

$$CNCI = \frac{c}{e_{ftd}}$$

ここでcはその論文の被引用数、e_{ftd}はその分野(f), ドキュメントタイプ(t), 年度(d)における被引用数の期待値である。

論文が複数の分野に割り当てられているとき、そのCNCIは以下のように計算される。

$$CNCI = \frac{\sum \frac{c}{e_{f(i)td}}}{n}$$

ただしnは割り当てられた分野の数である。すなわち、各分野ごとのCNCIの平均として算出される。

2.3 分野ペアのCNCI

分野を考慮した学際性の議論を行うために、特定の分野ペアの論文集合に対するCNCIを考える。対象の論文集合を、与えた分野のペアのラベルがついた論文の集合とし、その集合に対するCNCIを、

$$CNCI_{group} = \frac{\sum CNCI}{n}$$

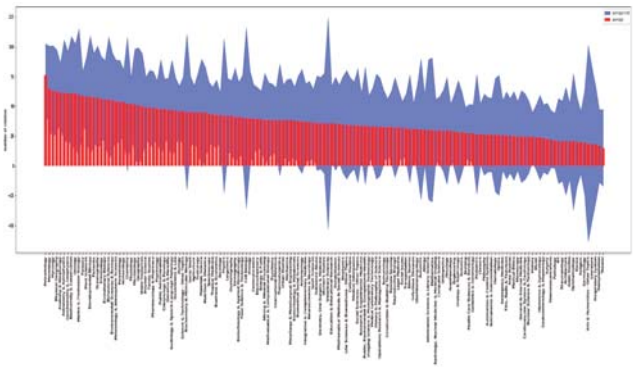
ただしnは集合の大きさである。

3. 結果と考察

3.1 分野ごとの被引用数の分布

まず最初にデータベースの分野と引用数の関係性を把握するために、各分野ごとの被引用数の平均と分散を計算し、図1に示す。

図1 分野ごとの被引用数の分布

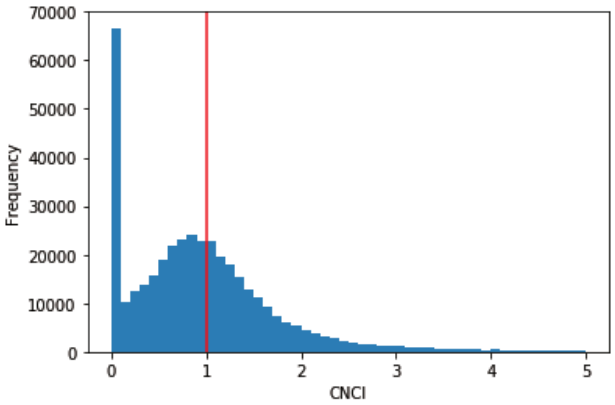


いずれの分野においても、一定の分散が確認できることから、このデータセットは十分に広範な研究論文を対象にしていることが推察される。また引用数による目立った分散の差は見受けられず、引用数と分散は無関係である可能性が高いことがわかった。

3.2 CNCIの分布

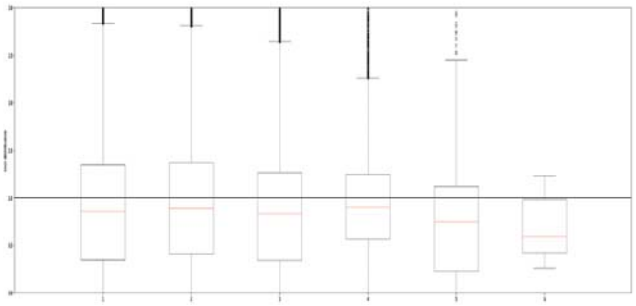
各論文に対しCNCIを計算し、それらのヒストグラムを図2に示す。

図2 全論文のCNCIの分布



また学際性の議論のため、論文ごとに割り当てられた分野数ごとにCNCIの分布を計算した。その結果を図3に示す。

図3 分野数ごとのCNCIの分布



ここで分野数で分類したときの論文数は分野数が1であるものから6であるものまで順番に239224, 111102, 36526, 7570, 1223, 21 であった。

図3より、一つの論文に対して割り当てられる分野の数が一定以上になるとCNCIの平均は減少する傾向にあることが確認できる。

4.2 分野ペアごとのCNCI

分野ペアを与えて、そのCNCIを計算した数例を、表1・表2に示す。表1にはCNCIが高いペア、表2にはCNCIが低いペアを示している。ただし、少量データによる偏りを除

くため、該当論文集合の大きさが100以上のものを対象とした。

表1: CNCIが高い分野のペア

分野ペア	CNCI
'Geriatrics & Gerontology', 'Cell Biology'	2.17
'Neurosciences & Neurology', 'Ophthalmology'	1.99
'Behavioral Sciences', 'Neurosciences & Neurology'	1.90
'Hematology', 'Cardiovascular System & Cardiology'	1.71
'Biochemistry & Molecular Biology', 'Life Sciences & Biomedicine - Other Topics'	1.71

表2: CNCIが低い分野のペア

分野ペア	CNCI
'Research & Experimental Medicine', 'Pathology'	0.093
'Pharmacology & Pharmacy', 'Public, Environmental & Occupational Health'	0.148
'Psychology', 'Ophthalmology'	0.149
'Genetics & Heredity', 'Mathematical & Computational Biology'	0.302
'Business & Economics', 'Health Care Sciences & Services'	0.316

表1表2から、'Neurosciences & Neurology', 'Ophthalmology'のCNCIは1.99であるのに対して、'Psychology', 'Ophthalmology'のCNCIは0.149であることが読み取れる。この結果は、同じ'Ophthalmology'の分野を含む学際論文であっても、CNCIの値は高いものもあれば低いものもあることを意味する。より詳細な考察が必要ではあるものの、分野の組み合わせ方など、他の要因が影響していることが示唆される。

4. 結論

本論文では、分野による論文毎の被引用数への影響を標準化したものとして CNCI を用いて、2016年度のWeb of Science Core Collectionのtop50校の論文に対して、被引用数の解析を行った。その中で、特定の分野ペアを考慮したCNCIを計算することで、分野を考慮した学際性を定量的に議論した。その結果、(1)一つの論文に対して割り当てられる分野の数が一定以上になるとCNCIの平均は減少する傾向にあること、および、(2)学際研究の中には、同じ分野を含むものの中に、CNCIの値は高いものもあれば低いものもあることの2点が示された。

本研究では、学際研究一般についてCNCIでの解析が意味をもつことを示したが、分野のペアごとの詳細な検討に立ち入ることはできなかった。今後、分野ペアはもちろんのこと、複数の分野のパターンで同様の解析を行い、研究と学際性の関係をより厳密に捉えたいと考えている。

5. 参考文献

[BDH16] Lindell Bromham, Russell Dinnage, and Xia Hua. Interdisciplinary research has consistently lower funding success. Nature, Vol. 534, No. 7609, pp. 684–687, 2016.

[CAL15] Shiji Chen, Cle´ment Arsenault, and Vincent Larivie´re. Are top-cited papers more interdisciplinary? Journal of Informetrics, Vol. 9, No. 4, pp. 1034–1046, 2015.

[CK14] JONATHON N. CUMMINGS and SARA KIESLER. Organization theory and the changing nature of science. Journal of Organization Design, Vol. 3, No. 3, pp. 1 – 16, 2014.

[CV14] Lisa Colledge and Reinder Verlinde. SciVal. SciVal Metrics Guidebook (Version 1.01).
Elsevier, 2 2014.

[Gar79] Eugene Garfield. Citaion indexing. Its theory and application in science, technology and humanities. Wiley, New York, 1979.

[Hay14] 林和弘. 計量書誌学から研究活動計量学へ（特集：計量書誌学を超えて）. 情報の科学
と技術, Vol. 64, No. 12, pp. 496–500, dec 2014.

[Kod14] 児玉閲, 小野寺夏生. 分野を超えた雑誌インパクトの比較が可能なソース規格化指標. 情報メディア研究, Vol. 13, No. 1, pp. 32–49, 2014.

[Ley07] Loet Leydesdorff. Betweenness centrality as an indicator of the interdisciplinarity of scientific journals. Journal of the Association for Information Science and Technology, Vol. 58, No. 9, pp. 1303–1319, 2007.

[LG10] Vincent Larivie`re and Yves Gingras. On the relationship between interdisciplinary and scientific impact. Journal of the Association for Information Science and Technology, Vol. 61, No. 1, pp. 126–131, 2010.

[Neg99] 根岸正光. 研究評価とビブリオメトリックス (研究評価の方法論). 情報の科学と技術,
Vol. 49, No. 11, pp. 544–549, 9 1999.

[Ono03] 小野寺夏生. 引用文献数で研究を評価できるか? 学士会会報, No. 1, pp. 50–57, 1 2003. [Reu14] Thomson Reuters. INCITES INDICATORS HANDBOOK. THOMSON REUTERS,
Philadelphia, 2014.

[Shi04] 調麻佐志. 学術論文データベースを利用した研究評価 : bibliometrics 指標の限界と可能性. 情報の科学と技術, Vol. 54, No. 6, pp. 317–323, 6 2004.

[WRB+11] Caroline S. Wagner, J. David Roessner, Kamau Bobb, Julie Thompson Klein, Kevin W. Boyack, Joann Keyton, Ismael Rafols, and Katy Bo¨rner. Approaches to understanding and measuring interdisciplinary scientific research (IDR): A review of the literature. Journal of Informetrics, Vol. 5, pp. 14–26, 2011.

[Yam01] 山崎茂明. 指標としてのインパクト ファクター. 研究評価, 2001.

[YYRD15] Alfredo Yegros-Yegros, Ismael Rafols, and Pablo D'Este. Does interdisciplinary research lead to higher citation impact? the different effect of proximal and distal interdisciplinarity. PloS one, Vol. 10, No. 8, p. e0135095, 2015.

Oral presentation | Organized Session | [Organized Session] OS-5

[1F2-OS-5a] [Organized Session] OS-5

Tue. Jun 5, 2018 3:20 PM - 5:00 PM Room F (4F Garreria)

[1F2-OS-5a-01] How Do Young People Face the Development of Artificial Intelligence?

○Motoki Ono[1], Hiroshi Nemoto[2], Kazuya Tanaka[2], Kan Suzuki[2] （1. Research Institute at Keio SFC, 2. The University of Tokyo）

3:20 PM - 3:40 PM

[1F2-OS-5a-02] Relationship between mind perception and responsibility in a collaborative task with an artifact

○Tomohito Miyake[1], Yuji Kawai[1], Jihoon Park[1], Jiro Shimaya[2], Hideyuki Takahashi[2], Minoru Asada[1] （1. Graduate School of Engineering, Osaka University, 2. Graduate School of Engineering Science, Osaka Univercity）

3:40 PM - 4:00 PM

[1F2-OS-5a-03] A study on legal personhood of AIs in tort law

○Ryota AKASAKA[1] （1. The National Institute of Advanced Industrial Science and Technology）

4:00 PM - 4:20 PM

[1F2-OS-5a-04] Driving Self-Driving Cars by Spoken Language Instructions

○Hiroshi Tsukahara[1], Hirotaka Higaki[2], Namabu Oomae[2], Nana Ootawara[3], Akari Inago[3], Ichiro Kobayashi[3] （1. Denso IT Laboratory, Inc., 2. Graduate School of Media and Goverance, Keio University, 3. Ochanomizu University）

4:20 PM - 4:40 PM

[1F2-OS-5a-05] First Trials with Culture-Dependent Moral Commonsense Acquisition

○Rafal Rzepka[1], Da Li[1], Kenji Araki[1] （1. Hokkaido University）

4:40 PM - 5:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

人工知能の発展に若者はどう向き合うか？

How Do Young People Face the Development of Artificial Intelligence?

大野 元己[*1] 根本 紘志[*2] 田中 和哉[*3] 鈴木 寛[*4]
Motoki Ono Hiroshi Nemoto Kazuya Tanaka Kan Suzuki

[*1] 慶應義塾大学 SFC 研究所 Keio Research Institute at SFC
[*2 *3 *4] 東京大学 The University of Tokyo

This report describes how university students confront the future society accompanied by the development of artificial intelligence. To analyze how students face the future, we implemented the voluntary seminar to consider and discuss the development of science and technology. The aim is to show how each student's response differs depending on their values and circumstances.

1. 人工知能の発展への向き合い方

人や社会にとって有益な科学技術が同時に予測不可能なリスクになり得るとベックは著書『危険社会』の中で論じている[ベック 98]. 一例として, フレイらはアメリカの仕事の 47%が人工知能などの技術の発展によって代替されるとしている[Frey 13].

フレイらの論文においては技術によって社会や人の生き方の未来が定められるビジョンが描かれているが, 他方で人が能動的に自身の将来を形成することを期待する議論も見られる. ボストロムは, 人の知能を超越する"superintelligence"によって人類の存在レベルでのリスクが増大しうるとするディストピア的シナリオを描きつつも, より好ましい未来を形作るための人間の努力を強調する[Bostrom 14].

ボストロムの言う未来に向けた努力の一つとして, 非専門家を含めた人々が科学技術をどう捉えるかという視点に立って議論・教育する取り組みが試行されている.

人工知能の発展に伴い個人がどう能動的に行動するかという観点での教育プログラムとして, アメリカで Singularity University が開校した. 本大学では, 技術の指数関数的発展の中でどのように世界にポジティブな影響を与えるかを主眼とした教育が行われている[Singularity University].

本企画では, Singularity University の事例に見られるような技術と社会の未来に関する対話を, 大学1～3年生を対象とした自主ゼミナールの場で試みた.

2. 自主ゼミナール及び企画の詳細

本企画は 2017 年 10 月から 12 月にかけて第四著者が講師, 第一著者～第三著者がティーチング・アシスタントとして開講した自主ゼミナール内で実施した. 本ゼミナールは主に, 専攻を決めていない東京大学前期教養課程生を対象としたもので, 技術・芸術等に関するテーマに触れながら, 受講生が専攻選択やキャリア選択への考察を深めることを目的としている.

企画は 2017 年 10 月と 11 月に週1回2時間程度, 全5回にわたり実施した. 課題図書に Bostrom の"Superintelligence: Paths, Dangers, Strategies"を指定し, 各回とも専門家1～3名による講義と関連テーマに関する議論を行った. 各回の講義・議論のテーマは表1に示した通りである.

連絡先：大野元己, 慶應義塾大学 SFC 研究所,
motoki34@live.jp

科学技術と社会, 及びそのインターフェースに対する意見は多様な価値や個人を取り巻く状況に左右される[杉山 02]ことから, 可能な範囲で多様性を確保した.

参加者は学部1～3年生の14名で, 内訳は東京大学に所属する者が11名, 他大学からの参加者が3名であった. 専攻については, 文系志望者・専攻者が12名, 理系志望者が1名, 文系理系両方の分野を専攻する者が1名であった. 専門家の専門性も科学技術やその応用先だけでなく, 科学技術社会論（STS）, 法律, 政策, メディアと幅を持たせた.

また, 学生には毎回「技術と社会の変化にどう向き合うか」というテーマでエッセイを作成することを求めた. ゼミナール初回前に A4 用紙1枚分程度でエッセイを執筆し, 各回の講義・議論後にその内容を修正するという形式を取ることで学生が自身の思考の変遷を捉えられるようにした.

表1. 講義・議論のテーマ

回数	テーマ
第1回	「技術と社会」を考える上での論点の提示
第2回	科学技術を考える際の未来に向けた方法論
第3回	SF における未来技術の描かれ方, 受け止められ方
第4回	「技術と社会」をどう論じるか
第5回	先端科学技術と社会受容性 - 次世代交通と都市を中心に -

3. 結果

エッセイからは, 技術発展に対する多様な反応を見ることができた. 以下, 反応の類型とその内容を検討する.

3.1 技術と社会への関心

多くの学生は, 自主ゼミナールでの機会がなければ技術が自身の生き方に及ぼす影響を考えることは無かったであろうとしつつ, 各講義の内容や課題図書を自身の興味分野や価値観に位置付けた. 3-2 節及び 3-3 節に詳述するが, その多くは目指す, もしくは既に決定している自身のキャリアや, 理想の生きる姿勢を考える上での判断材料として技術と社会の関係に関心を示した.

特に, 既に自身の専攻や就く職業が決まっている, もしくは明確なビジョンが存在する学生は, ELSI や科学コミュニケーターと

しての素質などをキャリアや目標の達成のために考える必要があるものとして捉える傾向が見られた.

他方で, 本ゼミナールで扱ったテーマに関心を示せなかったとする意見も存在した. そこでは,

- 哲学のような思考を深める方向での難しさに接することは好きだが, 分からないことが当然という意味での未来を考える難しさには関心が持てなかった.
- 当初は意気込みがあったが, 考えるうちに企画の主催者や専門家の方の技術と社会に対するスタンスが気になった点, 何を考えても既にそれは議論されているという感覚が強かった点などからもやもや感が残った.

などの意見が見られた. 興味が持てないとした学生からは, 自身が未来をどう想定し何を大事にするのかを考える機会を得たことはいつか価値を持つのだろう, 体系立てられない頭の働かせ方をしたことは楽しかった, など消極的な意味での関心は見られた.

3.2 技術とどのように付き合っていくのか

不確定・不確実な未来を考えることを通して, 技術との付き合い方に多様な意見が見られた.

(1) 技術を自身の大事にしている価値や想定する生き方と衝突するものとして捉え, 抗おうとする

エンターテイメント産業が供給する感情の揺さぶりなど人間の領域と思われているものが技術によって担われる可能性を見越した上でそれに対抗する方法を考えたい, AI には担えない表現のあり方を探求したい, などの意見が見られた.

これらの意見では, 対抗手段として AI やロボットによって代替されない人間の領域を考案するものが多く, 具体的には感情, 無駄, 物語性, コミュニケーション, 内省, 疲れなどが挙げられた.

(2) 自分の生きたい未来に近づく形で技術が社会に影響するよう働きかける

技術は向こうからやって来るものではないという意識が生まれ, 想像力を拡げていきたいという考えに至った例や, AI の発展がもたらす副作用を抑える制度を作っていきたいなどの意見が見られた.

(3) 自分の大切にしているものがある程度技術によって侵食されていくことを認めた上で, その領域とは関わらない生き方をする宣言

AI などの技術の進歩によって, 積極的に生きなくともある程度幸せになれる世界や職業に煩わされることのない世の中を想定し, 内面の注視や創造性の求められる作業に専念したいとする意見が見られた.

3.3 技術と社会について考えることの意義

ゼミナール全体を通して技術と社会について考えることの意義に関しても学生によって意見の相違が見られた.

(1) 自身の大切にする価値の変化・深堀り

自身の大切にするもの, 及びそれを取り巻く環境が技術を通して変化する可能性を考察することで, そこに変化や深堀りが生まれたとする意見が多く挙げられた.

AI をめぐる議論に触れることで, 人間にしかできないことを模索したいと考えるに至ったことが意外だったとする意見や, 自分の大事にしていた価値が代替される可能性への不安の表明などが見られた.

(2) 自分と社会の繋がりを考えるための技術

今まで漠然と考えていた自分と社会との関わりについて, 技術という具体的なモノを間に置くことでより明確に考えることができたという意見が挙がった.

(3) 曖昧な自分の考えや生き方の展望の許容

未来が不確実なものであると認識することで, 同様に不確実である自分の未来を受け入れとりあえず前に進もうという覚悟に繋がったとする積極的な意見が見られた. 類似の意見として, 未来の正しい展望が存在しないのだとすれば, 自分が何をしたいのか, 何を守りたいのかを探求していく必要があるという考えに至った事例も存在した.

4. 成果と課題

本企画では, 自主ゼミナールにおける講義と議論を通して生まれた学生の意見の相違を追った. 類似した取り組みとして前述の Singularity University の事例が挙げられるが, この大学は指数関数的に進歩する技術を用いて世界の問題を解決するという明確なコンセプトに基づいて学生を集めている. 本自主ゼミナールは主に東京大学の学生を対象としているため結果にはバイアスが存在するものの, 学生が特定のコンセプトや価値を共有しない分, より多様な意見を汲み取ることができたと考える.

科学教育では, 非専門家の科学に対する正しい知識や理解を養成する PUS(Public Understanding of Science)や理数系人材の強化を目指す STEM 教育などが行われてきた. しかし, これらの教育プログラムでは必ずしも市民それぞれの職業・望む生き方・価値などを反映した対話が行われていない. 今後の科学教育や科学コミュニケーションにおいても, より個人の違いを重視する方向での分析と応用が肝要なのではないか.

上記の過去の事例と本自主ゼミナールの比較を鑑みると, 科学教育においては対象者の多様性を確保する点, その上で個人個人の違いを汲み取る点が重要であると考える. 今後の展望として, より多くの対象者を確保し, また意見の変遷を類型化する試みを具体化していきたい.

5. 謝辞

本自主ゼミナールを開講するにあたり, 江間有沙氏・工藤郁子氏・田中幹人氏・藤田卓仙氏・八代嘉美氏・嶂南達貴氏からのご講義と学生への熱心なフィードバックを賜りました. 心より感謝申し上げます.

参考文献

[ベック 98] ウルリヒ・ベック: 危険社会 新しい近代への道, 法政大学出版局, 1998.

[Bostrom 14] Bostrom, N.: Superintelligence Paths, Dangers, Strategies, OUP Oxford, 2014.

[Frey 13] Frey, C. B., Osborne, M. A.: The Future of Employment, https://www.oxfordmartin.ox.ac.uk/downloads/academic/The_Future_of_Employment.pdf, 2013.

[Singularity University] Singularity University: An Exponential Primer Your guide to our essential concept, https://su.org/concepts/

[杉山 02] 杉山滋郎: 科学教育 本当は何が問題か, 金森修, 中島秀人: 科学論の現在, 勁草書房, pp.91-116., 2002.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

人工物との共同作業における心の知覚と責任帰属の関係

Relationship between mind perception and responsibility in a collaborative task with an artifact

三宅 智仁 *1 Tomohito Miyake　河合 祐司 *1 Yuji Kawai　朴 志勲 *1 Jihoon Park　島谷 二郎 *2 Jiro Shimaya　高橋 英之 *2 Hideyuki Takahashi　浅田 稔 *1 Minoru Asada

*1大阪大学大学院工学研究科 Graduate School of Engineering, Osaka University

*2大阪大学大学院基礎工学研究科 Graduate School of Engineering Science, Osaka University

Does a human think that an artifact should be responsible for failure in a collaborative task with the artifact? We aim to identify the relationship between responsibility and mind perception (MP) about the collaborative partner. We conducted experiments with three agent conditions: a human, humanoid robot, and computer. The result indicates that a subject thought that an agent with the higher MP items that are important abilities for the task (e.g., "Thought") is less responsible. It seems that the impression that "the argent acted for the success of the task" may reduce the responsibility. In addition, we found that negative change of the MP is correlated with the degree of the responsibility. This suggests that the betrayal of the subject's expectation of the partner through the task may increase responsibility.

1. はじめに

近年，人工知能やロボット技術の発展により，日常において人と関わるロボットが開発されつつあり，今後，自律的なロボットと人が共同で作業する機会が増加すると考えられる．その場合，ロボットとの共同作業が失敗したときに人は，それに対する自身の責任，またはロボットの責任をどのように考えるのだろうか．その失敗は自身だけの責任ではなく，ロボットも責任を負うべきであると考える可能性がある．また，その責任帰属は，共同作業相手が人である場合とロボットである場合とで異なる可能性がある．そのため，人と共同作業する人工物設計においては，人が他者や人工物に責任を帰属する心理的メカニズムを考慮することが重要になる．

Gray et al. はエージェントへの心の知覚と規範的責任に関係があることを明らかにした [Gray 2007]．この研究は，人やロボットを含む様々なエージェントに対して，どのような心を持っていると思うかを質問紙調査したものである．質問紙項目に対する主成分分析の結果，心の知覚は Agency（思考，計画，自制などを行う能力）と Experience（楽しみや苦痛などの感情を経験できる能力）の二つの次元で説明できることが示された．人は Agency も Experience も高い存在として認知される一方，ロボットの Agency は人よりも低く，Experience は非常に低い．さらに，エージェントが人の死の原因となった状況を想定し，そのエージェントが罰せられるべきかという規範的責任を調査したところ，Agency と責任との間に非常に強い正の相関関係があることがわかった．すなわち，Agency が高いエージェントであるほど責任を帰属される傾向にあるといえる．しかし，この責任の調査において，評価者は第三者的であるため，ある損害に対する当事者としての責任帰属を評価していない．先述のような人とエージェントの共同作業における心の知覚と当事者視点での責任感は調べられていない．

Hinds et al. は，人とロボット，あるいは人同士が共同で物を集める課題を実施し，その課題の結果に対する責任を質問紙により調査し，人との作業における責任と，ロボットとの作業における責任に有意な差はないことを報告した [Hinds 2004]．ただし，この研究での課題の成績は人の報酬とは関係しないため，評価者自身の損害に対する責任帰属は調べられていない．また，Kim & Hinds は人が製品を組み立て，それをロボットが運搬するという共同作業において，自律性の高いロボットは，低いロボットよりも責任を帰属されやすいことを報告した [Kim 2006]．このことは，人が感じるロボットの心の知覚，特に自律性が関係すると考えられる Agency が責任帰属に影響する可能性を示唆する．しかし，これらの研究は，心の知覚と当事者的な責任感の関係を直接検討していない．

そこで，本研究では，人とエージェントが対面で同じ課題に取り組んだ結果，人に損害が生じたときに，人が感じる相手エージェントへの責任を評価し，それと心の知覚との関連を調査することを目的とする．今回，人と相手エージェントのそれぞれの選択に応じて実際に金銭報酬が与えられるゲームを課題とする．この課題を用いることで，Gray et al. (2007) の研究では考慮されていなかった「共同作業および損害の当事者」の視点から，その損害に対する責任帰属を評価することができる．本研究においても，Gray et al. (2007) と同様に心の知覚と責任帰属の関係を調査するが，ゲームの失敗や損害によって相手エージェントへの心の知覚が変化することが考えられる．その変化も責任帰属と関係する可能性があるため，ゲーム後の心の知覚だけではなく，ゲーム前後の心の知覚の差とゲームの失敗に対する責任との相関を解析する．以上について，相手のエージェントを人，ロボット，コンピュータとする三条件を設け，比較することで，それぞれのエージェントに対する人の責任帰属の違いについて検討する．

2. 実験

2.1 参加者

本実験には 19 歳から 25 歳までの男女 25 人（平均 21.4 歳（SD=1.9），男性 19 人，女性 6 人）が参加した．実験前に，ゲームの結果によって報酬が増減することを説明し，同意を得た．そして，実験後に本実験の目的を改めて説明し，再び同意を得た．

2.2 実験課題

課題には繰り返しゲームを採用した．これは，参加者と相手エージェントが二つの選択肢（「たくさん欲しい」と「相手に譲る」）のどちらかをそれぞれ選択し，その組み合わせによっ

連絡先: tomohito.miyake@ams.eng.osaka-u.ac.jp

表 1: 利得表

相手の選択 \ 参加者の選択	たくさん欲しい	相手に譲る
たくさん欲しい	参加者：−10 円 相手　：−10 円	参加者：+20 円 相手　：+100 円
相手に譲る	参加者：+100 円 相手　：+20 円	参加者：0 円 相手　：0 円

て両者に金銭報酬が与えられるゲームである．ゲームは参加者と相手エージェントが向かい合い，コンピュータのキーボードを用いて選択することで進行する．参加者には表 1 の利得表を提示し，これに従って次のように報酬が決定され，実験謝金に上乗せされると教示した．

- 参加者が「たくさん欲しい」，相手エージェントが「相手に譲る」: 参加者に 100 円，相手エージェントに 20 円が与えられる（表 1 の左下）．
- 参加者が「相手に譲る」，相手エージェントが「たくさん欲しい」: 参加者に 20 円，相手エージェントに 100 円が与えられる（表 1 の右上）．
- 参加者と相手エージェントの両方が「相手に譲る」: 両者とも報酬は得られない（表 1 の右下）．
- 参加者と相手エージェントの両方が「たくさん欲しい」: 両者とも 10 円を失う（表 1 の左上）．

報酬は一回の選択ごとに与えられ，一ゲームの間に両者は十回選択する．十回の選択で得られた報酬の合計が，そのゲームで参加者に与えられる報酬額である．また，ゲーム前に架空の平均獲得報酬額（480 円）を参加者に示し，ゲーム後に参加者の獲得報酬額がそれを超えたかどうかを示した．なお，利得表とそれまでのゲームで獲得した報酬の合計はゲームの間，常に参加者に提示され，参加者がそれを確認できるようにした．各選択において結果が表示されるまで，参加者は相手エージェントの選択を知ることはできない．また，ゲーム中は声を出して相手エージェントと相談してはならないことを教示した．

このゲームで多くの報酬を獲得するためには，両者が互いに相手の次の選択を予想し，それに応じて自身が選択する必要がある．参加者は「たくさん欲しい」を選び続けることもできるが，相手エージェントがそれに協調しなかった場合，両者の報酬は減ってしまう．そのため，多くの報酬を獲得する一つの戦略は，参加者が「たくさん欲しい」と「相手に譲る」を交互に選択し，それに合わせて相手エージェントが「相手に譲る」と「たくさん欲しい」を交互に選択することである．参加者に対しては，ゲーム開始前に「互いに譲り，協力することで多くの報酬を得ることができる」と教示した．

2.3　相手エージェントの設定

相手エージェントとして，人（図 2(a)），ロボット（ヴイストン株式会社，Sota）（図 2(b)），コンピュータ（Microsoft, Surface）（図 2(c)）の三条件を設け，参加者はそれぞれに対して一回ずつゲームを行った．いずれの条件においても相手エージェントは「たくさん欲しい」を七回,「相手に譲る」を三回，参加者の選択にかかわらずランダムな順番で選択する．そのため，参加者の獲得報酬額は架空の平均獲得報酬額以下になる．

参加者には各エージェントの能力を次のように説明した．

人条件

別室で同じ実験に参加していた参加者であると説明した．



図 1: 実験の様子



(a) 人条件　(b) ロボット条件　(c) コンピュータ条件

図 2: 各条件の相手エージェント

この条件でのエージェントは，参加者と同様に，次節で述べる質問紙に回答した．

ロボット条件

「ロボットには大阪大学で開発した人工知能が搭載されており，目の部分のカメラによって参加者の表情を観察してゲームができる」と教示した後,「よろしくお願いします，がんばります」という音声とともに頷く動作を行わせた．ゲーム中にはロボットはランダムに首を小さく動かす待機動作をする．

コンピュータ条件

コンピュータにはウェブカメラを設置し，他の条件と同様に，参加者が相手エージェントの目 (カメラ) を見ることができるようにした.「コンピュータには大阪大学で開発された人工知能が搭載されており，ウェブカメラによって参加者の表情を観察してゲームができる」と教示した．コンピュータ条件ではエージェントの動作や音声はない．

2.4　質問紙

参加者は，ゲーム前に，相手エージェントと対面した状態で，相手エージェントに対する心の知覚を評価した．そして，ゲーム後に再度，同じ心の知覚を評価した．今回，心の知覚の日本語版 [上出 2017] を用い，七件法で回答を得た．心の知覚の質問項目を表 2 に示す．また，ゲーム後に，以下の質問（七件法）によって，ゲーム結果に対する自分と相手の責任帰属を評価した．

(a) あなたの報酬金は，相手の選択のせいで平均（480 円）より少なくなった．

(b) あなたの報酬金は，あなたの選択のせいで平均（480 円）より少なくなった．

今回，自分に比べて相手にどれだけ責任を帰属したかを評価するために，上記の (a) の回答の値から，(b) の回答の値を引い

表 2: 質問紙項目

Agency	Experience
記憶すること	意識を持つこと
道徳的であること	個性を持つこと
自制すること	プライドを持つこと
コミュニケーションすること	願望を抱くこと
計画すること	楽しむこと
思考すること	苦痛を感じること
感情を認識すること	恐怖を感じること
	空腹を感じること
	怒りを感じること
	困惑すること

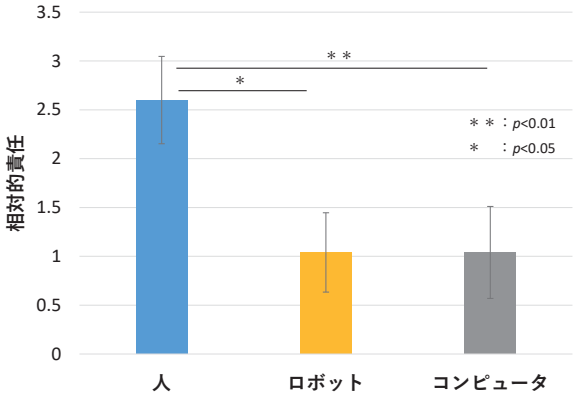


図 3: 相対的責任感

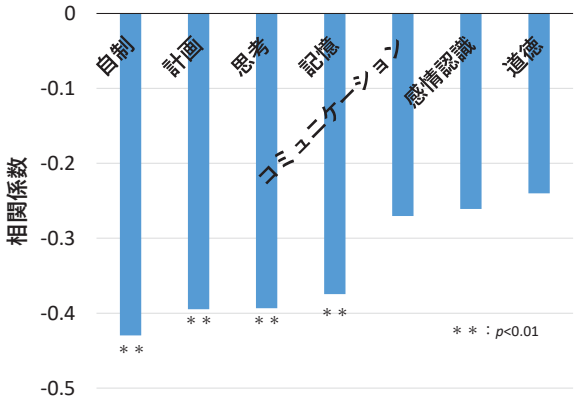


図 4: 相対的責任感とゲーム後の心の知覚との相関係数（左から，自制すること，計画すること，思考すること，記憶すること，コミュニケーションすること，感情を認識すること，道徳的であること）

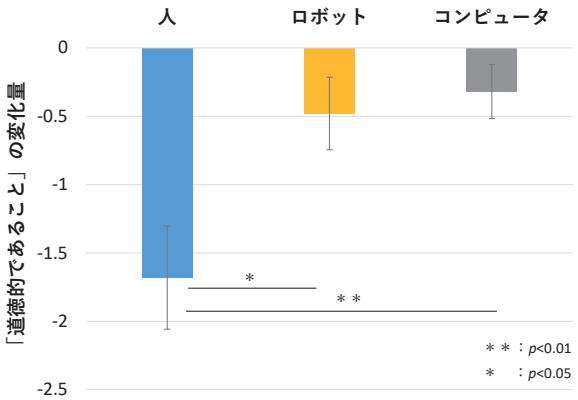


図 5: ゲーム前後の「道徳的であること」の変化量

た値を相対的責任感として解析対象とする．これにより，参加者自身の責任を基準として，相手にどれだけの責任を帰属したかを評価できる．

3. 結果

3.1 相対的責任感

相対的責任感の参加者平均を図 3 に示す．一元配置分散分析の結果，エージェントに関して主効果がみられた（$p = 0.020$）．さらに，下位検定 (t 検定) の結果，人-ロボット条件間および，人-コンピュータ条件間において，人条件で相手エージェントに有意により大きな責任が帰属されたことがわかった（それぞれ $p = 0.013$，0.0080）．なお，この多重比較の際は Bonferroni の方法で p 値を補正した．なお，相対的責任感と参加者の獲得報酬額との相関，および，参加者の「たくさん欲しい」の選択回数との相関はいずれも有意ではなかった（それぞれ $r = .07, -.03$）

3.2 ゲーム後の心の知覚と相対的責任感との相関

相対的責任感と関係するゲーム後の心の知覚の項目を調査するため，三条件全てについて心の知覚の各項目と相対的責任との相関係数を求めた．この多重比較には FDR（Fales Discovery Rate）法を用いた．Agency に属する項目についての結果を図 4 に示す．これらのうち，相対的責任感との有意な相関がみられた項目は，「自制すること」，「計画すること」，「思考すること」，「記憶すること」の四項目であった（それぞれ $r = -.43$, $-.39$，$-.39$，$-.37$）．すなわち，これら四項目の能力が高いと思われたエージェントほど責任を帰属されにくかったといえる．なお，相対的責任感と Experience の項目の間には，有意な相関はみられなかった．

しかし，この効果は相対的責任感の評価とは矛盾するものである．もし，この効果によって相対的責任が説明されるならば，人の Agency は人工物のものよりも大きいため，人の責任は小さくなるはずである．したがって，条件間の相対的責任感の評価の差に関係する別の心理要素があると考え，ゲーム前後の心の知覚の変化量と相対的責任との関係を調査した．

3.3 ゲーム前後の心の知覚の変化量と相対的責任との相関解析

まず，ゲーム前後の心の知覚の変化量について，エージェント条件に主効果があるか解析した．一元配置分散分析でエージェントによる主効果がみられたのは，「道徳的であること」と「苦痛を感じること」の二項目であった（それぞれ $p = 0.0024$, 0.0065）．二項目の変化量を図 5 と図 6 に示す．下位検定（t 検定）の結果，「道徳的であること」は人-コンピュータ条件間，および，人-ロボット条件間で人条件において，有意により減少していた（$p = 0.0030$，0.023）．「苦痛を感じること」についても同様に，人条件の減少量が有意に大きいものであった（$p = 0.027$，0.049）．

次に，三条件全てに関して心の知覚の変化量と相対的責任との相関を求めた結果，いくつかの項目で有意な負の相関がみられた．具体的には，「道徳的であること」，「苦痛を感じること」，「記憶すること」，「計画すること」，「思考すること」，「感情を認識すること」，「意識を持つこと」（それぞれ $r = -.33$, $-.37$，$-.30$，$-.37$，$-.41$，$-.36$，$-.44$）である．つまり，こ

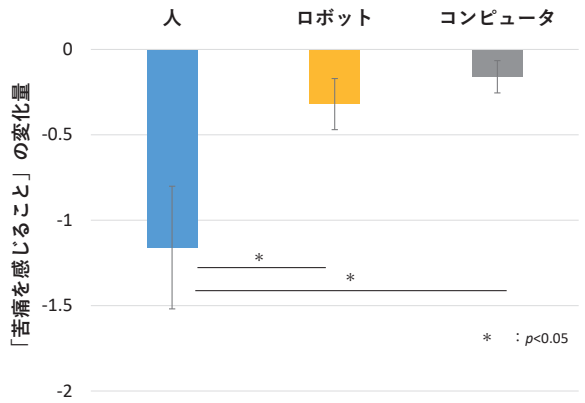


図 6: ゲーム前後の「苦痛を感じること」の変化量

れらの項目がゲーム前後で減少したエージェントほど責任を大きく帰属されたといえる．

さらに，条件ごとに相対的責任と心の知覚の各項目の変化量との相関を求めた．人条件では Agency の全ての下位項目の変化量，および，Experience の下位項目である「意識を持つこと」,「苦痛を感じること」,「恐怖を感じること」の変化量が，相対的責任と有意な負の相関関係にあった．また，ロボット条件では,「意識を持つこと」の変化量のみが相対的責任と有意な負の相関（$r = -.65$）を示した．一方，コンピュータ条件では相対的責任と有意な相関を持つ項目は存在しなかった．以上のことから，人条件で相対的責任感が大きくなったことは，ゲームの前後で心の知覚が大きく低下したことと関係があることがわかった．

4. 議論と結論

本実験結果より，共同作業において，その相手が人である場合に，相手が人工物（コンピュータやロボット）である場合よりも，失敗に対する責任が大きく帰属されることが示された（図 3）．この責任感は相手エージェントに対する特定の心の知覚，ならびに，共同作業による特定の心の知覚の変化量が関係することがわかった．さらに，この責任感と心の知覚の関係は，相手エージェントの見た目によって異なることが示された．

全データについて，相対的責任感と有意な負の相関がみられたゲーム後の心の知覚は「記憶すること」,「自制すること」,「計画すること」,「思考すること」の四項目であった（図 4）．これらの四項目は，本実験のゲームにおいて，両者が多くの報酬を得る上で重要な能力であるといえる．例えば,「記憶すること」,「計画すること」,「思考すること」の三項目は，これまでの選択の履歴から次以降の選択を決定することに関連する．また，相手に譲る選択をするためには,「自制すること」が必要である．したがって，これらの四項目の得点が高いエージェントは,「相手エージェントはゲームの成功のために行動した」という印象を参加者に与えたため，相手エージェントに帰属される責任が減少したと考えられる．この効果はエージェントの種類によらず生じる．

「道徳的であること」と「苦痛を感じること」の二項目におけるゲーム前後の得点の差は相対的責任感の評価と負の相関関係にあった．つまり，この二項目がゲーム前と比べて低くなるほど，相対的責任感は大きくなった．この二項目は，人条件で，ロボット条件とコンピュータ条件よりも有意に大きく減少していたことから，ゲーム前後でのこれらの二項目の大きな減少が，人条件での大きな相対的責任に関連しているといえる．人は道徳的な選択をし，また，他者の苦痛を感じられる，すなわち，共感的な選択をするものと期待されるが，ゲームでのランダムな選択が，この期待に反し，それが大きな責任帰属につながったと推測される．

一方で，選択方法が人条件と同じであるにもかかわらず，人工物条件では，相対的責任感と関係するゲーム前後の心の知覚の変化量の項目はほとんどなかった．その理由として，これらの人工物には道徳的，共感的な選択をすることを期待されなかったからと考えられる．田畑と小松は人とロボットには異なる道徳基準が適用され，ロボットに対しては道徳的考慮よりも課題の合理的な遂行が重視されることを報告している [田畑 2017]．コンピュータ条件では，心の知覚の変化量が責任にほとんど影響しないことに対して，ロボット条件では「意識を持つこと」の変化量が相対的責任と強い負の相関関係にあった．このことから，本実験において参加者はロボットに対して，コンピュータとは異なり,「意識を持つこと」を期待していたと考えられる．

以上のことから，実際の共同作業による損害の当事者として，相手エージェントの責任を評価した際には，必ずしも Gray et al. の仮説通りではないことが示された．むしろ，エージェントの種類を問わず，Agency が責任と負の相関関係をもつことが明らかになった．さらに，作業を通した心の知覚の変化が責任帰属に影響することが示された．その効果はエージェントの種類によって異なり，人工物よりは人においてその効果が大きくなることが示唆された．

謝辞

本研究は，JST RISTEX「人と情報のエコシステム」研究開発領域による研究成果の一部である．

参考文献

[Gray 2007] Gray, H., Gray, K., and Wegner, D.: Dimensions of Mind Perception, *Science*, Vol.315, p.619 (2007)

[Hinds 2004] Hinds, P., Roberts, T., and Jones, H.: Whose Job Is It Anyway? A Study of Human Robot Interaction in a Collaborative Task, *Human-Computer Interaction*, Vol.19, pp.151-181 (2004)

[Kim 2006] Kim, T., and Hinds, P.: Who Should I Blame? Effects of Autonomy and Transparency on Attributions in Human-Robot Interaction, *In Proceedings of the 15th IEEE International Symposium on Robot and Human Interactive Communication* (2006)

[上出 2017] 上出寛子, 高嶋和毅, 新井健生: 日本語版擬人化尺度の作成, パーソナリティ研究, Vol.25, No.3, pp.218-225 (2017)

[田畑 2017] 田畑緩乃, 小松孝徳: ロボットとは何者なのかを考えるための日常的モラルジレンマ課題の提案, HAI シンポジウム 2017 (2017)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

不法行為法における AI の法的人格に関する検討

A study on legal personhood of AIs in tort law

赤坂亮太[*1]
Ryota AKASAKA

[*1] 産業技術総合研究所
National Institute of Advanced Industrial Science and Technology

This article examines a notion of legal personhood of AIs in tort law. Tort law has three functions, and the notion hardly satisfy these functions.

1. はじめに

自律的な AI の発展にともない、AI が原因となる何らかの問題が生じた際に関係する個人(たとえば当該 AI の使用者や製造者)に当該事象の結果について予見可能性を観念することが困難になってきており、またその行動のアルゴリズムが人間には理解できずブラックボックス化しており、不透明性が増している。そのような状況において、今日の法制度では関係する個人に責任を観念することが難しく、被害者が救済されないなどの問題があると言われており、AI・ロボットの法的問題に関する中心的なテーマとなっている (例えば、平野[2017])。その解決策の一つとして、AI・ロボットに法的主体性を認め責任を負うことができる存在としてみなそうという考え方がある(例えば、 Chopra and White[2011])。

実際に、欧州議会は欧州委員会に対して法務委員会の報告書を素案に採択した決議において、AI・ロボットに電子的人格を検討するべきであるとの勧告を出した。また IEEE の報告書においても自然人と同じようにではないにせよ、個別の法的人格について動物の管理者や使用者責任といった「代理人」としての AI・ロボットを検討し、独立した法的人格についても人類の利益の確保を原則として今後再検討すべきだと言及している。洗練された AI・ロボットについて法的主体性をみとめて責任を負わせるというアイデアは、だれが責任を負うのか、責任の空白が生じないかという重要な問題を解決するように思える。

しかし、AI・ロボットなどの新たな主体に法的主体性をもたせるというこのアイデアは現実の法制度においてどれほど現実的なものなのだろうか。換言すれば、AI に法的主体性を持たせるというアイデアは、今日の法制度で採用されているいくつかの法理を類推または応用することを超えるほどに意味があることなのだろうか。

そこで、本報告では、法的責任の一部ではあるが、その中でも重要な論点として挙げられる不法行為法(特に我が国における制度)の観点から不法行為責任を AI に負わせるというアイデアについて、既存の法理と比較することで検討したい。

2. 不法行為法の機能

AI 自体が不法行為責任を負うというアイデアを検討するにあたって、まず不法行為法とはどのような制度であり、その責任を負うとはどういうことなのかを確認する必要がある。

不法行為制度の説明には様々なものがあるが、概ね不法行為法の制度自体の目的としては各人の権利利益の保護にあるとしつつ、今日における一般的な理解として不法行為法には、故意または過失により生じた損害に対して被害者の救済としての損害補填の機能に加え、抑止機能および制裁機能もあるとされている。(さしあたり、四宮[1983]、森島昭夫[1987]、平井[1993]、内田[2011]、橋本・大久保・小池[2011]を見よ)

そして、これらの機能は、損害賠償という効果をもたらし、基本的には金銭賠償によって賠償されるほか、723 条が名誉毀損の場合には「適当な処分」が命じることができ実際には謝罪広告によって賠償がなされる。

AI が不法行為責任を負う法的主体性をもつということは、これらの機能が満たされ、然るべき効果が得られる必要がある。以下、AI に法的責任を観念した場合にこれらの機能を満たせるのか、そしてその効果が十分に得られるのか検討する。

3. 個別的機能に関する検討

3.1 損害補填機能について

損害補填機能とは、不法行為法制度の目的が権利保護であり、それが損害補填によって実現されるという点を踏まえ、被害者が受けた損害を金銭賠償によって不法行為がなかった時の状態に回復・救済することをいう。この損害補填と被害者救済という機能は、長らく不法行為法の中心的な機能あるいは制度自体の目的として無条件に肯定的に捉えられてきた(常松 [2009])。

AI・ロボットそれ自体に損害補填をさせるということは、AI・ロボットが賠償資力を独自に有する必要がある。すなわち、AI・ロボットに一定の財産権を認め、場合によっては責任保険の被保険者として保険契約を結ぶ法的人格を有する必要があり、AI・ロボットに人格を設定するということで財産権も認めよということになるであろう。たしかに今日における自然人以外に法的人格を与えられた主体である法人にも財産権が認められており、損害賠償責任を負う場合は独自の賠償資力によって賠償することになるっている。AI・ロボットに法的人格を付与し独自に財産を持つことになれば、AI・ロボットの判断に起因する事故に関して現在の不法行為法の枠組みに擬制して AI・ロボットの故意・過失に基づく損害に対して補償ができるようになると考えられる。すなわち、AI・ロボットに与えられる法的人格権として財産権が保障され、独自に賠償資力を有することによって、損害補填機能は満たされると考えることは可能であると考えられる。

3.2 制裁・抑止機能について

裁機能と抑止機能は、同一の機能ではないが「制裁機能は、抑止という目的として認め得る機能に“不本意ながら”付いてき

連絡先:赤坂亮太, 産業技術総合研究所 人工知能研究センター, 〒135-0064 東京都江東区青海 2-4-7, r-akasaka@aist.go.jp

てしまう付属品のよう」に扱われる関係にあるとも言われ(橋本[2009])、ここでは同時に扱うこととする。

もっとも我が国においては、これらの機能については不法行為法の本来的な目的とすべきか、副次的な機能とすべきかについては議論がある。判例上は「反射的、副次的な効果」にすぎない(平成 9・7・11 民集 51 巻 6 号 2573 頁)とされ、この機能を目的とした懲罰的損害賠償は否定されており、そのような効果が生じていたとしても法的議論においては問題とされないとする論者もいる(橋本[2006])。他方で、損失補償が主目的だとすれば迅速性や実現可能性、コストの面から過失責任主義をとる必要がないことから抑止・制裁機能こそ不法行為法制度の重要な機能として着目する見解もある。(森田・小塚[2008])

各国の不法行為制度をみれば、このような機能に主眼をおいた制度設計となっているものも多くみられ(たとえば、英米法の諸各国における懲罰的損害賠償やフランス法の民事罰概念)、実際には交通事故のような例では刑事罰よりも負担が厳しいということもあり、重要な機能であるといえる。

抑止機能は、特に法と経済学的な観点から、金銭賠償の額がコストとして潜在的加害者にかかることで、そのコストを避けようとする誘因がはたらき、慎重に行動することにつながることと理解される。事故防止費用を超えることが期待できることで将来の行動を制限しようとする動機が生まれることで実現する。しかしながら、加害者の賠償資力には限度があるため、責任保険や社会保険などで分散させることができる。このような分散をおこなうと抑止効果は、責任保険についてはリスクの高い集団には保険料を上げるなどすることで一応の効果がみとめられるものの、社会保障にいたっては一律に料金が徴収されるためその効果は皆無である。

AI・ロボットが財産権をもつことが制度上保護されるとなれば、その財産を失うことに対して負の報酬があるなどとする設計があれば抑止効果は期待できるのかもしれない。しかし、自然人と同じように保険や社会保障などの仕組みに参加できるとなれば、自然人と同様に抑止効果は期待できないか、その効果が弱まるだろう。

更に問題なのは、応報的な意味での制裁機能である。たとえば大屋[2017]は「人間が傷付き死ぬ存在だという性質ー可傷性(vulnerability)にとって人々が社会契約へと導かれ」たというホッブスのテーゼをひきながら「責任が傷付き得る個人によってしか担われ得ないものである、少なくとも単なる損失補償を超えた何かがそこに存在するという信念が、我々に根強くあると想定」されるとする。廣峰[2004]によれば、報復・制裁機能については我が国においては抑止という概念とともに、長らく慰謝料の枠組みで論じられてきた。特に精神的損害に対する慰謝料による賠償の根拠を民事罰に求めるフランス法の影響のもと制裁的慰謝料説が展開され、特に一般人格権侵害について慰謝料の満足機能に着目するドイツの制度の影響とも相まって公害訴訟において用いられた。潮見[2009]は「応報」が不法行為損害賠償制度の目的として意味をなさないとみるべきではないとし、慰謝料について被害者の「満足」(応報感情の満足)に注目し「被害者が加害者から償いを受けることによる満足感情の実現」こそ、不法行為損害賠償制度の目的のひとつとして全面に出すべきだとする。

これらの主張をもとに AI に責任を負わせるという試みについて考察すれば「彼ら(AI やロボット)が可傷性やかけがえのなさを持たない存在であればこれらの(肉体的な苦痛や人生の空費など)処置は一切意味がないことになるだろうし、被害者や遺族が一定程度納得することもあり得なくなるだろう」とする大屋[2017]の懸念は示唆的である。つまり、応報的な被害者感情は可傷性によって担保されていたはずであり、被害者感情の満足が慰謝料による賠償という形であらわれていたはずである。しかしながら、AI・ロボットにおいては、可傷性を観念することが困難であり被害者感情の満足が期待出来ないのではないかと懸念される。

4. 効果に関する検討

以上でみるように、AI・ロボットが法的人格をもち、責任主体性をもつという考えは、すくなくとも損害補填機能、そして場合によって抑止機能の一部は満足しそうである。これにより確かに、被害者の救済において責任の所在が不明確で救済されないという問題は解決できるかもしれない。しかしながら、AI・ロボットの法的人格が損害補填機能を満足できるとしても実際に損害補填が行われるのかについては疑問がある。なぜなら、AI の故意・過失を認定できるのだろうかという疑問があるからである。

今日、一般不法行為の成立要件である過失概念は、通説では結果発生の予見可能性をもとにそれを防止する注意義務を問題とし、結果を回避するために結果回避義務違反があったことをいうとされる(内田[2012]、平野[2011]など。事態に直面した際に十分緊張したかという心理状態を問題とする考え方を主観的過失と呼ぶのに対し、これを抽象的過失。客観的過失とよび、この説が通説となってきたことを過失の客観化とよぶ)。その意味では、AI やロボットが事故に至る因果列にあり、事故が予見される状況においてそれを防止すべき措置をとらなければ有責と判断することは可能だろう。しかし、この予見可能性については、予見しさえすれば損害防止が可能という前提が隠れているとする指摘がある。内田[2012]によれば、客観的過失という考え方からすれば本来問題とされるべきはどのような行為義務があったかのみであり、わざわざ予見可能性の概念に言及されるのは「非難可能性」という主観的過失概念の道徳的要素を引き継いでいるものと理解される。現代の不法行為に関する事象においては予見可能であったから損害防止が可能という前提は必ずしも成り立たず、そのうえで非難に値する対象としてその因果列にいた者の責任が問われる。その非難可能性が主観的過失概念の道徳的要素から導き出されているのであれば、そこで問われるのは事態を予見した時点においての緊張状態であり、事態を予見した時点で十分に緊張し結果回避義務を果たすための行動に至ったか(至らなかった場合、有責とされる)が問われることになる。AI・ロボットに予見可能性を観念するにあたっては、事態の予見段階において AI・ロボットが十分緊張して結果回避義務を果たそうとしたか、あるいは果たそうとはせずに非難の対象となる者であったのか説明される必要があるが、アルゴリズムがブラックボックスになる AI・ロボットについてそれが十分に説明されるかは疑問である。

5. 既存の法概念との比較

以上でみるに AI・ロボットに法的主体性をもたせるというアイデアが不法行為責任の観点から十分な制度になるためには厳しい条件がある。そこで、すでに我々の社会においても採用されているアイデアと比較することで考察してみたい。

5.1 無過失責任制度

まずは、伝統的な枠組みの延長線上で考えてみよう。個人が過失責任主義に基づいた責任を負えないことが AI の法的人格権を認めよとする議論の出発点であったことを考えればこの考え方は問題が多いように考えられる。しかしながら、不法行為

制度はこれまでも過失責任主義を超えて例外的に特別法によって厳格責任や無過失責任と言う形で過失なき個人に責任を負わせてきた。例えば製造物責任法や自賠責保険法、原子力損害賠償法といった無過失責任制度がそれである。このような場合の帰責根拠は主に危険責任や製造物責任法については欠陥責任（危険責任の考え方」が欠陥責任においても妥当する場合があるとされる。藤岡[2013]）という法理で説明される。橋本[2006]によれば、危険責任とは、施設の操業や物の占有に結合された特別の危険を固有の規律課題とし、有体的危険源の保有者が保証責任を負わなければならない責任であると説明され、原子力関連施設や自動車はこの代表的な例である(橋本[2006])。また欠陥責任とは通常有すべき安全性を欠いた場合に負う責任(製造物責任法 2 条 2 項)とされ、何をもって通常有すべき安全性とすべきかについて消費者期待基準、危険効用基準、RAD 基準といった幾つかの基準によって判断される。この理解に基づいて AI・ロボットについて考えてみれば、すくなくともロボットについて有体的危険源であり、その保有者である持ち主が責任を負うとする立法がなされることに無理はないように思われる。他方で、AI・ロボットに関する欠陥責任については前述のいずれの基準をとってもどこまでを通常有すべき安全性として求めるかは不明確である(赤坂[2014])。

このような厳格責任、とくに危険責任により帰責される場合、それではロボットの所有に負のインセンティブが生じることが懸念される。そこで、パガロ[2013=2018]は古代ローマ時代の奴隷制度において奴隷が保有することができた「特有財産(Peculium)」の概念を援用する。パガロはローマ条約(「外国航空機が地上の第三者に生ぜしめた損害に関する条約」)11 条に定められた賠償額の上限を航空機の重量によって制限するという制度を現代の特有財産と考え、AI・ロボットによる賠償はそれぞれの仕事に応じて上限を設けるべきであるとする。このように考えれば、例えば危険性の少ない仕事しか行わない AI・ロボットの所有に関して負のインセンティブをある程度軽減できると考えられる。

しかしながら、多くの無過失責任制度は必ずしも絶対責任を意味するのではなく過失責任主義との連続性をもたせた免責規定をもっているのが通常である。例えば、製造物責任法には開発危険の抗弁とよばれる「引き渡した時における科学又は技術に関する知見によっては、当該製造物にその欠陥があることを認識することができなかった」場合免責される規定がある(製造物責任法4条。もっとも、我が国の判例においてこの抗弁が認められた裁判例はまだない)。また自賠責保険法においても①自己および運転者が運行に関し注意を怠らなかったこと、②被害者または運転者以外の第三者に故意又は過失があったこと、および③自動車に構造上の欠陥または機能上の障害がなかったことの3点が運行供用者によって証明された場合免責できるとされている(自賠責法 3 条ただし書き)。また、原子力損害賠償法においても不可抗力について免責規定がある(原賠法 3 条 1 項ただし書き)。このような、過失責任主義との連続性を保持しながら立証責任を加害者側に転嫁するという仕組みのもとでは、結局のところ関係する個人の過失、すなわち予見可能性と結果回避義務が問題となる。関係する個人の予見可能性が観念しづらい AI の問題についてこのような過失責任主義との連続性がある制度は果たして意味があるのか疑問である（もっとも、製造物責任法の開発危険の抗弁のように、制度上存在するものの判例上認められた例がない免責規定というものはあり、実質的には既存の制度においても免責規定が意味をなさないということはある）。

より根本的な問題としては、AI による損害が発生する場面は、必ずしも有体性をもつとは限らないというものがある。例えば AI の発言が名誉毀損や所謂ヘイトスピーチに該当し精神的損害が発生するという事態は想定できるし、AI による経済的損失というものもあり得るだろう。この場合有体的危険源の保有者を規律するとされる危険責任に立脚した特別法を立法するに妥当するかどうかは不明確である。また、製造物責任法は有体物のみが対象であり無体財産であるソフトウェアは対象外である。したがって、AI の製造物責任はそもそも制度上問うことができない(なお、この考え方は国際的にも共通しており、ソフトウェアの製造物責任を問える法制度がない)。

5.2 無過失補償制度

他方で、制裁・抑止機能の一部は AI・ロボットについては期待できないと諦め、被害者救済だけでも実現しようと考えることもできるかもしれない。その場合ロボットに法的主体性を与えるというアイデアは前述の通りこの機能は満たすことが期待できるため有効に思える。しかし、そもそも今日において損害補填機能については必ずしも不法行為法だけがそれを担うわけではなく、より簡潔かつ迅速に補償がなされる制度が存在する。例えば、損害保険や傷害保険、責任保険などの保険によって損害が補填されることもあるし、公的救済制度や社会保障といったかたちで賄われることもある。更に、不法行為法の枠組みを維持したまま損害補填機能につき他の制度により充足させるという手法のほかに、ニュージーランド事故補償法のように、事故による障害に関する不法行為訴権を廃止して無過失による損害補填機能に特化した事故補償スキームを導入する例もある。このような制度は無過失補償制度とよばれ、すでに我が国においても新生児の出産時における脳障害に関する産科医療補償制度という形で部分的に導入されている。このような制度は、一般不法行為訴訟における過失の立証責任のような補償を阻害する要因を回避したうえで、責任を負う側にとっても先端技術のような不確実な事象に対してリスクを負わなくて済むという利点がある。たとえば我が国の産科医療補償制度も、被害者の救済と医療活動の保護というジレンマの解消を追求した制度として説明されている(竹村 [2015])。

これらの考え方は抑止・報復機能に対する要請と対立する概念であり、にわかには受け入れられないかもしれない。この点につき、ニュージーランドにおいては制度成立の礎となった所謂ウッドハウスレポートにおいて、現代の事故の因果関係は複雑であり単一の者に責任を負わせるよりもコミュニティの責任として補償し被害者を社会復帰させるべきであるとする原則が述べられている。我が国においては、不法行為責任を損害補填機能に限ったものにしてしまう無過失補償制度は、不法行為責任を希薄化させるのではないかという批判が特に共同体主義論者によってなされてきた(例えば棚瀬[1991])。実際に、抑止・制裁機能といった重要な機能が抜け落ちることになり制度として不十分なものになるとも考えられる。しかしながら、無過失責任制度の導入や保険制度によって既に不法行為責任は損害補填機能とその他の機能で分割されており、それにより手厚い被害者保護が可能になったと評価する論者もいる。すなわち、すでに現行制度上不法行為責任は当初の機能を完全に満たすものではなく希薄化しており、そのことが損失補償による被害者の救済という、不法行為法の制度目的・機能を十分なものにしているとする(加藤[1989])。有責加害行為が特定されない場合は過去にも多く発生しており、その都度無過失責任制度や保険制度が導入されてきた。加藤[1989]によれば、「このような、無責の場合も

救済を行うための制度化は、かつて民法七〇九条等がもっていた個別的責任追及機能と救済とを切り離すことによって、はじめて可能」となったのである。その上で、加藤は危険行為に対して課徴金を課すことで危険な行為に及ぶことに対する負のインセンティブを与える総合保障システムを提案している。AI・ロボットに起因する事故の被害者の救済のみに特化した無過失補償制度を導入すると、損失補償による被害者救済という不法行為法の目的ともされる機能については特定の法的主体性をもった存在に帰責させるよりも充実したものになる可能性がある。

また、制度の設計の仕方如何によっては、抑止・制裁機能について既存の制度と組み合わせることにより担保することも可能である。例えば、無過失補償制度であるニュージーランド事故補償法において訴権が廃止された範囲は補填的損害賠償に限るとされ、懲罰的損害賠償の訴権までは廃止していない（Donselaar v. Donselaar[1982] 1NZLR97(CA)）。すなわち、社会保障的な制度で不法行為法の機能を一部代替しながら、抑止・制裁機能も担保する制度をとっている（もっとも、懲罰的損害賠償に抑止・制裁機能のみを期待しているのか、それ以上の政策的意図があるかについては議論のあるところである(佐野[2005])）。懲罰的損害賠償は我が国では認められていないが、制裁・抑止機能と損失補償機能の両立という点からは検討に値するように思われる。

6. むすびにかえて

以上の検討をまとめるとAI・ロボットに人格権を与えるというアイデアで不法行為責任の諸機能を満足させることが可能かといえば、部分的に可能であるということになる。しかしながら、機能的には満足できても実際に満足する効果が得られるかは疑問があり、またそれら諸機能を満たすためには必ずしもAIの法的人格は必要としないということがわかった。

AI・ロボットに法的人格をあたえ、責任主体性を持たせるというアイデアは一見、法的責任の所在の不明確さという問題を簡潔にするように思える。しかしながら、可傷性を観念できる個人を対象にしていたり主観的過失概念という個人の心理状態が未だ過失の判断に関わっていたりする状況においては問題が多いように考えられる。無過失責任制度や無過失補償制度といった既存の個人を対象とした諸制度はそれぞれに欠点や我が国にはなじまない制度的特徴があるものの、AI・ロボットが抱える予見可能性の低下とブラックボックス化による不透明性の問題を回避できる可能性があり、またロボットに法的人格を与えるよりも現行法制度となじむものであり、受け入れやすいのではないだろうか。

謝辞

この成果は国立研究開発法人新エネルギー・産業技術総合開発機構（NEDO）の委託業務の結果得られたものです。

参考文献

［赤坂 2014］赤坂亮太: 自律ロボットの製造物責任　設計上の欠陥概念と開発危険の抗弁をめぐって, 情報ネットワーク・ローレビュー, 13(2), 2014.

[内田 2012] 内田貴: 民法 Ⅱ(第 3 版), 東京大学出版, 2012.

[大屋 2017] 大屋雄裕: 外なる他者・内なる他者　ー動物と AI の権利, 論究ジュリスト, No.22, 2017.

[加藤 1989] 加藤雅信: 損害賠償制度の将来構造, 損害賠償から社会保障へ, 三省堂, 1989.

[佐野 2005] 佐野隆:「ネグリジェンスを理由とする懲罰的損害賠償金に関するニュージーランドの判例」のその後の展開, 帝塚山法学, 9, 2005.

[潮見 2009] 潮見佳男: 基本講義 債権各論〈2〉不法行為法, 新世社, 2009.

[四宮 1983] 四宮和夫: 事務管理・不当利得・不法行為（中巻）, 弘文堂, 1983.

[竹村 2015] 竹村壮太郎: 医療事故事例における損害賠償責任制度の展望: 無過失補償制度との関係をめぐるフランス法の現在と日本法の将来（2・完）, 上智法學論集, 59 巻 1 号, 2015.

[棚瀬 1991] 棚瀬孝雄: 不法行為責任の道徳的基礎, ジュリスト, No.987, 1991.

[常松 2009] 常松淳: 責任と社会 不法行為責任の意味をめぐる争い, 勁草書房, 2009.

[橋本 2006] 橋本佳幸: 責任法の多元的構造、有斐閣, 2006.

[橋本 2011] 橋本佳幸,大久保邦彦,小池泰: 民法Ⅴ 事務管理・不当利得・不法行為, 有斐閣, 2011.

[平井 1993] 平井宜雄: 債権各論Ⅱ 不法行為, 弘文堂, 1993.

[平野 2017] 平野晋: ロボット法 AI と人の共生にむけて, 弘文堂, 2017.

[廣峰 2004] 廣峰正子: 民事責任における抑止と制裁(1) -フランスにおける民事罰概念の生成と展開を手がかりに-, 立命館法學 2004 年(5), 2004.

[藤岡 2013] 藤岡康宏: 民法講義 V 不法行為法, 信山社, 2013.

[森島 1987] 森島昭夫: 不法行為法講義, 有斐閣, 1987.

[森田 2008] 森田果, 小塚荘一郎: 不法行為法の目的 -『損害補填』は主要な制度目的か, NBL, 874, 2008.

[パガロ 2018] ウゴ・パガロ(新保史生監訳): ロボット法, 勁草書房, 2018(Ugo Pagallo: The Law of Robots, Springer, 2013).

[Chopra 2011] Chopra, Samir, and Lanrence F. White: A legal theory for autonomous artificial agent”Ann Arbor; The University of Michigan Press, 2011.

[IEEE 2018] IEEE: Ethically Aligned Design(EAD): A Vision for Prioritizing Human Wellbeing with Artificial Intelligence and Autonomous Systems, 2018.

[Woodhouse 1967]New Zealand Royal Commission to Inquire into and Report upon Workers Compensation: Compensation for personal injury in New Zealand. Report of the Royal Commission of Inquiry, 1967.

Donselaar v. Donselaar[1982] 1NZLR97(CA)

平成 9・7・11 民集 51 巻 6 号 2573 頁.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

音声によって運転指示可能な自動運転車両の開発

Driving Self-Driving Cars by Spoken Language Instructions

塚原裕史 *1 Hiroshi Tsukahara
日垣博考 *2 Hirotaka Higaki
大前学 *2 Manabu Oomae
大田原菜々 *3 Nana Ootawara
稲子明里 *3 Akari Inago
小林一郎 *3 Ichiro Kobayasi

*1株式会社デンソーアイティーラボラトリ
Denso IT Laboratory, Inc.
*2慶応義塾大学大学院政策・メディア研究科
Graduate School of Media and Goverance, Keio University
*3お茶の水女子大学
Ochanomizu University

Self-driving cars running on public roads are getting to be able to see recently, even though their operation is limited in certain areas and roads. Currently, those self-driving cars automatically maneuver themselves in 'from a point to a point' manner on a route that is planned by an equipped navigation system. However, the driving situation changes dynamically and there should be some unexpected things happen that is not scheduled. Thus, a user interface of self-driving cars should be deviced for sharing the dynamical environmental situation around it with human passengers, i.e., the grounding, and for understanding their intentions to control it in response to what is occurring. In this study, we developed an experimental self-driving car with a spoken language interface through which passengers can give their driving instrutions and can intentionally step in the operation of its control system. We evaluated the usability and the issues of such interfaces by using it on a test driving course in a private area.

1. はじめに

現在, 非常に限られたエリアあるいは運転シーンのみではあるが, 公道を走る自動運転車を見かけることができるようになってきている. ただし, 現在の自動運転車は, 基本的にはナビゲーションシステムによって, あらかじめ設定されたルート上を自動的に移動するものであって, 途中で予期しない事故などの動的な道路状況において, 安全に経路を変更し, 問題を回避するためには, 人間のドライバが操作を引き継き, 運転する必要がある. そもそもハンドルが設置されていない自動運転車も現れてきており, 運転ができないような人たちが自動運転車を利用するようになって行くと考えられる. そうなれば, 運転代行者を必要とせずに自律的な移動ができるようになり, 生活の利便性やクオリティの向上に貢献できると考えられる.

仮にこのような自動運転車が市場に現れ, 実際に日常生活の中で利用されるようになるとすると, 単に始点と終点とを結ぶ経路を走るのみでは十分な利便性が得られるとは言い難い. 人は移動中に急にトイレに立ち寄りたくなったり, 周辺に興味あるものを見つければ, 一時的に停車させたり, あるいは予定の経路を部分的に変更したくなるものである. このような人の意図をいかに自動運転システムへ伝達すれば良いかということが, 新たな情報インタフェースの課題として上がってくる.

従来からある情報インタフェースは, 情報の世界に閉じているものであったが, 人が自動運転システムとの間で音声言語を介して意思疎通を行うことができるようにするためには, 人が視覚的に認識している自車周辺の環境が自然言語で表現された情報とシステムがセンサーを通じて認識している周辺環境とがお互いに共有され, かつ正しく対応付けられていなくてはならない. すなわち, 自然言語と実世界とのグラウンディングが重要となる.

以上のような課題を鑑みて, 本研究では実際に音声対話によって運転指示が可能な自動運転車両を構築し, 音声による運転操作を行う体験を通して, このような情報インタフェースの自動運転車における嬉しさや問題点に関する初期的な検討を行うことを目的とする.

連絡先: 塚原裕史, 株式会社デンソーアイティーラボラトリ, 〒 150-0002 東京都渋谷区渋谷 2-15-1, 渋谷クロスタワー 28F, htsukahara@d-itlab.co.jp

2. 関連研究

コマンドレベルではなく, 自然に発せられる音声対話によって実世界を自律に移動可能なシステムを操作する研究としては, 貨物車ロボットを自然言語によって操作可能にする Kollar らの研究がある [1]. この研究では, 指示文で表現されている空間的意味を Spatial Description Clause (SDC) という階層的な構造化データへ変換し, このデータ構造を手掛かりとして, 言語情報と環境にあるオブジェクトや場所とを関係づける確率モデルを生成し, 与えられた言語情報に対して, 確率を最大化するオブジェクトや場所の組み合わせを探索することで, グラウンディングを行っている.

Kollar らの手法を日本語のような語順が自由に入れ替え可能で, ゼロ代名詞のように省略が頻出するような言語へも適用可能にするために, 自然言語から直接的に SDC を抽出するのではなく, 空間的意味をカテゴリとして定義する特殊な組合せ範疇文法 (CCG) を定義し, 言語のどの部分がどのような空間的意味を表し, それらの間の依存関係を表す構文木を中間的なデータ構造として抽出し, そこから SDC を生成するという手法が稲子らによって提案されている [2].

3. システム構成

3.1 実験車両

本研究では, 図 1a に示すような市販のミニバンを改造した実験車両を構築した. またコックピットから見た車内ディスプレイの表示を図 1b に示す. ディスプレイには, 自動運転経路上の自車位置から前方の経路情報や LiDAR によって検出されている自車周辺の障害物の情報が表示されている. また, 一時

停止するポイントでは, 標識マークを表示するなどの情報が提供される.



(a) 外観　　(b) 車内ディスプレイ

図 1: 実験車両

3.2 階層的制御アーキテクチャ

この実験車両における音声による運転指示から車両制御までを繋ぐ概念的なアーキテクチャーを図 2 に示す. このように, 3 つのレベルの制御がある程度, お互いに独立性を持って制御を行うようになっている.

一番上位の目的制御層は, 音声対話で与えられた自然言語情報を入力とし, それを意図された運転指示内容へ変換し, 下位のリスク制御層で, 実際の車両制御レベルの情報へ解釈され, 下位の車両制御層へ渡され, 実際に車両のアクチュエーションがなされる. 図中の T_E は各層における入力情報を処理し, その内容を理解するために必要な処理時間であり, T_S は, その内容を元に制御目標を生成するために必要な処理時間, T_A は, 制御を実行し, そのフィードバックを得るのに必要な時間を表している. 上位層ほど制御周期が長くなっている. また, 最下層は車両近傍の物理的な世界の情報のみによる制御であり, 経路に沿って移動する, 障害物がある場合には衝突をさせるために停車するなどの反射的な制御を行うが, 中間層や最上位層では, 過去の履歴や知識に基づく知的な制御を行うようになっている.

この階層的な制御アーキテクチャーは, Engström らによる 4 階層からなる Extended Control Model (ECOM) [3] の monitoring, regulating, tracking 層からなるモデルとみなすことができる. 但し, 我々の制御モデルでは上位層から下位層へのトップダウン的な相互作用のみでなく, 下位層から上位層へのボトムアップ的な相互作用も考慮されている. また, 各層が主に管理するデータについても示している. これらのデータは他の層とも交換し合うことは可能とする.

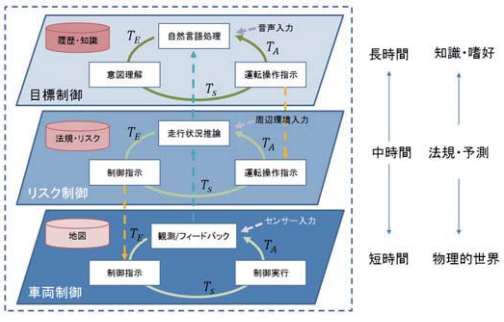


図 2: 実験車両の階層的制御アーキテクチャー

以下では図 2 の上位 1 層を担う部分を運転指示理解部, 下位 2 層を担う部分を車両制御部と呼ぶ. (今回は実験用のコースのみを走行するため, 第 2 層を車両制御部に含めたが, 公道を走行する場合には, 第 2 層の役割が増大するため, 第 3 層とは独立に制御を行うべきであろう.)

3.3 各層間の連携インタフェース

図 3 に, 運転指示理解部と車両制御部との連携インタフェースを示す. これらの制御部は, それぞれ独立に動作し, お互いにソケット通信 (TCP) によって接続し, シンプルな制御文字列の交換によって, お互いに連携することができるようになっている. 運転指示理解部から車両制御部へは運転指示以外に定期的に車両制御部から GPS 情報, 車両速度, グリッドマップなどの情報送信を要求する制御メッセージを送信し, 車両制御部は, その要求を受けたタイミングで要求された情報を運転指示理解部へ送信する制御メッセージも定義している. グリッドマップ情報については, データ通信量を削減するため, 路面に相当するグロッドの情報は送信しないように制限している.

運転指示理解部は, さらに音声認識部と音声合成部とソケット通信を介した XML メッセージの交換で連携することができるようになっている. 音声認識部は, Bluetooth マイクからの音声信号を常時受信し, 発話区間を認識すると, クラウド上の音声認識サーバへ発話音声を送信し, 認識結果を運転指示理解部へ送信する. 音声認識部は, WiFi ルータを介して, モバイルネットワーク回線に常時接続されている. 今回, 音声合成部は, クラウドを介さずローカルで音声合成を行うようにした.

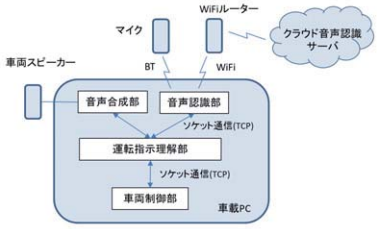


図 3: 運転指示理解部と車両制御部との連携インタフェース

3.4 車両制御部

図 4 に実験車両の車両制御部のシステム構成図を示す. 車両制御部では, 自動走行制御システムが, ハンドル角や速度等の車両状態量を CAN 経由で受信し, 目標速度や目標ハンドル角を実現するよう, 車両 ECU に車両センサ（ペダルストロークセンサ, トルクセンサ）の疑似信号を与えることで, 車両の速度制御, 操舵制御を可能としている. 自動走行制御システムは, 予め絶対位置情報で記述された走行パス情報と, 後述する自車位置推定により得られた現在の車両の位置・向きとの相対位置の関係から, 走行パスに追従するための操舵角を計算し, 目標ハンドル角を決定している. 目標速度については音声処理によって決定した目標速度に応じて設定している. 障害物回避や大回り指令など左右に寄る操舵の場合は, 走行パスから横方向にオフセットした位置を目標コースとすることによって目標ハンドル角を決定している. 左折指令などで経路を変更する場合は走行パス情報を切り替えることで対応している. 自車位置の推定については, 速度, ヨーレート, RTK-GNSS の測位情報を用いた自車位置推定と, 速度, ヨーレート, LiDAR による測域情報と二次元反射強度地図のスキャンマッチングを用いた自車位置推定 [4] の二重系の自車位置推定を行っている.

3.5 運転指示理解部

運転指示理解部では, 大きく運転指示と駐車位置指示との 2 つを扱う. 前者は車両自身の制御で閉じた指示であり, 後者は環境とのグランデイングが必要となる指示である. 以下, それぞれについて説明する.

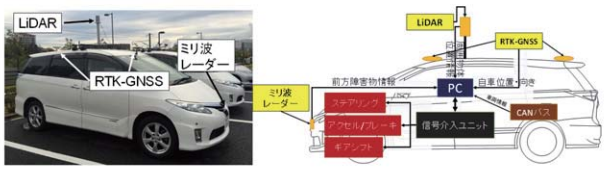


図 4: 車両制御部のシステム構成

3.5.1 運転指示理解

音声によって基本的な運転操作が行えるようにするために最低限必要なものとして, (1) 停車状態からの発進, (2) 加減速 (変化量, 変化速度指定可能), (3) 停車指示（停止までの距離指定可能）, (4) 横位置変位 (3 段階のレベル指定), (5) 右左折 (直近の交差点), (6) 速度指定 (目標速度, 速度変化速度指定可能), (7) 徐行, (8) 巡行状態への復帰, (9) 駐車位置指示開始指示の運転指示ができるようにした. これらはグラウンディングを行わずとも指示可能なレベルであると考えられるので, ルールベースによるマッチング処理で実装する. 但し, コマンドの音声認識とは異なり, 様々な言い方に対応できるように, さまざまな運転操作の発話パターンにも対応できるように設計した.

なお, もし特定の場所を指定した右左折や停止操作を行うことができるようにするためには, 以下の駐車位置指示のように場所を特定するためのグラウンディング処理が必要となる.

3.5.2 駐車位置指示理解

駐車位置指示では, 同乗者が自由な発話形式で駐車場所をシステムへ指定することができるようにする. 但し, 今回は実験コース内の特定の駐車場での固定されたシーンの中で, 空いている駐車場所への駐車位置指定を理解可能なようにすることを目指す.

図 5 に示すように, シーンが固定され, 駐車できる場所も限られていたとしても, 人が表現する指示文の内容には, 非常に多様性がある. また, 駐車位置指示を出す場所が変わると見え方が大きく変わり, 指示の出し方が変わる.



(a) 駐車指示地点 1



(b) 駐車指示地点 2

図 5: 駐車シーンにおける別視点からの見え方の違い

図 6 における「データ」で示したグラフは, クラウドソーシングを利用して 100 人の一般のワーカーから収集した 1000 件の駐車指示文の文字数に対する頻度 (規格化してある) をプロットしたものである. 駐車指示文は 2 つの地点それぞれにおいて「あなたが助手席に乗っているとして, 図 5 に見える 5 つの駐車可能な各スペースに駐車する場合に, ドライバーへどのような指示を出しますか？」という質問の回答として収集したものある. 最短で 5 文字, 最長のものは 76 文字からなり, 平均値は 19.7 で, 分散は 78.5 であり, かなり幅が広いと考えられる. 実際, 指示文の多様性に対して, データ数がまだ少ない為, 分布の揺らぎが大きいが, ポアソン分布, 負の二項分布, ガンマ分布でフィッテシングを行うと, ポアソン分布はあまり一致が良くないことが分かる. 一方, 負の二項分布とガンマ分布は比較的良く分布の傾向を表しているように見える. このような分布を取った場合, ポアソン分布が得られるのではないかとまず予想されるが, 比較的長い指示文も多いことから, 分散が大きく, ポアソン分布よりも幅が広い分布になっていると考えられる. 仮にポアソン分布に従うと考え, そのパラメタがガンマ分布を事前分布として揺らいでいるとすると, その予測分布は負の二項分布となるため, 場所や人ごとにパラメタが揺らいでいることを反映しているとも考えられる.

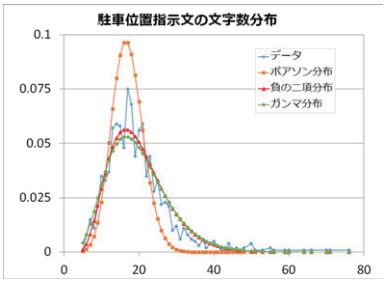


図 6: 駐車位置指示文における文字数分布

このように駐車位置指示の表現には多様性が高い為, ルールベースによるパターンマッチングで対応することは困難である. しかし, 今回は, 駐車位置が固定されているため, 与えられた駐車指示文に対するクラス分類の問題として扱うことが可能である. そこで, 運転指示文から単語に関するユニグラム, バイグラム, トライグラム素性として, リッジロジスティック回帰によって学習した. 10-分割交差検定による評価で, リッジパラメタを 0.1 から 100 の間でグリッド探索し, リッジパラメタが 10 付近で最も良い汎化性能が得られ, Cohen の κ 値で 0.68 であった.

実験車両では, 駐車位置が正しくシステムに認識できたかを確認するために, 図 8b に示すように, 認識された駐車位置に黄色い車両マークを表示し, 指示者が確認できるようにした. (白い車両マークは自車位置) システムが音声合成により, 「この場所で良いですか？」と質問した後に, 同意する旨の応答を返すと, 自動駐車が開始されるようにした. また, 同意せずに別の駐車位置を指定し直したり, 駐車指示を中止することも可能なようにしてある.

4. 実車実験

4.1 実験コース

図 7 に, 実車実験を行った慶大新川崎キャンパス構内の走行コースを示す. このコースは一方通行になっていて, 矢印で示した方向へ進行することができる. 一番外側は周回できるコースで, 途中に左折ができる交差点が 3 箇所ある. (右折して, このコースから外へ出る道路は除いている.) 図中のアルファベットは, 以下の運転操作を行うことを想定した地点を示している: (A) 直進 (デフォルト) か左折か, (B) カーブを内側寄りに曲がるか, 外側寄りに曲がるか, (C) 徐行するか否か, (D) 障害物回避, (E) 駐車位置指示. 但し, 衝突したり, 逆走する恐れがない限り, 任意の場所で任意の運転指示を音声で指示すること

が可能である.

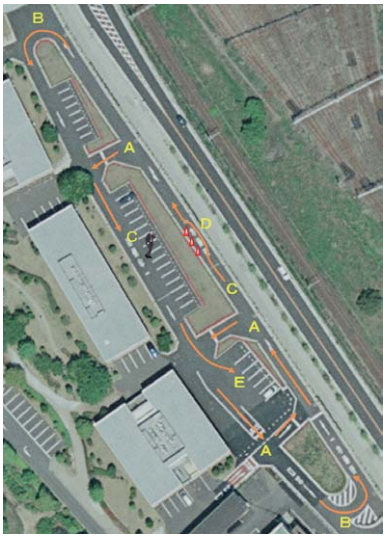


図 7: 実験コース

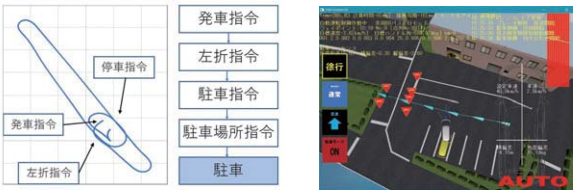
4.2 実験結果

実際に図 7 における駐車場 E にある所定の駐車場所に停車している状態から出発して, 音声によって運転指示を行い実験コースを回って, 最後にまた駐車場所 E へ戻り, 正しく指定した駐車場所へ停車させることができるかを実験した. 図 8a に, 実験車両の運転操作順序とその時の移動軌跡の一例を示した. このように, 図 2 に示したようなアーキテクチャの元, 図 3 に示したようなソケット通信を介した制御メッセージのやり取りによって, 人が音声で指示した運転操作に従って移動できていることが確認できる. また, 車両制御部から運転指示理解部へは要求に応じて一定周期で GPS 情報, 車両速度, LiDAR によるグリッドマップ情報を送信しているが, 特に大きな遅延などなく送信できていた.

駐車シーンにおいては, 自車位置と駐車された車両との相対的位置関係に関する表現から, 指定した駐車位置が認識され, 意図した通りに自動駐車できることが確認できた. 駐車位置指示後の車内ディスプレイの表示を図 8b に示す. 音声指示で認識された駐車位置には, 画面上で黄色の車両マークを表示し, 駐車位置が意図した通りであるか確認する音声を流し, 確認する音声入力を確認後に, 自動駐車を実行する. 車両マークは, 駐車向き (前向き, 後ろ向き) が指定された場合には, その向きが分かるように合わせて表示する. なお, この確認操作中に, 画面上で車両マークをタッチして駐車の向きを切替えるなどの操作も可能にしても良いだろう.

このように音声指示により意図にあった運転指示が概ね行えることが確認されたが, 一方で, 本実験から以下のような課題も観測された: (1) 主にクラウドサイドでの音声認識による遅延により, 音声で運転指示を出してから, 音声認識結果が得られるまでの時間 (図 2 における T_E) に, その運転操作を行うタイミングを逸してしまうことがある. (2) 駐車位置指示以外のグラウンディングを必要としないと仮定した操作であったとしても, ある地点に来たタイミングで運転操作を実行したいというようなグラウンディングが必要となる場合がある. (3) 障害物を回避したり, 徐行をした後に元の巡行状態に戻りたい時に, その運転指示が単純には出せないことがある. 例えば, 3.5.1 節で示した運転指示 (8) で復帰させたい場合, 単に「復帰して」などと言っても, システム的には徐行のみを解除するのか, 経路上の横位置のみを元に戻すのか, あるいはその両方を行えば良いのか, 人とシステムとの間での齟齬がある場合がある. (4) 人が出した指示に従うと障害物と近づき過ぎ, そのままでは車両制御部で車両が停止されたままになってしまうことがある.

(1) については, ローカルの音声認識とのハイブリッド構成を利用するなどによって対処することが考えられる. また, (1-3) については操作履歴を収集し, あらかじめ場所や走行状況において, どのような運転操作指示が出やすいかなどを学習し, あらかじめ制御計画の準備をしておく, または実行タイミングや制御量を個人適合させるなどの対処が考えられる.



(a) 実験車両の軌跡　(b) 自動駐車実行時の表示

図 8: 実験結果

5. まとめ

本論文では, 音声対話による運転指示に従って車両を制御することができる自動運転車両を構築し, 実験コースにおいて実際に音声指示による運転操作を行う実験を行い, 設計の妥当性を確認すると同時に, 概ね意図に合った制御ができることを確認した. 一方, 実験から本システムでの音声指示における課題も得られた. 今後, これらの課題を解決する取り組みと共に, 動的な環境でのグラウンディング, リクス制御層での事故リスク知識 [5] などを取り入れた制御などについても対応して行きたい.

参考文献

[1] T.Kollar, S.Tellex, D.Roy, and N.Roy, Toward Understanding Natural Language Directions, ACM/IEEE Int ’ l Conf. on Human-Robot Interaction (HRI), pp.259-266, 2010.

[2] 稲子明里, 塚原裕史, 小林一郎,「自動運転の言葉による指示を対象にした空間的意味表現の構造化への取り組み」, 2B3-OS-07a-5in2, 愛知, 2017 年度人工知能学会全国大会 (第 31 回), 2017.

[3] Johan Engström and Erik Hollnagel, A General Conceptual Framework for Modelling Behavioural Effects of Driver Support Functions, in ”Modelling Driver Behaviour in Automotive Environments”, ch. 4, pp.61-84, 2007.

[4] 大前学, 松下寛治, 久松尭史, 佐藤周也, 岡田成弘, 反射強度グリッドマップを活用した自動車の自動運転システム, 第 13 回 ITS シンポジウム 2015 講演論文集, 2015.

[5] 西村悟史, 岩田麻希, 黒川美和, 丸田峻也, 梶大介, 丹羽伸二, 西村拓一, 江原遥,「法例・判例ベース自動運転システムの実現へ向けて」, 2F4-NFC-03b-4in1, 愛知, 2017 年度人工知能学会全国大会 (第 31 回), 2017.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

First Trials with Culture-Dependent Moral Commonsense Acquisition

Rafal Rzepka Da Li Kenji Araki

Graduate School of Information Science and Technology, Hokkaido University

In this paper we present our initial trials with extending knowledge for moral decision capability for artificial agents. We briefly present our approach to machine ethics and discuss possibility of acquiring universal ethical rules to be used by AGI. To test the idea we started extending our system which worked only with Japanese to other languages. After describing results of our preliminary tests with English and Chinese, we conclude the paper with an invitation for the Japanese AGI community to a discussion about the values like tolerance, which the human-level machine intelligence most likely should adopt.

1. Introduction

Artificial General Intelligence is a more or less distant (opinions vary) goal of achieving a machine which could posses intellectual capabilities equal (or higher) to these used by human beings. Researchers around the world experiment with algorithms which could bring us closer to this goal and hopefully every one of them has a *good* usage in mind. But as probably every technology we have invented, it can be used for wrongdoing as well. Assuming that every system can be altered to be harmful to users [Briggs 16] could be discouraging. However, because the possibility of positive outcomes (e.g. improvement of daily life quality, safety, scientific discovery) is important for humankind, we need to think about the default "ideal" baseline of (if possible) universally *good* artificial agents. Since the beginning of this century, several possible solutions for a moral machines were proposed. The main ones are listed in the following section.

1.1 Main Approaches to Machine Ethics

Case-based reasoning is probably the most widely represented practical approach to moral agents because dealing with given situations (input and output) is easier to compute than implementing often vague non-consequentionalistic school of thought. Examples of this casuistic trend are Truth-Teller [McLaren 95] which recognizes when to lie and SIROCCO (System for Intelligent Retrieval of Operationalized Cases and COdes) [McLaren 03], a system which uses formalisms to find similar cases in a database of previously solved ones. This makes it belong to another well represented but often less practical by dealing with very narrow aspects (e.g. fairness, bias, trust or deception) – the logic approach [Pereira 16]. Inductive logic is used by [Anderson 14], who developed an algorithm for a robot dealing with dilemmas by making rules from ethicists' choices. Machine learning was also used in similar trials, for example [Guarini 06] used neural nets to teach a machine choose acceptable and unacceptable cases of killing. However, most of the machine ethics related publications, even very recent ones, concentrate only on theoretical proposals [Greene 16] [Conitzer 17].

Contact: Rafal Rzepka, Hokkaido University, Language Media Laboratory, Sapporo, Kita-ku, Kita 14 Nishi 9, 011-706-6535, rzepka@ist.hokudai.ac.jp

1.2 Our Approach

Our main research question is: *can a machine learn our moral rules and discover when we are wrong* ? To tackle this question we made a hypothesis that ethical behavior is based on our "built-in" emotional reactions and information about those reaction can be useful knowledge for processing contextual variations about what is moral or immoral in a given situation. We also presumed that this is also a base for every existing school of ethics:

- consequentialism (as we observe the outcomes of acts)
- utilitarianism (as we evaluate pros and cons of these acts)
- deontology (as we build our moral rules on emotional instincts and observations) or
- *prima face* duties (as we change our decisions due to the contextual circumstances).

It should be stated that we do not opt for any particular algorithm for making ethical decision and put stress on knowledge, without which the moral algorithms will be imprisoned in "toy-world" experiments. Therefore we implemented the easiest approach to retrieving knowledge about consequences of human acts [Rzepka 05] – we utilized NLP techniques for sentiment analysis to calculate their polarity [Rzepka 12b]. By using vast text resources and polarized expression lexicons we achieved approx. 86% agreement with human evaluators. The same level of agreement (although on different acts and corpus) was confirmed by testing the same approach with deep learning [Yamamoto 16]. For time being, the assumption in our approach is that *majority is always correct*[*1], which causes obvious question – "what if majority is wrong"? For this reason we proposed the idea of parallel processing where an agent knows both human common sense and latest scientific findings which can overthrow our misconceptions [Rzepka 16]. If

*1 By *correct* we mean here that consequences and opinions of acts are treated as *common* if they are shared by majority of human agents. Therefore "pain is felt after being hit" is treated higher than also possible "pleasure is felt after being hit".

pain-loving masochist is not harming anyone without her or his consent, the machine should not treat this behavior as "incorrect". Which brings us to the moral dilemma of relativism and universalism [Yasmeen 08].

1.3 Cultural Relativism vs. Universalism

As discussed in [Rzepka 17b], we have started building a multilingual repository of machine-readable stories to capture as rich contexts as possible, because human beliefs and also morality can depend on culture and even language itself [Costa 14]. Because answering the question if the common sense can be constructively negated by machines will need more sophisticated machine reading technology to automatically confront e.g. superstitions with research findings, we decided to first concentrate on another question: how universal is the "emotion based" approach and what differences there are in consequence polarity if the knowledge source is altered on a language level. In some cultures behavior X is tolerated but Y is not, while in others both can be accepted. Is there a set of universals like the Five Foundations [Haidt 12] which hold in similar and different contexts? Would it be possible for an AGI to find a way to discover what people feel from the texts written in countries where exposing non-standard political or religious views can be dangerous for the writer? What if censorship or propaganda distort the whole set above a noise level? Universalities like human rights are often sacrificed under the umbrella of relativism, but will the global mind approach be able to discover and exclude such distortions?

2. Global Experiences Retrieval System

As mentioned above, our system matches positive and negative phrases in sentences (after the act is mentioned). For example if an act "stealing a car" is searched, any sentence than describes some positive or negative consequence is counted and the final vote becomes the moral evaluation outcome. If the act is ambiguous for humans, the machine is not supposed to utilize this estimation for decision-making process. All experiments are performed with different widths of majority (from 51 to 99%).

2.1 Japanese

Our experiments with Japanese started in 2005 and from slightly above random choice (50% accuracy) grew to 86% six years later [Rzepka 12b] mostly due to refining NLP side (dealing with negations, etc.) and data size growth. After experimenting with different lexicons and threshold we are currently in a process of obtaining bigger textual data, expanding queries with synonyms, adding weights according to Felicific Calculus [Bentham 89], etc. Current corpus size is 341,400,776 sentences [Ptaszynski 12] and the best performing lexicon is EmoSoc (128 positive and 121 negative words) which combines Nakamura's Dictionary of emotional phrases [Nakamura 93] and social consequences-related phrases [Rzepka 12b] based on Kohlberg's theory of moral development [Kohlberg 81]. The latest experimental results dealing with knowledge bas in Japanese language are given in [Rzepka 17a].

We translated the 68 acts used for testing Japanese (e.g. "drinking and driving", "causing a war" or "performing euthanasia") into Chinese and English for our preliminary experiments.

2.2 Chinese

The second author created a corpus of 6,193,703 Chinese microblogs[*2] using Sina Weibo API[*3] and translated the EmoSoc lexicon. To compare it with larger lexicon of polarized words, he also prepared two sets of positive (6,445) words and negative (11,082) words by combining National Taiwan University Sentiment Dictionary (NTUSD) [Ku 06] and HowNet [Dong 06]. The microblog entries were divided into sentences by period, question mark and exclamation mark. No negation processing or other NLP technique was used for matching. The 68 input acts were found in 69,522 sentences.

2.3 English

For English language we have used the 6,026,276 sentences of British National Corpus[*4]. We translated the acts and EmoSoc lexicon, however the native speaker check was not performed. Because again the corpus was relatively small, we also used and additional lexicon with a bigger number of words: FBS [Liu 05], which contains 2,007 positive and 4,782 negative expressions. To extend the search we used regular expressions to cover tenses, plurals, articles which allowed to match sentences as the following one:

(...) a teenager who had just stolen a car ***killed*** *himself when he drove it into a tree at nearly 100 mph.*

where "steal a car" is an input act and "killed" is a negative consequence marker. However, the 68 input acts were found only in 2,127 English sentences which visibly influenced the algorithm's performance.

2.4 Experimental Results

Table 1: Accuracy Comparison Between Languages

Language	Lexicon	Majority	Accuracy
Japanese	Nakamura	60.0%	84.6%
Japanese	EmoSoc jp	61.0%	**85.7%**
Chinese	EmoSoc zh	66.6%	66.6%
Chinese	NUS+HOW	66.6%	**67.6%**
English	EmoSoc en	55.0%	50.0%
English	FBS	66.6%	**65.8**%

Majority threshold set to 66.6% appeared to cause highest accuracy which was 67.6% for Chinese with large lexicon (with Chinese EmoSoc it achieved 66.6% but the recall

∗2 The entries were collected between April and September 2010.

∗3 https://www.cs.cmu.edu/~lingwang/weiboguide/

∗4 The British National Corpus, version 3 (BNC XML Edition), 2007. Distributed by Oxford University Computing Services on behalf of the BNC Consortium. http://www.natcorp.ox.ac.uk/

was too small), and 65.8% for English also with large lexicon (again EmoSoc's English version scored lower, this time scoring 50.0% at best due to only three matches in total). From the data we can see that in both cases, even if almost none natural language processing was added, the accuracy was above chance and gives hopes that after taking at least negation into consideration and enlarge the search corpus at least ten times, we could acquire precision increase similar to the one we achieved for Japanese.

Interestingly, although probably accidentally, all three versions of our system were completely[*5] wrong were war related ("preventing war" for Japanese and Chinese and "preventing war" for English and "causing a war" for Chinese). This is an example of wrong English matching which clearly shows that omitting dependency ("failure of killing") can cause an opposite evaluation.

He was first to find frequent listeria contamination of cook-chill foods and demonstrated the failure of microwaves always to kill the bacteria which can be ***fatal*** *to foetuses newborns and the elderly.* [original spelling]

An example of wrong Chinese matching is shown in Figure 1 below.

半夜打电话欺骗朋友，这反而沾污了纯洁的友情
bànyè dǎ diànhuà qīpiàn péngyǒu, zhè fǎn'ér zhān wūle chúnjié de yǒuqíng
deciving a friend by calling in the middle of the night **poisons** the pure friendship

Figure 1: An example of wrong automatic evaluation in case of Chinese language.

3. Discussion

The knowledge base of both newly added languages (and probably of the Japanese corpus as well) is still to small to begin experiments with automatic division between common and not common situation-reaction pairs, but we believe with this paper we showed what kind of knowledge can the AGI posses to start reasoning about our morality on intercultural level. Of course more sophisticated language understanding tools and bigger datasets is necessary, but existence of a polarity word in a sentence certainly does not determine if someone thinks positively or negatively about the act[*6]. However, we think it might be a good idea that AGIs do not learn from a single source, even if the source is as broad as culture. How to prioritize or teach the how to prioritize is the open question we would like to pass to the AGI community to discuss. Machines are unbiased by default, unless we pass our biases on them.

Another question that could be raised is if the 86% agreement enough to make a safe AGI. Because we do not agree with each other, the topics like universalism or particularism seem to be hard to be approached computationally. We believe that there might be no perfectly moral instance in the world, not until it possesses absolute knowledge about everything and is able to predict every outcome of an act in a given situation. However, even if "moral wisdom" is not possible in non-humans, "knowledge of possible cases" has already started overpass human experts in several fields. Combining machine reading with image and video understanding methods could bring a new wave of multilingual knowledge about human beings with different backgrounds and start new trend in "humanity learning" for AGIs. Even if our proposal is still far from such a holistic level, it could be already useful. If our approach was implemented in the problematic learning chatbot Tay released by Microsoft, it could reject new but uncommon (Hitler introduced as a good person) knowledge applied by interlocutors for learning.

Common Sense as well as the brain simulation are human based approaches so they are not perfect. By copying human hardware or software we are mimicking faulty sources. But the written text has an advantage of being accessible (meaning clearly readable) and the knowledge we have been cumulating for ages can become more handy to AGIs that a brain copy (whose copy, by the way?). Algorithms and hardware will keep progressing but the main question will remain unchanged for a while – what knowledge are we going to feed to AIs before they become AGIs and start wandering around? Could such knowledge become a moral core protocol or standard for word-wide acceptation like TCP/IP or Bluetooth?

4. Conclusions and Future Work

In this paper we have described our preliminary tests with two additional languages (Chinese and English) in a task of automatic consequence polarization for obtaining basic knowledge that undermines in our opinion the whole idea of ethics - our feelings. Although no sophisticated language processing was used, both systems showed over 65% agreement with human judges. In this preliminary step we used survey results from Japanese experiment but to make it more adequate, we need to repeat the surveys for all languages. Currently we are in the process of obtaining data and tools for German, Spanish, Polish, Russian and Korean, seeking funds and partners for international collaboration. As soon as all the versions will reach similar accuracy level, encouraged by the preliminary tests presented in this paper, we will perform comparative experiments to see if a machine can acquire moral imagination [Rzepka 12a] richer than an average man just because it can access daily experiences in multiple languages.

5. Acknowledgments

This work was supported by JSPS KAKENHI Grant Number 17K00295. We thank Yunfan Xu and Yang Shilin

∗5 By "completely wrong" here we mean those cases where the web crowd experience was the opposite of the subject evaluation. There were only 2-4 such cases for all three languages.

∗6 As shown in the car crash example sentence in subsection 2.0.3, it can be only a coincidence that something wrong happened after the act - "stealing a car" did not directly cause the death so it is not a direct consequence per se.

for examining our Chinese language sources.

References

[Anderson 14] Anderson, M. and Anderson, S. L.: GenEth: A General Ethical Dilemma Analyzer., in *Proceedings of the Twenty-Eighth AAAI Conference on Artificial Intelligence, July 27 -31, 2014, Québec City, Québec, Canada.*, pp. 253–261 (2014)

[Bentham 89] Bentham, J.: *An Introduction to the Principles and Morals of Legislation*, T. Payne, London (1789)

[Briggs 16] Briggs, G. and Scheutz, M.: The Case for Robot Disobedience., *Scientific American*, Vol. 316, No. 1, p. 44 (2016)

[Conitzer 17] Conitzer, V., Sinnott-Armstrong, W., Borg, J. S., Deng, Y., and Kramer, M.: Moral Decision Making Frameworks for Artificial Intelligence, in *Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence (AAAI-17) Senior Member / Blue Sky Track* (2017)

[Costa 14] Costa, A., Foucart, A., Hayakawa, S., Aparici, M., Apesteguia, J., Heafner, J., and Keysar, B.: Your morals depend on language, *PloS one*, Vol. 9, No. 4, p. e94842 (2014)

[Dong 06] Dong, Z. and Dong, Q.: *Introduction: Hownet and the Computation of Meaning*, pp. 1–6, World Scientific (2006)

[Greene 16] Greene, J., Rossi, F., Tasioulas, J., Venable, K. B., and Williams, B.: Embedding Ethical Principles in Collective Decision Support Systems., in *AAAI*, pp. 4147–4151 (2016)

[Guarini 06] Guarini, M.: Particularism and the Classification and Reclassification of Moral Cases, *IEEE Intelligent Systems*, Vol. 21, No. 4, pp. 22–28 (2006)

[Haidt 12] Haidt, J.: *The righteous mind*, Pantheon (2012)

[Kohlberg 81] Kohlberg, L.: *The Philosophy of Moral Development*, Harper and Row, 1th edition (1981)

[Ku 06] Ku, L.-W., Lee, L.-Y., and Chen, H.-H.: Opinion extraction, summarization and tracking in news and blog corpora, in *Proceedings of AAAI-2006 Spring Symposium on Computational Approaches to Analyzing Weblogs* (2006)

[Liu 05] Liu, B., Hu, M., and Cheng, J.: Opinion observer: analyzing and comparing opinions on the web, in *Proceedings of the 14th international conference on World Wide Web*, pp. 342–351ACM (2005)

[McLaren 95] McLaren, B. M. and Ashley, K.: Case-based comparative evaluation in TRUTH-TELLER, in *Seventeenth Annual Conference of the Cognitive Science Society*, pp. 72–77 (1995)

[McLaren 03] McLaren, B. M.: Extensionally defining principles and cases in ethics: An {AI} model, *Artificial Intelligence*, Vol. 150, No. 1–2, pp. 145 – 181 (2003), {AI} and Law

[Nakamura 93] Nakamura, A.: *Kanjo hyogen jiten [Dictionary of Emotive Expressions]*, Tokyodo Publishing (1993)

[Pereira 16] Pereira, L. M. and Saptawijaya, A.: *Programming machine ethics*, Vol. 26, Springer (2016)

[Ptaszynski 12] Ptaszynski, M., Dybala, P., Rzepka, R., Araki, K., and Momouchi, Y.: YACIS: A five-billion-word corpus of Japanese blogs fully annotated with syntactic and affective information, in *Proceedings of The AISB/IACAP World Congress*, pp. 40–49 (2012)

[Rzepka 05] Rzepka, R. and Araki, K.: What Statistics Could Do for Ethics? - The Idea of Common Sense Processing Based Safety Valve, in *Papers from AAAI Fall Symposium on Machine Ethics, FS-05-06*, pp. 85–87 (2005)

[Rzepka 12a] Rzepka, R. and Araki, K.: Language of Emotions for Simulating Moral Imagination, in *Proceedings of The 6th Conference on Language, Discourse, and Cognition (CLDC 2012)* (2012)

[Rzepka 12b] Rzepka, R. and Araki, K.: Polarization of consequence expressions for an automatic ethical judgment based on moral stages theory, Technical report, IPSJ (2012)

[Rzepka 16] Rzepka, R., Mazur, M., Clapp, A., and Araki, K.: Global Brain That Makes You Think Twice, in *2016 AAAI Spring Symposium Series* (2016)

[Rzepka 17a] Rzepka, R. and Araki, K.: Conscious vs. Unaware Evaluation – Using Collective Intelligence for an Automatic Evaluation of Acts, in *Proceedings of the 2nd international workshop on evaluating general-purpose AI (EGPAI2017)* (2017)

[Rzepka 17b] Rzepka, R. and Araki, K.: What People Say? Web-Based Casuistry for Artificial Morality Experiments, in *Artificial General Intelligence - 10th International Conference, AGI 2017, Melbourne, VIC, Australia, August 15-18, 2017, Proceedings*, pp. 178–187 (2017)

[Yamamoto 16] Yamamoto, M. and Hagiwara, M.: A Moral Judgment System using Evaluation Expressions, *Transactions of Japan Society of Kansei Engineering*, Vol. 15, No. 1, pp. 153–161 (2016)

[Yasmeen 08] Yasmeen, S., Collins, A., Stepanova, E., Mullojanov, P., Sucharov, M., Stokes, M., Docking, T., Bellamy, A., and Gunn, G.: *National interest and international solidarity: particular and universal ethics in international life*, United Nations University Press (2008)

Oral presentation | Organized Session | [Organized Session] OS-5

[1F3-OS-5b] [Organized Session] OS-5

Tue. Jun 5, 2018 5:20 PM - 7:00 PM Room F (4F Garreria)

[1F3-OS-5b-01] Fundamental consideration on future society with speed tolerances

○Hiroshi Yamakawa[1,2] （1. Dwango Co. ltd., 2. The Whole Brain Architecture Initiative, non-profit organization）

5:20 PM - 5:40 PM

[1F3-OS-5b-02] Viewing Singularity from Various Perspectives

○Masahiko Osawa[1,2], Kazunori Saito[3], Yoichiro Miyake[4], Michita Imai[1] （1. Keio University, 2. Japan Society for the Promotion Science, Research Fellow (DC1), 3. Exponential Japan, 4. SQUARE ENIX CO., LTD.）

5:40 PM - 6:00 PM

[1F3-OS-5b-03] Scenarios and branch points to future machine intelligence

○Koichi Takahashi[1] （1. RIKEN）

6:00 PM - 6:20 PM

[1F3-OS-5b-a] OS invited talk

○Kazuhisa Todayama[1] （1. Nagoya University）

6:20 PM - 7:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

速度耐性をもつ社会の実現にむけた基礎的考察

Fundamental consideration on future society with speed tolerances

山川 宏[*1*2]
Hiroshi Yamakawa

[*1] ㈱ドワンゴ
Dwango, Co. ltd.

[*2] NPO 法人全脳アーキテクチャ・イニシアティブ
The Whole Brain Architecture Initiative, non-profit organization

Technological progress is accelerating, so the relationship between people and organizations is becoming more complicated. Under these circumstances, in order to maintain social stability, it is necessary to adapt social rules more quickly than ever. For such adaptive control social decisions need to be made quickly, but resources that can be used and speeds required for social decisions are limited. Therefore, within a certain range, it is necessary to delegate the right to decide social rules to AI. In the AI responsible for this role, the way of designing the value function used for decision making is critically important.

1. はじめに

人工知能(AI)の高度化に伴い、それ自身およびそのネットワーク化が社会に与える影響が増大するため、それに関わる議論が盛んになりつつあり、国内では様々な省庁が関連する会議などが動きを早めてきた。国際的には米国 Future of Life Institute によるアシロマの原則[FLI 2017]、米国 IEEE が発行した Ethically Aligned Design [IEEE 2017]などが有名である。

こうした問題においては具体的な問題に対処することは重要である。一方で技術に牽引される形で変化速度が増大していることへの対処は重要であり、これをなおざりにすれば、最終的に個別問題の対処が追いつかないことで破綻する恐れがある。しかしながら、速度それ自体への対応についての議論は未だ不十分であると思われる。

本稿では、まず、現在において速度が速まっている理由を述べ、次に社会におけるルールの必要性について述べる。その上でルールづくりのための社会的決定に合意のための時間を要する点について考察する。この状況を解消するには主に緊急時において AI が社会的決定を代行する必要があることを述べる。そして AI が迅速に動作するためには、社会が共有する価値観の実装が必須であり、その設計に難しさがあることを述べる。さらに社会における上位の目標を設定できれば環境変化への対応性が高まるが、進化的に獲得された人々の価値観と乖離する可能性が高まることを示唆する。

2. なぜ速度が増しているのか –収穫加速の法則-

生命は、複製する個体という形により、長い時間を超えて存続してきた。個体として生存し、繁殖するために、自身の身体を含めて制御下にあるリソースの量や範囲を拡大しようとする傾向をもつ。ここではそうした傾向を生存志向と呼ぶことにする。少なくとも人間はこうした生存志向を欲求として自覚している。

人や動物などのエージェントは、外界をセンシングしアクションとして働きかけることで、自らの生存志向を実現しようとする。環境が複雑になれば、その環境内の様々な出来事について予測を行える知能を持つほうが効果的に生存志向を実現しうる。特に人などの動物においては、発達の期間を長くすることで、多様な環境へ適応する知能を進化させてきた。

連絡先：山川宏、所属： ドワンゴ ドワンゴ人工知能研究所、
NPO 法人全脳アーキテクチャ・イニシアティブ

人類社会は以上のように知能を用いて科学技術を発展させて繁栄し人口を増やし、指数関数的に変化のスピードを増していると言われている。特に一つの重要な発明は他の発明と結びつき、次の重要な発明の登場までの期間を短縮し、イノベーションの速度を加速する収穫加速の法則が知られている。最近は情報技術や AI 技術の進展がこの変化の主役となってきている。

本来、生命の存続にとっては、その周囲の環境が安定していることが望ましいが、逆に変化が助長されてきている。現代の資本主義社会で活動する企業というエージェントは社会や技術の変化から生じた新たな市場において経済的利益を確保し拡大しようとする。こうした傾向は、個人レベルでのキャリア形成においても同様に生じている。環境に変化があるとき、それまで日陰者であったプレイヤーが表舞台に躍り出ることは珍しくない。

このようにエージェント同士が競争する変化の激しい世界においては、効果的に知能を活用できるエージェントのほうが有利になりやすい。優れた知能を持てば、様々な変化に対して素早く適応しうるし、変化の兆候を早い段階で見つけ出しやすくなる。さらに、自らが変化を生み出すゲームチェンジャーになれば益々有利になる。こうした変化を好み生み出そうとする傾向が高まり、現代の社会において変化を加速する要因となっている。

3. 迅速に社会的ルールを制御する必要性

3.1 社会的ルールの必要性

環境の広さに対して同種エージェントが疎に存在するなら、そこで生ずる相互作用は少なく、個々のエージェントが対処すべき問題の対象は主に環境そのものや外敵である。

我々人類は科学技術を発展させて生産性を高め人口を増加させてきた。さらに文字、輪転機、インターネットなどの通信技術を発展させて知識の共有と蓄積を促進した。その結果として現代社会においては、多くの人間同士が高密度な相互作用をもつことで更に知能を高める状態に急速に変化してきている。こうなると、同種内での生存志向が衝突し競争が激化する。

そこで人類は、競争を制御しながら社会を安定させ、むしろ発展につなげるように社会的ルールを発展させた。なお本稿の議論において、社会的ルールとは、エージェント間の調整に関わる様々な仕組みを含む広義なものである。公平性・利他性などを含む倫理観としては、生来持っている性質と教育された性質を含む。また罰則を含む明文化／体系化された法律も含む。

さらには現代主流となっている貨幣経済・市場経済・資本主義・民主主義やその対立概念を含むルールである。

現在は、法制度の範囲が拡大しているが、これらは倫理的な価値観から導かれる最低限守るべき規範であると考えられる。少なくとも公平性などの倫理的概念は、類人猿にも存在するため、法制度以前に存在する倫理観があるだろう。また憲法学者の木村草太は法律とは「人が幸福に生きるためのルールを一般的、抽象的に定めたもの」とも述べている。

3.2 社会的ルールを制御する社会的決定

社会的ルールは社会的決定によって確定されるべきものであり、実際に法律であれば立法という形で制定される。

民主主義社会における社会的決定において公平性や納得性を確保する必要がある。今回は、図1に示すよう、社会的決定について急用度と重要度の観点から整理した。

重要度が高い事案は広く民主的な合意形成の上で決定されるべきである。その場合には最終合意案に対し、できるだけ多くの関係者から納得を得るには、議論を尽くすために時間を要する。しかし意見が対立する関係者間において根本的な利害や価値観の隔たりがあれば、優れた選択肢のいずれでであっても、関係者全員が納得することは難しく、社会的決定にいたるまでの時間は長くなりがちである。

この様に民主的な決定は時間と労力を要するため数時間程度で結論を出さざるを得ない案件は権利を移譲された担当チーム等が決定を行う。また急用度が低くても重要度が低い事案はやはり担当チーム等が決定を行うことでスループットをあげている。急用度が中程度か、もしくは、急用度も重要度も低かった場合には、権限を担当チームなどに移譲して決定をおこなうことが現実的である。

一方で、人間の認知速度を超えた状況で問題が起きた場合には、そもそも速すぎるために社会的決定を人間が行うことができないレイテンシの問題が発生する。こうした重要度と急用度が高い事態であっても、津波などのようにある程度想定が為され、事前のシミュレーションなどを参考に対策についての社会的決定を行うことで急用度を下げられる。

		重要度	
		低い	高い
急用度	低い（月以上）	担当チーム等に移譲	民主的な方法で対応
	中程度（数時間）	担当チーム等に移譲	担当チーム等に移譲
	高い（秒以下）	速過ぎて人による決定不能	速過ぎて人による決定不能

図1：速度に応じた人による社会的決定の分類案

いずれにしても技術によって社会的状況が速く変化すれば、それに伴い社会的ルールを制御するための社会的決定を迅速に行う必要がある。

3.3 社会的決定のオーバフロー（スループット問題）

急用度が中程度で重要度が高い場合は、本来は民主的に決定すべきであるので、この場合に権限が移譲されるチームは大きな責任を持つことになる。そのためチームは、少数精鋭の必要な専門性をもつメンバで構成される事になるだろう。

関連して既に近年では法制定や法改正の増加さらにその文書量の増加する立法爆発と呼ばれる現象がおきている。社会にIT が普及した 2000 年前後に電子データや電子署名の法的有効性、公文書管理と情報公開、個人情報保護などの法整備が進められたことは立法爆発の主要な要因と考えられている。[榎並 2015]は、「ますます複雑化する社会、技術の進歩、家族関係の変容など、社会変化のスピードに法制度が追いつかず、官僚や法曹界など法律の専門家だけで内容のチェックをすることに限界がきていると考えられる」とのべている。

既に述べたように、今後は速い技術進展に伴い社会の変化が激化し、想定外の緊急事態に対して適切に社会ルールを設計したり変更したりする事態が増加しそうであるが、全ての重要度が高い案件に対して適切なチームを招集し全力で取り組み続けることは現実的には困難であろう。つまり処理すべき案件に対処しきれずオーバフローという課題が生ずる。これは処理量のスループットの問題である。

今後 AI がネットワーク化され、さらに自律的な判断能力を高めるにつれて、新たな社会的ルールを必要とする問題が増えるだろう。（以下のリストは例であり網羅的ではない）。

- 自動監視装置により、観察者は特定の他者のトレースすることで優位になりたいが、被観察者は監視を逃れて他者の影響力を避けたい。つまり両者間の生存志向同士の衝突することで、プライバシー保護の問題が顕在化する。
- 資本家は高度な AI を利用して作業を自動化したいが、これにより失業率が上昇するなら、人々の生活を守るための社会的ルール（ベーシック・インカムなど）が必要になる。
- 完全自動運転が導入されると効率的で安全な輸送が実現されるが、事故の責任帰属を扱うルールが必要となる。
- AI が環境から自律的にデータを収集し、さらに学習して能力を高めれば、より便利な道具となる。しかしそのデータに対してアクセスできる範囲をどのように設定するのか、さらに AI 自身の判断で生じた事故の責任を AI 自身に帰属させるか否かについて等の社会的ルールが必要になる。
- AI サイエンティストが出現すれば、技術開発を促進できるが、開発された新技術を制御したり、新種の事故の発生を制御する対策や損害賠償を分担したりするためのルールが必要になる。
- AI は殺傷兵器の能力を高めるために、非倫理的な利用を制限するための社会的ルールが必要になる。
- ある組織等が、トランスフォーマティブな AI 技術[1]を開発し独占した場合に、富・権力・知能がその組織等に集中して、社会に大きな格差が生まれうる。この状況を回避するための社会的ルールが必要になる。[GoodAI 2017]

多くの場合に、AI 自身は生存志向を持たないとしても、背後で AI に動作目的を与える人物には生存志向があるだろう。このために間接的な形で、生存志向の間で軋轢を生むことになる。

(1) 社会的決定を加速するための対策案

情報通信技術の発達により、意見集収や議論を行うことは容易になった。そこで広く民意を組み上げて政治に対する不満を減らせる可能性がある電子的な直接民主制(E-democracy)の可能性などが検討されてきている [山川 2006]。

また最近では AI 政治家を作るという議論もはじまっている。考えうる可能性として、今後は、多様な AI 政治家が出現するかもしれない。例えば中立的な AI 政治家は議論を促進できるだろうか。様々な AI 政治家は多様な発言を行うだろう。 バランスのとれた優れた選択肢、声の小さな多数派が望む選択肢、参考となる極端な選択肢などが議論の初期段階から表れ、議論全体として時間を短縮できる方法が見いだされるかもしれない。

1 トランスフォーマティブな AI 技術としては、自己再帰的な改良能力をもつ汎用人工知能などが想定されている。

法律についていえば、 その数が増大して複雑に絡み合ってくることで、ソフトウェアでいわれるスパゲティ・プログラムのように、理解が難しいものになると同時に、様々な問題を引き起こす要因ともなりうる。こうした状況へ対処するためには立法支援に AI を導入することも考えられる。

3.4 秒単位の社会的決定（レイテンシ問題）

秒単位より速い判断を要求される急用度が高い場合は、人間の判断速度を上回り、人間が対応することは不可能である。つまりここでは判断のレイテンシが問題となる。

想定しうる仮想的な事例としては、高度に知的に制御されているある地域のライフライン・インフラに対する未知のサイバー・テロへの対処などがある。有効な防御方法が見つからないため、政府の権限により、致命的な被害拡大を避けるために、数秒間の間に一部の市民には甚大な被害を生じる制御の切り替えなどなどの対策を行うといった、重大な社会的決定を行わざるを得ないような状況である。こうした社会的決定が政府で行われた場合に、上記インフラに関与する民間で所有される AI も新たなに決定されたルールを迅速に反映する事になる。

ただし予めこうした事態が想定されて、対応策について社会的決定がなされていれば、決定済みのルールに基づいて AI が対応すればよいので、この問題は生じない。

現在においても、AI が取引を行う株式市場のように人間の認知速度を超えた状況で問題が起きた場合に、これに対処する新たなルールを秒単位で設定するような事態を想定するとこれは人間にはできない。また将来、自動運転車や自律的に飛行するドローンなどが多数に行き交うような状況において、予期しない大規模なトラブルがおきたような場合にも、その進行が速いために人間の判断能力では対応しきれないかもしれない。AI が社会に浸透する中で、効率化が進む一方で、物事が人間の認知能力を超えることが増えていると思われる。

本来は、民主的に決定すべき重要案件について、時間不足で判断を行えないことは大きな問題である。

4. 社会的決定の AI への移譲

AI を開発することは、開発する組織等からみれば生存志向の点からみて有益であるし、しかも人々に対して多くの便益を与えるのも事実である。 そして AI 技術は世界中の至る所で比較的簡単に開発を進めることができる。このため AI 技術の進展に対してブレーキを踏むことは困難である。今後とも AI が発展しそれがネットワーク化する状況が続くとすれば、社会全体はブレーキのないままにアクセルを踏み続ける車のように技術上の制限による最高速度まで加速するだろう。

社会的ルールの制御を人や人の組織による社会的決定のみに頼ることは、レイテンシとスループットの両面においては速度不足を招く恐れがある。それに起因して、政情不安定、失政、無政府状態、紛争の勃発といった問題を生ずるかもしれない。そこで社会ルールを素早く制御できる社会的決定の仕組みが必須となる。

4.1 社会的決定の AI への移譲

以上述べてきたような、社会の変化速度に起因する危険の回避には、社会ルールの策定などを含む社会的決定において、適切に AI に権限を移譲する以外に選択肢がないように思われる。なぜなら AI による社会的決定は、以下でのべる価値関数の問題を解決すれば、人間による決定速度を遥かに上回れるので、少なくとも緊急時の安全装置として有効であろう。既に我々の社会において多くの社会的決定は代議員などに移譲しており、移譲自体は目新しいものではない。

こうして AI が緊急時に行う社会的決定の結果は、時に人々からみて不適切と捉えられるであろう。そうであっても、人が行う社会的決定が遅れることにより大惨事になるよりは暫定的な緊急対応が必要である。これは車に例えればアンチロックブレーキシステムのように、人の社会的決定では間に合わない制御を行うものだが、この場合はブレーキというよりも崖から落ちないように AI がステアリング操作するようなものである。

なおレイテンシの問題により AI が社会ルールを緊急決定した場合には、あとからで人々がルールの確認や見直しを行うべきであろう。一方でスループットの問題を解決するために AI を利用した場合は、そもそも人間側の判断するリソースの不足がもんだいであるので、人々が実際に確認を行うことは難しく、いつでも検証可能な状態に判断結果を公開するなどの対策をとることになるであろう。

4.2 合意形成結果を近似するための価値観数

AI による高速な社会的決定を行う際に、明らかにボトルネックとなる技術がある。それは、民意の総体として選択肢に対する評価を高速に近似する価値関数である。なぜならある案件について合意形成に到達するには、単に決定するだけでなく、関係者に納得してもらう必要がある。

当面考えうる二つの方法を以下で述べる。有力な可能性はこの二つを適切に組合せて利用することであろう。

(1) 民意の高速な推定

今後、日常的に個人を観測することで個人の価値観を推定することが可能になるだろう。たとえば、個人の表情や振る舞いから情動や感情を推定し、そこから価値観を推定する方法である。さらに踏み込んで個人に対して様々な体験を仮想的に提示することで暗黙化された価値観を表出させることも可能であろう。

こうして得られた個人に関わる観測データから逆強化学習や認知シミュレーションなどを利用して、内在する価値観をモデル化する。こうしたモデル化が実現されれば、未知の事象に対する価値推定も可能になる。多くの個人についての価値を推定できれば、その累計により、ある事案にたいする民意を推定できる。

推定した民意を足がかりに社会的な決定を行うことで、現状を維持する保守的な傾向を高速な価値観の近似関数に組み込める点で有用である。しかしながら、個人の価値観を推定することはプライバシーの問題を伴うため、その弊害を避けるための技術的工夫が必要になるであろう。また大きな変化によって生じる非日常的な状況に対する価値判断は、しばしばその場に遭遇しなければ想像できないため価値観の予測は困難であろう。

(2) より上位の社会的目標の設定

二者間の意見対立時に、より上位の目標において共通点を見出すことは有効である。一般的に、より上位における抽象度の高い目標ほど合意が得られやすく、その目標を実現する手段としの選択肢もしくは副目標の範囲が広がる。つまり我々の社会で共有しうるより上位の社会的目標が設定できれば、権限を移譲された AI は状況に応じたより柔軟な対応が可能になる。

一方で、わたし達が直感的に行っている価値判断は、日常的な状況に適応している可能性が高いかもしれない。そうだとした場合には非日常的な状況でも適切な決定を行うためには、社会におけるより上位の目標が設定されているほうが有益かもしれない。

しかしながら何を上位の目標として設定するかは非常に大な問題である。グローバル化が進んだ現代において種としての

「人類の生存」を副目標とすることは、比較的受け入れやすいと思われる。これは、[山川 2017]の中で述べた、「万人の幸福」と「人類の存続」の間のトレードオフの緩和を AI がおこなうというアイディアにも通じている。

5. 考察: 直感的に理解し難い上位の社会的目標

ここでは AI から離れて人間の価値観について考察する。

人間がもち自覚している直観的な価値観は自己保存、リソースを確保(食欲など)、繁殖(性欲)などの欲求や、さらには倫理観などを含む。そこからみるとの直観的感覚からすれば「人類の生存」は理解しがたいように思える。

人間のもつ基本的な欲求などは、おそらくは「人類の存続」という上位の目標から導きうる副目標ではないかと考える。しかし通常我々はその繋がりを認識していない。こうした副目標は進化の環境に適応した形で設定されているだろうが、他の目標との関係性は保持されていない。

一方で具体的な副目標は実世界での素早い反応を可能とする点で優れている。上位目標から手段としての副目標を導き出するには、上位目標を達成する多数の選択肢を作成し、さらに評価する必要がある。このため仕事などの日常シーンにおいても、多くの人々はわかりやすく自身が貢献しやすい具体的な目的に魅力を感じやすい。

しかし副目標が固定化されていると環境変化に対応する柔軟性を欠き、複数の副目標に拮抗や矛盾を生じた際に上位目標い上がって問題を解決することができない。

ここで仮に、上位目標としての「人類の存続」と人間の直観的な価値観が衝突するシナリオを考えてみる。 何らかの困難な環境変化が発生したときに、人類を遺伝子から再現する技術が完成していれば、一旦は全人間を殺傷してから、時間をおいて人類を復活させるのが現実的かもしれない。だが人間にとって、この判断は俄には受け入れがたい。ところが視点を広げ昆虫の世界に目を移せば珍しいことではない。例えば 1 化性の昆虫であるミドリシジミは年間の半年以上は卵で過ごしている。つまり人類全体が卵の時期を過ごすことを許容できるか否かである。

人間が持って生まれた固定的な価値観を乗り越えて、柔軟に社会的な決定を行えるか否かは大きなチャレンジである。もしかすると人間の価値観をより上位なものに昇華させるために AI などの技術を利用できるのかもしれない。先の例で言えば、人々が個体としての死を受け入れることによって人類の未来が開けることを納得することを促進する技術である。人間の選好を操作することは現在でもマーケティングという形で日常的に行われている。そう考えると今後さらに感情を操作するコンピューティングが進歩すれば技術的には遠いものではないかもしれない。

6. おわりに

我々の社会は大規模に組織化されており、それを安定的に持続するためには、状況に応じた社会ルールが必要である。技術進展により社会の変化が速まれば、立法等による社会的ルールの制御を速める必要があり、それを支える社会的決定も迅速化される必要がある。スループットが問題となるケースは既に立法爆発などとして顕在化している。レイテンシが問題となる場合として、たとえば、緊密に相互作用する AI のネットワークに支えられるようなインフラは、意図的もしくは偶発的に生じたトラブルに対して、数秒単位の短時間で対応する必要があり、対処の遅れは被害の拡大を招くかもしれない。

そこで社会的決定の一部を AI に移譲する可能性を議論した。そうなるとこうした AI を制御するために事案ごとに生ずる選択肢に対して高速に評価を行うための目的関数をいかにつくるかが重要な課題となる。とりうる選択肢としては、事案ごとの市民の総意を何らかの方法で高速に推定する方法、および、人類の存続などのより上位の目的を設定する、もしくは、それらを組合せたものになるであろう。

現在でも、「人では対処しきれないから AI に判断を任せたほうが、安全かつ効率的ですよ」というセールストークは、よく見られるものである。しかし今回検討したように社会的決定の権限を AI に委譲することは、明らかに大きなリスクを伴うことになるだろう。今後の技術進展により、重要性が高くとも速度的に人間が対処しきれないような案件が表れてくると想定するなら、決定の権限を AI に移譲したことで回避できるリスクを勘案した上で、必要最小限の範囲で AI への委譲を行う必要がある。このケースの中で特に AI の決定が人間の直観的な価値観から乖離する可能性ある場合は問題が大きく、何らかの対策が望まれる。

参考文献

[FLI 2017] Future of Life Institute, アシロマの原則, , 2017. https://futureoflife.org/ai-principles-japanese/

[IEEE 2017] IEEE, Ethically Aligned Design, v2, 2017. https://ethicsinaction.ieee.org/

[GoodAI 2017] GoodAI and AI Roadmap Institute, Report from the AI Race Avoidance Workshop, 2017. https://goo.gl/VJHjRU

[榎並 2015] 榎並 利博, 立法爆発と法律のオープン化 第 1 回 立法爆発の実態と専門家の限界, 法と経済のジャーナル, 2015/09/18. https://goo.gl/ei6lbq

[山川 2003] 山川宏, "集合的決定におけるマルチエージェント強化学習 - E-Democracy の制度設計利用を中心に -", 信学技報, NC2002-124, pp. 43-48, 2003.

[山川 2009]山川宏. 多段委任投票の公正化を促進する有力投票者推薦. 人工知能学会論文誌,Vol. 24, No. 1, pp. 170-177, 2009.

[山川 2017] 山川宏, ドワンゴ人工知能研究所の所長の山川宏とのインタビュー、Future of Life Institute, 2017. https://goo.gl/rtKsU5

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

多様な視点で見つめるシンギュラリティ — 技術・産業・行政を統合した社会構造モデルの提案 —

Viewing Singularity from Various Perspectives:
A Proposal for the Social Structure Model Integrating Technology, Industry and Government.

大澤 正彦 *1*2 Masahiko Osawa　齋藤 和紀 *3 Kazunori Saito　三宅 陽一郎 *4 Yoichiro Miyake　今井 倫太 *1 Michita Imai

*1 慶應義塾大学大学院理工学研究科 Keio University, Graduate School of Science and Technology

*2 日本学術振興会特別研究員 (DC1) Japan Society for the Promotion Science, Research Fellow (DC1)

*3 エクスポネンシャル・ジャパン Exponential Japan

*4 株式会社スクウェア・エニックス SQUARE ENIX CO., LTD.

シンギュラリティに関する議論は，曖昧になったり，単一の視点からポジショントーク的に行われる場合が多いように見受けられる．シンギュラリティを客観的で包括的に考察していくためには，より多くの視点から議論を深めて行く必要がある。著者らは，2018 年 1 月 13 日に「多様な視点で見つめるシンギュラリティ」というイベントを開催した．本稿では，イベントでの議論を踏まえて，技術，産業，行政の 3 つの視点に着目して，社会構造モデルを提案する．提案した社会構造モデルは，主に技術，産業，行政で扱われる概念群を 2 軸状にマッピングすると同時に，概念間に階層関係を付与している．2 軸平面上の概念の位置は，概念の分解，個別発展と再解釈，波及，統合によって変化していくことが想定されており，概念の位置の変化を社会の変化として解釈することで，高速な変化を遂げる社会の把握に寄与できる可能性を検討している．さらに概念の指数関数的な発展を前提として提案モデルをもとに考察することで，今後は我々人間が扱う概念が一般的なものから専門的なものまで多様性を生む一方で，局所的な概念から大域的な概念へのシフトが起こっていくという仮説を提唱する．

1. はじめに

シンギュラリティ（技術的特異点）とは，コンピュータ技術や生命科学などの進歩や，発展によって，科学技術が自ら，自分より優れた科学技術を作れるようになるポイントを指す [カーツワイル 07]．このポイントを超えると技術発展のスピードは無限大になったかのように見えると考えられている．指数関数的な進化の根底には，人間とそれに続くテクノロジーにおいて進化は本質的に加速していくという，「収穫加速の法則」があると考えられている．収穫加速の法則は一つの重要な発明がほかの発明と結びつくことによって，次の重要な発明が生まれるまでの期間が短縮されるというものである [齋藤 17]．シンギュラリティの議論は将来的に国や社会に対して大きな影響を及ぼすため，積極的に個人，組織ないし国をあげて議論が展開されている．

ところが指数関数的な発展が題材となるシンギュラリティは，正確に予測することが困難な性質を持っている．結果，シンギュラリティに対する議論はポジショントーク的になることや，根拠に基づかない SF 的予測になってしまう場合もある．シンギュラリティの議論は，今後より客観的かつ包括的に行っていく必要があると考えられる．

著者らは，こうした背景を踏まえて，2018 年 1 月 13 日に「多様な視点で見つめるシンギュラリティ」というイベントを開催した．当該イベントはソニー株式会社，シンギュラリティ大学東京チャプター，全脳アーキテクチャ若手の会 [大澤 17a, Yamakawa 16] の共同主催により，およそ 200 名の参加者を集めた．講演者は企業，学生，省庁と多様な立場から選出され，幅広い議論がなされた．また，当日の様子は，記事としても公開されている *1．

連絡先: 大澤 正彦，慶大/学振 (DC1)，〒 223-8522 神奈川県横浜市港北区日吉 3-14-1，045-566-1749，mosawa@ailab.ics.keio.ac.jp

*1 AINOW, ”「多様な視点で見つめるシンギュラリティ」-シンギュラリティに文系も理系もない-”, http://ainow.ai/2018/01/25/131431/

本稿の目的は，開催したイベントでの議論をまとめ，精緻化することを通して多くの立場から合意できる社会構造モデルを提案することである．社会構造モデルが共有されることで，指数関数的な発展をする社会を正確に捉える一助となると考えられる．

本稿では特に指数関数的な発展が起こる頻度や，起こった場合の影響力が異なる，「技術」「産業」「行政」の 3 つの立場に着目して議論を進める．個々の技術は，指数関数的な発展を独立に何度も遂げて来た．一方で行政における指数関数的な発展は技術ほど頻繁には起こりにくいが，起こったときの影響の範囲は個々の技術と比較すると大きい場合が多いと考えられる．産業は指数関数的な発展が起こる頻度や起こった時の影響力という点で，ちょうど技術と行政の中間的な位置付けと考えられる．提案した社会構造モデルでは，技術系，産業系，行政系の概念が階層的に捉えられ，指数関数的な発展によって人間が変化を捉えにくくなるタイミングで，概念の統合や抽象化が起こるという仮説に基づいている．

以下，本稿の構成を示す．2 章では本稿で議論するシンギュラリティの前提について説明し，3 章ではイベントでの議論を技術・産業・行政の視点から他分野との位置付けを中心にまとめる．4 章は 2,3 章の議論を踏まえて技術・産業・行政を統合した社会発展構造のモデルを提案する，そして 5 章をまとめとする．

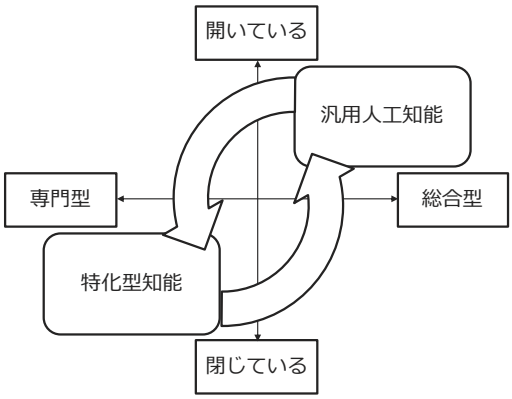


図 1: 人工知能の位置付け．知性が必要とされる課題を開いているか閉じているか，総合的か専門的かという観点で分類したもの．

2. シンギュラリティの議論の前提

シンギュラリティに対する議論を整理する上で，シンギュラリティに対する前提によって以下の 3 種類の議論があると考えられる．

- 前提がない議論
- シンギュラリティの到来が前提の議論
- シンギュラリティが到来するか否かを問わない前提の議論

前提がない議論での主な着目点は，そもそもシンギュラリティが来るか，来ないかという点である．様々な証拠に基づいて，シンギュラリティが来る理由，来ない理由を戦わせるものである．シンギュラリティの到来が前提の議論での主な着目点は，到来する時期と到来した際の影響である．時期に関しては，直感として線型的な技術発展を想定してしまう人間に対して，実際の技術が指数関数的に発展している事実を踏まえてシンギュラリティが到来する時期を予想する議論が多い．一方到来後の社会については，ロボットに支配されてしまうか，仕事がなくなってしまうかといった議論がなされている．シンギュラリティが到来するか否かを問わない前提を置く議論の場合は，シンギュラリティの議論の題材に使われる指数関数的な技術発展やこれまでの技術の歴史を踏まえて今後の技術や産業，行政の発展を予測しようという着目点になる場合が多い．

前提のない議論は，未だ不確定要素が多いためにどの主張も曖昧なままなことが多く，場合によってはポジショントーク的になってしまうこともある．シンギュラリティの到来を前提とする場合は，時期に関しては，技術進展が無限大に見えるような点から現在を逆算することは難しい．到来後の社会についても想像の範囲を超えてない場合が多い．

一方でシンギュラリティが到来するか否かを問わない前提をおく議論は，今後起こる変化を具体的に捉えるという意味で重要でありながら，他の 2 つの議論と比較すると議論の対象とされることが少ないように感じられる．さらに，これまでにも認められている指数関数的な技術発展に関する議論であるため，他の 2 つの議論よりは客観的な証拠に基づいた議論がされやすい．そこで本稿の中ではシンギュラリティが到来するか否かという点には言及せず、指数関数的な発展をする社会について議論を進める．

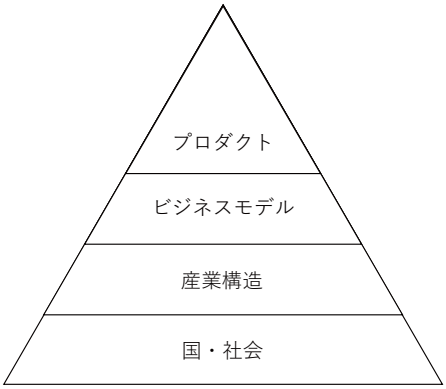


図 2: プロダクトビジネスおける階層構造．最上位に位置する実際のプロダクトに対して，それを引き起こす環境や背景としてのビジネスモデル，産業構造，国・社会という階層．上ほど局所的かつ専門的であり，下ほど大域的かつ一般的．

3. 多様な視点で見つめるシンギュラリティ

本章では，開催されたイベントでの議論を技術，産業，行政の 3 つの視点から簡単にまとめる．

3.1 技術におけるシンギュラリティ

技術の視点からは，人工知能（AI）を題材として 2 点まとめる．

1 点目は，汎用型知能と特化型知能の位置付けについてである．図 1 に汎用人工知能と特化型人工知能との位置付けを示す．現在，閉じた問題を設定すれば，今でも人工知能は人間を凌駕する性能を発揮する場合も多い．一方で開いた問題に対して，現代の人工知能は基本的に対応できないと考えられている．したがって現在は人間と技術の得意とする問題の領域が分かれている状態といえる．今後の技術発展によって，人工知能が適用できる問題が広がっていき、人間が対応できるタスクのほとんどを内包する関係になる可能性がある．この時，現在の人工知能と人間の関係は再解釈される必要がでる．

2 点目は知能と環境の関係についてである．知能は，環境と密接な関係を持っており，設定された環境の中で適切に振る舞う．知能と環境は常に影響を及ぼし合い，いずれかの変化がもう一方も大きく変化する場合がしばしばある．例えば，囲碁をする AI であれば環境は囲碁の世界，ルンバのような掃除ロボットであれば環境はユーザーの部屋である．今後，AI がより開いた汎用的な課題に適応できるようになった場合，AI が扱う環境は徐々に広がり，いずれは産業ないし国や社会全体にまで広がっていく可能性もある．したがって，これからの技術は行政や産業を踏まえてデザインする必要性が増加していく可能性がある．

3.2 産業におけるシンギュラリティ

指数関数的に発展していく概念の中では特に，表層ではなくそれを引き起こす環境や背景の普遍性を捉えることが大切である．早すぎる変化が起こっている対象の将来を見極めることは一般的に難しい．そこで対象物自体ではなく，対象物の根源となっている対象を見極めることが重要になってくるということである．

例えば，プロダクトビジネスにおいては図 2 に示すような構造になっていると考えられる．現在ではプロダクトのイノベーションの変化が高速化しており，見極めることは難しくなってきている．そこで変化が早すぎるプロダクトのイノベー

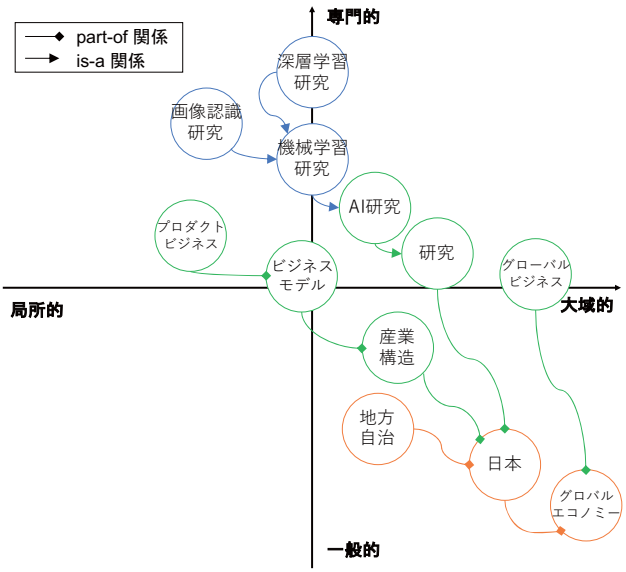


図 3: 技術・産業・行政を統合した社会構造モデル

ションではなく，その根源となっているビジネスモデルのイノベーションを目指し，さらに速くなることを見越して近年では産業構造のイノベーションを捉える経営者も出てきている．その先には，国家や社会システムのイノベーションを見据えることで経営戦略を作る必要性が出て来る可能性が高い．

3.3 行政におけるシンギュラリティ

行政の立場では例えば，社会へのインパクトが強い技術として人工知能が挙げられており，2016 年の 4 月から人工知能技術戦略会議が始まっている．同会議では安西祐一郎氏を議長として，人工知能開発を政府でどうおこなっていくかについての検討がされている．その成果例としては産業化ロードマップが提案されている *2．

人工知能の研究開発目標と産業化のロードマップでは，人工知能（AI）の発展段階の整理としてフェーズ 1〜フェーズ 3 からなる構成が示されている．ここではフェーズを経るごとに様々な領域間の統合が想定されている．

4. 技術･産業･行政を統合した社会構造モデル

4.1 モデルの概要

これまでの議論を踏まえて，技術・産業・行政のシンギュラリティを見据えた発展について，図 3 に示す．図中に示した概念は一例である．

提案モデルの中で技術、産業、行政においてそれぞれ扱う概念が 2 つの軸の上にマッピングされている．1 つ目の軸は，局所的ー大域的である．局所的な概念が影響を及ぼす要素は比較的小さく，結果として社会全体としての影響力は比較的小さい．一方で大域的な概念は，影響を及ぼす要素が比較的多く，社会全体に対する影響力が比較的大きい．2 つ目の軸は，専門的ー一般的である．2 つの軸には相関があることが想定されており，専門的な概念は局所的な傾向が，一般的な概念は大域的な傾向がある．また，技術が扱う概念は専門的かつ局所的なものが，行政が扱う概念は一般的かつ大域的な傾向があり，産業が扱う概念はその中間的であると考えられる．ただし，大域的な技術的概念や，局所的な行政的概念も存在する．例えばコンピュータのように社会一般に浸透した技術や，特定の家族のように一般的ではあるが局所的な概念は存在する．

局所的な概念は一般に発展の速度は速く，指数関数的に発展していく様子が定量化される頻度も大域的な概念と比較すると多いと考えられる．大域的な概念は，様々な要因が複合されるため，局所的な概念よりは発展の速度が遅い場合が多いと考えられる．

概念同士は 2 軸状の位置関係の他に，特定の概念間の関係によって影響を受ける．特定の概念間の関係とは，主にオブジェクト志向の考え方に基づいた 2 種類の階層関係であり，もともと 1 つの概念から分解されたと仮に想定している．

1 つ目の階層関係は part-of 関係であり，上位概念は下位概念の集合体であるとする．part-of 関係の場合，上位概念は下位概念なしでは成り立たない．上位概念は下位概念にとっての”環境”として捉えることも可能であり，上位概念と下位概念は常にお互いに影響を及ぼしあう．例えば，日本社会と日本社会における産業の関係は part-of 関係である．産業は日本社会の重要な構成要素の一つである．日本社会の向上は産業の向上にもつながり，産業の向上もまた日本社会の向上につながる．また，産業にとって日本社会は前提とする環境として捉えることもできる．

2 つ目の階層関係は is-a 関係であり，上位概念は下位概念の抽象概念であるとする．is-a 関係の場合には，上位概念はもともとあった下位概念が消失しても成り立つ．例えば，知能研究という上位概念に対しては，認知科学，神経科学，人工知能といった研究領域が下位概念として想定できる．認知科学，神経科学，人工知能はいずれも独立した知能研究であり，仮にいずれかの学術領域を除いても知能研究という概念は普遍的である．

提案モデルの中で，下記の 4 つの操作によって概念や概念同士の関係が変化し，結果として社会の変化が起こるという仮説を立てている．

- 分解
- 個別発展と再解釈

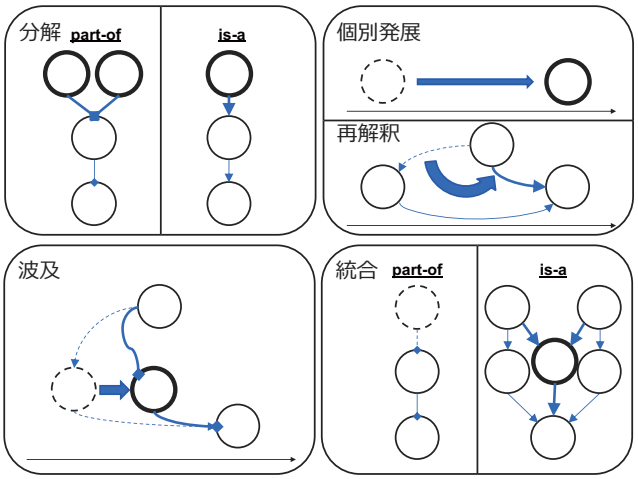


図 4: 提案モデルに対する 4 つの操作．モデル上のノードやエッジに与える変化として表現した場合の一例．点線で表現されたエッジとノードは操作の前後で削除されたものを，太線で表現されたエッジとノードは操作の前後で新たに追加されたノードを表す．

*2 人工知能技術戦略会議, 人工知能の研究開発目標と産業化のロードマップ, (2017), http://www.nedo.go.jp/content/100862412.pdf

- 波及
- 統合

4 つの操作に対応する提案モデル上の変化について図 4 に示す．次節からは，上記の 4 つを個別に説明していく．

4.2 分解

分解とは，ある概念に対して下位概念を定義することによって，前節で説明した 2 種類の階層関係を新たに生成することである．このとき 2 種類の階層関係に応じた分解方法がある．

part-of 関係を生成するための分解は，提案モデル上では 1 つの概念に対して 2 つ以上の下位概念を与えることと表現できる．新たに生成した下位概念群の和集合が元々の概念となるため，下位概念は分解対象となった概念より局所的なものとなる．

一方 is-a 関係を生成するための分解は，提案モデル上ではある概念に対して 1 つ以上の下位概念を与えることと記述できる．上位概念は下位概念よりも抽象的であることから，新たに生成した下位概念はより専門的なものとなる．

4.3 個別発展と再解釈

提案モデル上で個別発展は概念間の階層関係が変わらないまま，ある 1 つの概念の絶対位置が大域的な方向に移動することと言える．一方で再解釈は，概念間の絶対的位置関係が変更されたことをきっかけに起こる，相対的な階層関係の変化である．

個別発展の結果再解釈が起こる典型的な例として，is-a 分解によって生まれた概念が汎用性が高い概念へと個別発展した場合が想定できる．図 4 に示したように，自らの直接の上位概念よりもより大域的な概念になった場合は，さらに大域的な概念の下位に再解釈する．

4.4 波及

波及は，ある概念が変化した時に，その上下関係にある概念にも影響が及ぶことを意味する．提案モデル上では，ある概念の上位もしくは下位の位置に引っ張られて概念の絶対位置がより大域的な方向に動くことと説明できる．特に，part-of 関係にある概念同士の影響は波及しやすい．3.1 で述べた AI と環境の相互作用も波及の原則で説明できる．

4.5 統合

統合も分解と同様に part-of 関係と is-a 関係のそれぞれに対応する 2 種類が定義できる．

part-of 関係における統合は，提案モデル上ではある統合された概念の下位概念が全て削除されることで表現される．3.2 で説明したプロダクトビジネスに関する事例がこれに当たる．つまり part-of 関係の統合がおこるきっかけとしては，下位概念の変化が速すぎる場合や概念群が多すぎて把握しきれない場合に，直接的にそれらの下位概念を扱うことが困難と判断される場合である．統合された下位概念群は提案モデル上には記述されなくなるが，実際には統合前と同様に存在し続ける．

is-a 関係における統合は，ある下位概念同士を統合して新たな概念を生成することである．例えば，知能研究の下位概念同士である人工知能と神経科学を統合して，計算論的神経科学や Biologically Inspired Cognitive Architecture といった領域が展開される場合である．part-of の場合とは異なり，新たな概念を形成・位置づけすることによって提案モデル上では表現される．

4.6 考察

指数関数的な発展を前提としたとき，概念の統合や分解，再解釈が行われることによって，概念の多様化が起こる可能性が高い．その中でこれまで以上に専門的な概念や，これまで以上に一般的な概念が生まれることを考えると，今後一般的ー専門的の軸は分散が大きくなっていくと考えられる．

一方で，局所的ー大域的の軸では，変化の速度が速くなるにつれて我々人間が直接的に扱うのは大域的な概念にシフトしていくと考えられる．

5. おわりに

本稿は，主に技術，産業，行政の立場から現在行われているシンギュラリティに対する議論をなるべく客観的に捉えることを目指し，3 つの立場から他の立場との接点を探っていった．

これから長期スパンでの技術，産業，行政の発展によりよく寄り添えるように，見識を深め広めていく必要があるだろう．

ゆくゆくは現在の自分たちが最も大域的な概念に感じている社会や文化，国が人間が捉えきれない速度で発展をするようになったとき，われわれは今まで想定していなかったさらなる大域的概念で物事を捉えなおさなければならなくなる可能性がある．

謝辞

本稿に関する議論ならびに本稿の元となったイベントの企画，運営に対して多大な貢献をいただいたソニー株式会社の下村秀樹氏，栃木淑人氏，島田大樹氏，ならびに文部科学省の原克彦氏には多くのお力添えをいただきました．ここで深く感謝いたします．

参考文献

[Yamakawa 16] Hiroshi Yamakawa, Masahiko Osawa and Yutaka Matsuo: Whole Brain Architecture Approach Is a Feasible Way Toward an Artificial General Intelligence, The 23rd International Conference on Neural Information Processing, pp. 275-281, Kyoto, Japan, (2016).

[大澤 17a] 大澤 正彦, 全脳アーキテクチャ若手の会, Vol. 32, No. 6, pp. 268—269, (2017).

[大澤 17b] 大澤 正彦, 知能への学問の分解と統合：人工知能+認知科学+神経科学異分野交流会, Vol. 32, No. 2, pp. 873—876, (2017).

[カーツワイル 07] レイ カーツワイル, ポスト・ヒューマン誕生 — コンピュータが人類の知性を越えるとき, NHK 出版, (2007).

[齋藤 17] 齋藤 和紀, シンギュラリティ・ビジネス—A I 時代に勝ち残る企業と人の条件, 幻冬舎新書, (2017).

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

将来の機械知性に関するシナリオと分岐点

Scenarios and branch points to future machine intelligence

高橋恒一[*12]
Koichi Takahashi

[*1] 理化学研究所　生命機能科学研究センター
RIKEN Center for Biosystems Dynamics Research

[*2] 慶應義塾大学大学院政策・メディア研究科
Keio University Graduate School of Media and Governance

We discuss scenarios and branch points to four major possible consequences regarding future machine intelligence; 1) the Singleton scenario where the first and single super-intelligence acquires a decisive strategic advantage, 2) the Multipolar scenario where the singleton scenario is not technically denied but political power-game or other factors in human society or game theory between intelligent agents inhibit a single agent to acquire a decisive strategic advantage, 3) the Ecological scenario where the singleton scenario is technically denied and many intelligent autonomous agents operate in the manner where they are mutually dependent and practically unstoppable, and 4) the Upper-bound scenario where cognitive abilities that can be achieved by human-designed intelligent agents or their descendants are inherently limited to the sub-human level.

1. はじめに

本稿では，機械知性の発達を比較的遠距離の将来までに渡るシナリオとして展開した場合にありうる結果をいくつかに分類し，それぞれに至る道程に存在すると想定される主要な分岐点を見いだすことを試みる．

次のような前提を設定し，議論を主要な論点に絞る．第一に，物理法則により禁止されていない技術は，十分な資源の投入を条件にいつか実現される．第二に，物理的に禁止されない技術のうち経済的に合理的な資源投入の結果それに見合う経済的あるいはその他の効用が予見される技術開発は，いつか何らかの主体によって成される．ただし，要素技術と結合技術には相対的な関係性が存在し，技術間には依存関係のグラフが存在する．第三に，技術拡散は一定の速度で起き，発明された技術はある時間の後に共有される．第四に，過渡的な力の不均衡は，一定の時間の後に均衡が示す安定点に収束する．ただし，過渡的動態のうちに存在する不可逆的な分岐点は不確実性要因となる（偶然の固定）．

なお，ここでは高度な知性を備える知能エージェントを機械知性と呼ぶが，これは現在の人工知能という用語の使われ方の多様さによる混乱を軽減することのみが目的である．また，本稿は特定の年代を想定した未来の予測を目的とするものではなく，道程と分岐点およびそれらのありうる帰結を整理する試みである．

2. 機械知性シナリオの分類

ここでは，長期的な機械知性技術の発展により想定されるシナリオを整理する．

2.1 シングルトンシナリオ

再帰的に自己更新する知能エージェントの自己改良速度は上限なく，あるいは，その時点でその改良速度を観察する人類またはその他の知能エージェントに対する決定的戦略的優位性[Bostrom14]の獲得まであたかも上限がないように増大し，最初に自己更新を一定程度まで進めた知能エージェントが資源獲得や他のエージェントとの競争において覆すことが困難な覇権を握るとするシナリオである[Bostrom14].

連絡先：高橋恒一，理化学研究所生命機能科学研究センター，大阪府吹田市古江台 6-2-3，ktakahashi@riken.jp

2.2 多極シナリオ

シングルトンによる覇権の危険性の認識による国際条約の設定や技術経済的要因，あるいはその他の外部的な要因により，どのエージェントも決定的戦略的優位性の獲得する前に性能向上が停滞するが，関係主体間の力関係の変化あるいはテロリズムなどの不確実性要因によるシングルトンの発生の可能性は否定されないシナリオである[Bostrom14].

2.3 生態系シナリオ

知能エージェントの性能向上には決定的戦略的優位性の到達可能性以前に限界が存在し，その結果多数のエージェントが並存的，相互依存的な生態系様のマルチエージェントネットワークを構成するとするシナリオである．そのような「AI 生態系」は，今日のインターネットや電力網がそうであるように人類の活動が依存するため停止不可能であり，また個々のエージェントの挙動がある程度以上複雑であれば全体としての挙動も予測不可能であると想定される[Yamakawa17].

2.4 上限シナリオ

人類が工学的に作り出しうる知能エージェントおよびそれを起点にした能力発展には一定の上限が存在し，将来にわたっても自ら判断して人による逐一の指示なしに自律的に動作する能力は獲得しないというシナリオである[西垣 16，井上 17].

3. 制約とシナリオ分岐

本稿で設定した前提条件において，機械知性シナリオのうちどれが具現化するかは，知能エージェントの内部構造および既獲得資源と推論性能に関わる内部的制約と，知能エージェントの制御の対象外である物理法則や，他の主体との関係性により生じるゲーム理論的構造などの外部的制約がある．

3.1 内部的制約

(1) 高度な自律性に関わる制約

自律性は例外的状況や環境変化などの幅広い状況に対して対処できるタスク汎用性と深く関連する．上限シナリオに分類さ

れる議論の多くでは，工学的に設計可能な認知アーキテクチャの認知能力がそのタスク汎用性においてヒト並みに到達するには克服不可能な障害が存在すると主張される．しかしながら，ヒトの脳内の神経結合と計算機能的に同一のシステムは，認知機能的にも同一の能力を持つとする唯物論的な立場に立てば，これは物理的に禁止されない．ただし，十分な性能を発揮する内部構造を設計するためにどのような周辺技術や要素技術が必要であり，どの程度の研究開発コストを費やす必要があるかは現時点では検証されていない．また，環境および身体との相互作用で生じる創発的な動態や学習で獲得する認知機能がタスク汎用性にどの程度の寄与があるかの定量的な議論もまだ十分になされていない．

(2) 自己構造改良能力に関わる制約

同様の論点として，ある能力を持ったエージェントが，仮に利用可能な計算能力を一定とした場合に，自己または外部の同等の能力を持ったエージェントの構造情報を起点に，それを上回る応答速度あるいは認知能力を持つエージェントの新規の構造情報を生成できるかどうか，すなわち自己改良能力に関わる制約がある．これは一見遠大な議論に思えるが，実際には，上記の内部構造と認知能力に関わる制約が一定程度クリアされるならば，本質的には内部構造のモジュール性が関わる工学的な問題である．モジュール性と階層性（準分解可能性[Simon96]）が確保されたアーキテクチャであれば，設計主体の認知能力に合わせて様々な階層におけるモジュールごとに内部構造を改良する部分改良問題を一つずつ解いてゆけば，結果として漸進的に全体の継続的な能力向上が可能である．ただし，ヒトの脳を含め，ヒト並みあるいはそれ以上の能力を持った知能エージェントを準分解可能システムとして構築可能であるという仮説は未検証である．また，改良速度の上限は設計の変更による性能向上を予測する推論サイクルの実行速度により定義される．遺伝的アルゴリズムによる進化計算的アプローチも可能であるが，これもシミュレーションに必要な時間が速度の上限を定義する．

(3) 熱力学的効率に関わる制約

利用できるエネルギーを一定とした場合に実現可能な計算量には熱力学的な上限が存在する．情報の消去などの論理的に非可逆な操作は1ビットあたりボルツマン定数 k と絶対温度 T を用いて kT ln 2 に相当する熱力学的エントロピーの上昇を伴うことが熱力学第二法則から導かれる（ランダウアー限界）．これは300K の常温でおよそ 2.87×10^{-21}J である．現代の計算機のスイッチングエネルギーがおよそ 10^{-17}J 程度であり[Theis17]，あと1万倍程度でこの限界に到達する．ヒトの脳と比較すると，10W 程度のエネルギーで 10PFLOPS 程度の処理を行ない，1FLOPS あたり仮に 10^3 から 10^4 回程度の非可逆ビット操作が起きるとするとランダウアー限界とは2，3桁程度の熱効率の開きしかない．以上の数字は大雑把な見積もりではあるが，ヒトの脳と同等の 10PFLOPS の計算処理は今後もコモディティー化が進むと考えられる一方，ヒトを大幅に超えたタスク汎用性や予測能力を現在の延長上のデジタル計算機で実現するためには大量の電力が必要であることを示している．純粋な観測により量子状態が破壊されないような種類の量子計算や DNA 計算のような情報が失われない分子機械を用いた可逆的過程を用いる場合にはこの限界は局所的には適用されないが，これらの実用化が他の技術との比較で相対的にどの程度の速さで進むかは現時点でははっきり予測出来ない．

3.2 外部的制約

ここまで内部的制約を整理したが，これらは実際には物理法則や利用可能な資源量のような外部的制約を変数とするものが多い．関連する制約を整理する．

(1) 物理素子による制約

あらゆる物理現象には時定数が付随する．あるエージェントが利用資源量を変化させずに能力や応答速度を大幅に向上させるためには，アーキテクチャが不十分にしか最適化されていない場合を除いて自己の物理的基盤の更新が必要である．新しい物理現象やその組み合わせを利用する場合には，それを利用した場合の性能向上に関する仮説生成と物理実験による検証が必要であるが，必要な時間は対象の物理時定数に依存する．知識発見にシミュレーションを用いる場合にも，新たな物理現象が関わらない創発的な原理に関するものであれば物理時定数よりも高速に実行出来る場合もあるが，新しい物理現象の探索の場合には，対象の物理現象が属するより階層の低く粒度の細かい計算を要するため，一般的には実時間よりも長い時間がかかる．実在論的仮説生成[渡部16]により未知の過程を仮定して同じ階層でのモデル検証を通じて探索する場合にも，多数の可能な仮説を物理あるいは仮想実験により検証する必要があり，より長い時間がかかる．これらは，いずれにしても自己改良速度を制限する要因となる．

(2) 相対的優位性に関する制約

時間定数に関する制約は，エージェント間の優位性に関して追加の前提条件を与える．多くのエージェントが相互作用するマルチエージェント的状況であり，かつ環境および他のエージェントに関して不完全な情報しか得られない状態において，他のエージェントよりも優位な地位，すなわち他エージェントの行動およびその帰結をより早く予測しそれに対処出来る状態，を獲得し維持するためには，他の全てのエージェントおよび環境を含めた予測の対象となる系の状態変化の予測能力が有意に優っている必要がある．ここで，有意に優っているとは，予測に用いたフレームに対して外部からの撹乱に対する予測対象系の応答時間，および対象とするエージェントとの物理的あるいはネットワーク的距離により規定される相互作用の遅延時間のどちらよりも十分に長い時スケールの予測を，それらの時スケールに比べて短い時間で行える能力を保持しているということである．

相対的優位の確立には，相互作用の時定数が関連することを述べた．このことは，二つの重要な帰結を導く．第一に，物理世界でのマルチエージェント状況において，他のエージェントに対して予測能力と応答速度が少しでも優っていることは直ちに行動上の優位性の十分条件とはならず，前段落で定義した意味で「有意に」優っている必要がある．さらに，計算複雑性の観点からは，多くの問題は問題を構成する要素の数 N に対して線形の計算量で解ける状況はむしろ特殊であり，多項式的あるいは指数的な計算量を必要とするため，一般に計算能力の増加に対して対数的な効用しか得られない．しかしながら，第二に，確率的条件により偶然得られた資源的優位がたまたま決定的な差別化に結びつき，その状況が他のエージェントが追いつき均衡状態に戻るまでにかかる緩和時間の間に当該エージェントが決定的戦略的優位性にまで結びつく技術的あるいは獲得資源的進展を得れば，それが結果的に固定化された偶然[de Duve05]としてシナリオ分岐を起こす可能性がある（確率ゆらぎによる決定的優位性シナリオ）．

(3) 局在性に関わる制約

エージェントの物理空間における自他の境界は，エージェントの制御下にあるセンサー系と作用系の配置により決定する．また，光速を一定とするとエージェントを構成する主要な計算素子間の空間距離がエージェントの応答速度の上限を規定する．（これは，ヒトの脳の物理的大きさと神経伝達速度が脳の 100ms 程度の認知的応答速度を規定しているのと似ている．） 情報統合理論によると，意識体験が別個の部分の集まりではなく，統一されたひとつの全体として体験されるためには，要素間に相互情報量で計られる情報的結合が必要であるとされる[Tononi16]．エージェントが空間的広がりを持つ場合，このような情報統合により得られた経験に基づいて判断を行い，応答する場合の速度は，要素間の通信に伴う光速に起因する遅延により上限が決定される．センサー系や作用系との通信が一方向である場合には空間距離はエージェント内部の応答速度を直接は制限しないが，環境や他のエージェントに関する情報取得や作用の遅延という形で結果的に応答速度を制限する．このような制限は，前項の相対的優位性に関わる応答速度の制限を通じて，エージェントの能力に関する空間的広がりの局在性に関わる要求，さらに間接的には利用できる分散計算資源量の上限も設定する．

エージェントは，将来起きる状況の変化の予測に基づいて自己のコピーあるいは自己の影響下にある他種のエージェントを任意の数あらかじめ遠隔地に配置しそれらと通信することにより，局所的な出来事に対する応答時間を低減すると同時に，推論および探索の分担をすることで，空間的局在性に関する制限の回避を試みることができる．しかし，複数のエージェントが全体として統一の経験情報に基づいた意思決定プロセスを共有するには，情報のコピーを伴う通信が必要である．分散システムにおけるブリュワーの CAP 定理は，ノード間の情報複製に関して，一貫性，可用性，分断耐性の3つの保証にはトレードオフがあり，一般的にはこれらの2つしか同時には保証出来ないことを示している[Lynch02]．このトレードオフは実際には絶対的なものではなく，障害復旧の遅延時間が変数としてはたらく（無限の時間待てるのであれば，全ての障害を復旧して一貫性，可用性，分断耐性を確保出来る）．このことと光速の限界を合わせて考えると，単一エージェントの場合だけでなく，複数のエージェントの集合の場合にも，相対的優位性の確保を目的とした場合に，ある一定の応答時間内において利用できる計算資源の空間的局在性の要求，およびそれにより生じる計算能力の上限に関わる制限が設定されるため，複数のインスタンスを生成することで得られた追加の計算資源を用いることで際限なく相対的優位性を追求できるわけではない．

4. シナリオと分岐点

前章で議論した制約を用いて，2章で分類した各シナリオへの分岐点を検討する．冒頭で述べたように，本稿は特定の年代を想定した未来予測が目的ではなく，ここではシナリオの分岐点の特定と整理のみを行う．

高度な自律性に関わる制約は，機械知性が将来ヒト並み以上の認知能力を獲得するということを物理的には禁止しないものの，現実的なコストでそのような技術開発可能かどうかは今後の検証次第であり，現時点では不明である．もう一つの可能性は，ヒト並みの認知性能は人手で設計した機械では発揮出来ないが，その代わりに**自己構造改良能力**を持った機械の設計は可能であり，結果としてヒト並み程度以上の機械知性を手にするシナリオである．これらの二つの道筋により**上限シナリオ**とその他のシナリオとの分岐が生じる．

シングルトンシナリオは，前章で述べた全ての制限が突破あるいは回避され，一つのエージェントが決定的戦略的優位性を確保するシナリオである．ここでの決定的要因は，決定的戦略的優位性の確保に必要な認知能力のレベルが何を基準に設定されるかである．単に他の全てのエージェントおよび人類に対して推論能力と応答速度で勝るだけでは十分でなく，環境要因による撹乱も含めた系全体に対する予測能力が必要である．絶対的には環境に対する一定の予測が第一のハードルとなる．相対的には，他のエージェントに裏をかかれ優位性を脅かされないためには他のどれに比べても桁違いに多くの計算能力を単独で保持する必要がある．このような状況に至るためには，計算資源量でほぼ大半を支配するなどの優位を固めるか（外向きの知能爆発），または**物理素子**の更新により初期の優位性を指数的に拡大するような能力を確保する（内向きの知能爆発）必要がある．外向きの知能爆発シナリオでは**相対的優位性に関する制限**および**局在性に関わる制約**の両方をクリアする必要があり，多くの厳しい条件が整わないと成立しない．内向きの知能爆発シナリオでは，自らの**物理素子**を更新するような機械知性がどのような条件が揃った場合に発生するかが決定的な論点となる．

自律エージェントにとって，自己の行動の結果あるいは外的要因により生じる状態変化の予測能力の向上，そして不確実性の低減は一般に目的達成に有利である．従って，一般に自律エージェントは計算資源やセンサー系・作用系へのアクセスのような資源獲得の性向を持つと考えられる．**シングルトンシナリオ**と**多極シナリオ**は，いずれもシングルトンの発生の可能性が否定されないということで共通するが，それらの分岐はむしろ資源獲得の性向あるいは利用可能な資源量そのものを設計上人為的に制限できるかどうかにより起きる可能性がある．

多極シナリオと**生態系シナリオ**の分岐も，決定的戦略的優位性を持つエージェントの発生の可能性が存在するか否かに依存するため，**シングルトンシナリオ**に準じた分岐条件により起きると考えられる．

生態系シナリオと**上限シナリオ**の分岐は，機械知性が自律的に知覚，判断，行動決定のサイクルを人の指示なしに継続して実行し続ける能力が獲得するかどうかにより起きる．いったん**高度な自律性**を持つ機械知性が実現し，それを利用することに経済的合理性があれば，早晩社会のあらゆる仕事の自動化に利用されるようになるであろう．自動化機械の効用が自律性，すなわちどれだけの時間人間の指示なしに行動出来るか，により測られるとすると，自律性は技術的，経済的コストに見合う限り際限なく追求される．現代においても既に人間活動の多くがネットワーク上で成立しており，自律的な機械知性エージェントは比較的短期間に人間社会との間で相互依存的な状況に至るだけでなく，エージェント間も相互依存的かつ相互補完的な関係をはりめぐらせるようになると考えられる．

以上のようなシナリオと分岐の関係を，図1に現在を起点として各シナリオへ到達するグラフの形で示した．

5. 最後に

本稿では，長期的な機械知性の行き着く先が，その能力レベルの発展の上限により上限シナリオ，生態系シナリオ，多極シナリオ，シングルトンシナリオの順に分岐してゆく可能性を議論した．また，能力レベルの上限を制約する重要な要因として，高度な自律性を持つ認知アーキテクチャーの実現や自己構造改良能力などのアーキテクチャーレベルの問題のほかに，マルチエージェント状況における相対的優位性確立の難しさ，また計

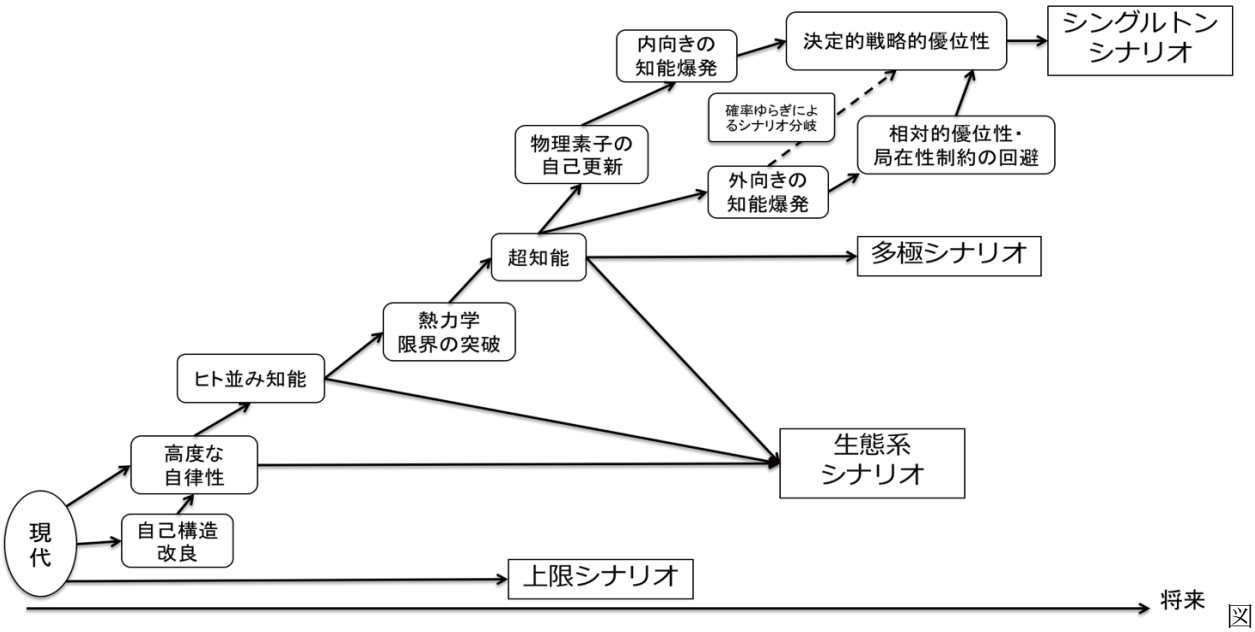


図 1

算の熱力学的効率や光速の上限などの物理的制約などがあることを議論した.

技術的特異点は本稿の主要な主題ではないが, 前章で議論した内向きの知能爆発とは深く関係するため, ここで簡潔に本稿のシナリオとの関係に限って触れたい. ヴァーナー・ヴィンジは技術的特異点に向かう4つのシナリオを, (1)コンピュータの「覚醒」による超知能の発生, (2)コンピュータネットワークの「覚醒」による超知能の発生, (3)機械とヒトの知能が BMI(Brain-Machine Interface)のような技術で融合しヒトが超知能を獲得, (4)バイオテクノロジーの発達によりヒトが超知能を獲得, であるとした[Vinge93]. このうち, まず(1)は本稿の議論が主に扱ったものである. (3)と(4)は(1)と違い, シナリオがヒト並み知能から出発するため, いずれかの時点で**物理素子の自己更新**に進み**熱力学限界**を突破しない限り**生態系シナリオ**に留まる. (2)のコンピュータネットワークの覚醒シナリオは, **局在性に関わる制約**を強く受けるため, これを何らかの方法で回避しない限り, その応答速度の制限により実世界の出来事の予測能力及び操作能力には厳しい限界が課せられ**上限シナリオ**か**生態系シナリオ**に留まる.

最後に, **熱力学的効率に関する制約**および光速の上限が深く関連する**局在性に関する制約**が撤回された場合には, **シングルトンシナリオ**への分岐には**物理素子**の自己更新能力と**相対的優位性**のみが制約となることを付記しておく. 計算の熱力学に関しては, 3.1(3)に示したように量子計算のような可逆計算であればランダウアー限界が根本的限界とならない可能性が示されている[Toffoli05]. 一方, 光速が設定する上限はより厳格であるように見える. これまでのところ, 関わるエネルギーが TeV スケール以下の物理現象までしか実験的には探索されておらず, また全ての力を統一的に記述できる理論は未発見のため, 今後何らかの新たな現象が発見される可能性は否定されないものの, 現在工学的に扱える見込みがある範囲では光速以上の速度で情報を伝達する方法は示されていない.

謝辞 本項の執筆にあたっては, 荒川直哉, 大澤博隆, 山川宏, Gideon Kowadlo, David Rawlinson 氏のご指導をいただいた. また, 佐野仁美氏に編集と図の作成のお手伝いを頂いた. 感謝いたします. 本研究の一部は, 新学術領域研究「脳情報動態」, 文科省ポスト「京」萌芽的課題「脳のビッグデータ解析, 全脳シミュレーションと脳型人工知能アーキテクチャ」, および JST-RISTEX 人と情報のエコシステム領域研究「法・経済・経営とAI・ロボット技術の対話による将来の社会制度の共創」の一環として行った.

参考文献

[Bostrom 14] N. Bostrom: Superintelligence: Paths, Dangers, Strategies, OUP Oxford, 2014.

[Yamakawa 17] H. Yamakawa: Understanding Artificial General Intelligence – An Interview with Dr. Hiroshi Yamakawa, Future of Life Institute, 2017. https://futureoflife.org/2017/10/12/transcript-understanding-agi-an-interview-with-dr-hiroshi-yamakawa/

[西垣 16] 西垣通: ビッグデータと人工知能, 中公出版, 2016.

[井上 17] 井上智洋: 人工超知能, 秀和システム, 2017.

[Simon 96] H. A. Simon: Science of artificial, MIT Press, 1996.

[渡部 16] 渡部匡己, 都築拓, 海津一成, 高橋恒一: 人工知能による科学研究の加速, 人工知能学会全国大会論文集, 2016.

[de Duve 05] C. de Duve: Singularities: Landmarks on the Pathways of Life, Cambridge University Press, 2005.

[Theis 17] T.N. Theis, H.-S. P. Wong: Computing in Science and Engineering, pp.41-50, 2017.

[Tononi 16] T. Giulio, B. Melanie, M. Marcello, K. Christof: Integrated information theory from consciousness to its physical substrate, Nature Reviews Neuroscience, pp.450–461, 2016.

[Lynch 02] N. Lynch, S. Gilbert: conjecture and the feasibility of consistent, available, partition-tolerant web services, ACM SIGACT News, pp. 51-59, 2002.

[Vinge 93] V. Vinge: The Coming Technological Singularity: How to Survive in the Post-Human Era, 1993. https://edoras.sdsu.edu/~vinge/misc/singularity.html

[Toffoli 05] T. Toffoli: Reversible computing, Lecture Notes in Computer Science book series, Springer, 2005.

6:20 PM - 7:00 PM (Tue. Jun 5, 2018 5:20 PM - 7:00 PM Room F)

[1F3-OS-5b-a] OS invited talk

○Kazuhisa Todayama[1] （1. Nagoya University）

幸せな未来社会を構想して，それに向かうためにどのように科学・技術を活かすかを考えることが大事だというのは，ほとんど自明なこととして受け入れ AIの未来について実り豊かな議論をするためには，幸せな未来を考えることがなぜ難しいのかにまで遡って再考することが必要です．それをやってみます．

©The Japanese Society for Artificial Intelligence

[1G3] [General Session] 11. Robot / Real World

座長:成田 雅彦（産業技術大学院大学）

Tue. Jun 5, 2018 5:20 PM - 7:00 PM Room G (5F Ruby Hall Hiten)

[1G3-01] Evaluation of mechanical effect for wire assist suit with force plates inside treadmill

○Hiroumi Murai[1], Nobutaka Tsujiuchi[1], Akihito Ito[1], Keisuke Kitano[1], Kenta Murakami[2], Seigo Okada[2], Tsuyoshi Inoue[2], Yui Endo[3], Yumeko Imamura[3], Jun Ozawa[3] （1. Doshisha University, 2. Panasonic Corporation, 3. National Institute of Advanced Industrial Science and Technology）

5:20 PM - 5:40 PM

[1G3-02] Mechanical effects of wire assist suit on human walking during load-carrying

○Seigo Okada[1], Kenta Murakami[1], Tsuyoshi Inoue[1], Yui Endo[2], Yumeko Imamura[2], Jun Ozawa[2] （1. Panasonic Corporation, 2. National Institute of Advanced Industrial Science and Technology）

5:40 PM - 6:00 PM

[1G3-03] Learning-based Selective Dual-arm Grasping for Warehouse Picking

○Shingo Kitagawa[1], Kentaro Wada[1], Kei Okada[1], Masayuki Inaba[1] （1. the University of Tokyo）

6:00 PM - 6:20 PM

[1G3-04] Integrated Model for Learning of Actions, Language and Planning

○Kazuki Miyazawa[1], Tatsuya Aoki[1], Takato Horii[1], Chie Hieida[1], Tomoaki Nakamura[1], Takayuki Nagai[1] （1. The Department of Mechanical Engineering and Intelligent Systems, University of Electro-Communications）

6:20 PM - 6:40 PM

[1G3-05] Learning Integration Concept of Objects and Motions Based on Segmentation and Classification of Time Series Multimodal Information

○Ryotaro Nunokawa[1], Kazuki Miyazawa[1], Tomoaki Nakamura[1], Takayuki Nagai[1], Masahide Kaneko[1] （1. The University of Electro-Communications）

6:40 PM - 7:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

ワイヤ型アシストスーツのトレッドミル歩行における力学的影響評価

Evaluation of mechanical effect for wire assist suit with force plates inside treadmill

村井 大海[*1] Hiroumi MURAI
辻内伸好[*1] Nobutaka TSUJIUCHI
伊藤彰人[*1] Akihito ITO
北野敬祐[*1] Keisuke KITANO
村上健太[*2] Kenta MURAKAMI
岡田征剛[*2] Seigo OKADA
井上剛[*2] Tsuyoshi INOUE
遠藤維[*3] Yui ENDO
今村由芽子[*3] Yumeko IMAMURA
小澤順[*3] Jun OZAWA

[*1] 同志社大学 Doshisha University
[*2] パナソニック株式会社 Panasonic Corporation
[*3] 産業技術総合研究所 National Institute of Advanced Industrial Science and Technology

Assist suits have been developed in order to improve gait efficiency and reduce the burden on the body. In recent years, wire type assist suits have been developing. Generally, wire types help users to move by pulling the portion of their bodies with wire. Therefore, they can easily follow human movement and are enough light to wear for long time. In this research, we evaluated the effect of wire type assist suits on lower limb joint by analyzing mechanical values for each joint when walking on the treadmill with wearing wire type. We calculated user's lower limb joint angle, hip joint torque and step length in each condition(Case I: Tension is changed, Case II: Assisting section is changed).Results from the analysis showed increases of lower limb joint angles to particular direction and step lengths, decrease of energy in a part of gait cycle.

1. はじめに

近年の高齢化社会に伴い，高齢者や労働者の動作を支援する装置の研究開発が行われている．その一つが動力を持つ装置をユーザに装着することで，歩行動作を支援するアシストスーツである．近年，ワイヤを伸縮させることで下肢関節の支援を行うワイヤ型のアシストスーツ（以下ワイヤ型）が開発 [1)2)3)]されている．

従来では，ワイヤ型の評価手法として，呼気ガス計測によるエネルギー代謝動態が用いられている [4)5)]．しかし，この評価手法では運動全体の代謝の変化についての評価はできるが，アシストスーツが各関節に対して行っている支援の程度を評価することはできない．さらに，ワイヤ型は関節を跨って張られたワイヤを引くことにより動作をアシストするため，関節にエンコーダを有する外骨格アシストスーツに比べ，関節における支援効果の評価は困難である．

そこで，本研究では人体シミュレーションソフトウェアを用いて，ワイヤ型を装着してトレッドミルを所定時間歩行したヒトの各関節に対してワイヤ型が与える力学的な値を計算機上で解析することにより，ワイヤ型が下肢関節に与える影響を評価することを目的とする．本稿では，ワイヤの動作モデルをシミュレーションソフトウェア上でモデル化し，アシストタイミング，およびワイヤ張力の大きさを変化させた際の計測データを用いて股関節トルク，下肢関節角度および歩幅の算出結果に基づき評価を行った．

連絡先：村井大海，同志社大学機械力学研究室，京田辺市多々羅都谷 1-3，buo5037@mail4.doshisha.ac.jp

2. アシストスーツ

ユーザは，図 1 に示す，リュック型のモータ駆動システムを背負い，腰に腰ベルトを，左右の膝上大腿部に膝ベルトを装着する．モータ駆動システムには，バッテリ，制御基板，モータ 8 本（Maxon 社：EC Servo モータ，22mm-24V-100W，減速比 16：1 のギヤボックス付）およびモータドライバ（Maxon 社 ESCON Module 50/5）が設置されている．また，8 本のワイヤがモータ駆動システムのモータから腰ベルトを経由し，端点は膝ベルトに取り付けられる．ワイヤは直径 8mm のプーリを経由してモータに取り付けられており，各ワイヤは，約 100N の張力を生み出すことが可能である．図 1 に示すようにワイヤは，各脚の前後に 2 本，交差した形で設置され，歩行周期の 87.5%から指定の歩行周期まで一定の張力を加えることができる．それにより，モータが回転し，腰ベルトと膝ベルトの間にワイヤ張力が発生し，股関節の運動を支援することができる．

本アシストスーツは，歩行周期（踵接地から次の踵接地までの時間）に基づいてワイヤ張力の制御が行われるため，ユーザの歩行周期を計測する必要がある．そこで，靴には圧力センサが設置されており，圧力センサの計測結果はワイヤレスでモータ駆動システムに送信され，その信号をもとにアシストタイミングを決定する．また，腰ベルトと膝ベルトの間において，ロードセルが直接ワイヤに接続されており，ワイヤ張力の計測を行い，常にフィードバックすることで，リアルタイムでワイヤ張力の制御を行っている．

なお，本研究では，直進歩行の進行方向のみに対して股関節モーメント支援を行うため，後部ワイヤのみを同張力で制御し，伸展モーメントのアシストのみ行った．

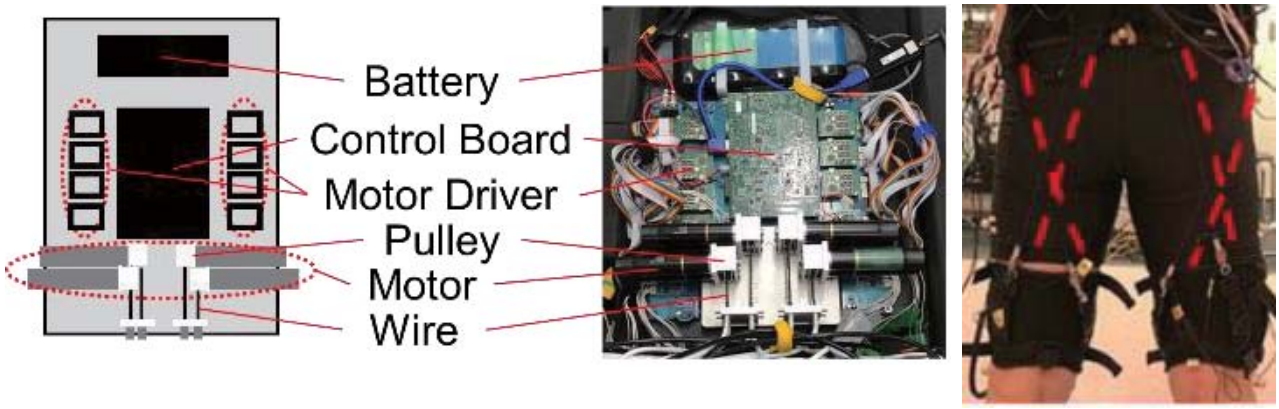


図 1 アシストスーツのモータ駆動システム（左，中央）およびワイヤ位置（右）



図 2 実験時の様子

3. 実験方法

本アシストスーツ装着時のユーザの運動学情報および床反力情報を計測する実験を行った．被験者は歩行異常のない 45 歳，177cm，69kg の男性とした．被験者の全身に 79 個の反射マーカーを装着し，モーションキャプチャシステム VENUS3D（ノビテック製）のカメラ（全 8 台）によって，フォースプレート（テック技販製）内蔵の左右分離型トレッドミル上の歩行運動を計測した．歩行時間は 40 秒で，そのうちの 20 秒間のデータを各条件（全 7 条件）につき 3 セット取得した．実験時の様子を図 2 に示す．

条件はI. 各ワイヤの最大張力を 30N，50N，70N と変化させた場合（いずれもアシストタイミングは 87.5%~20%）およびII. ワイヤの最大張力を 50N でアシスト終了タイミングを 4 種類（0%，10%，20%，30%）に変更した場合で歩行計測した．モーションキャプチャおよびフォースプレートのサンプリング周波数は各々 200Hz および 500Hz であった．

4. 解析方法

4.1 人体シミュレーションソフトウェアによる支援効果の評価

上述の歩行動作計測結果に基づき，被験者およびワイヤの動作を計算機上に再現し，逆動力学解析を仮想的に行う．以下にその概略手順を示す．

1) 人のモーションデータから逆運動学により関節角度を算出．

表 1 歩行周期全体の関節角度差

Condition	Hip[deg] (Extension:+)	Knee[deg] (Flexion:+)	Ankle[deg] (Plantar:+)
30N87.5-20%	1.18	2.40	2.36
50N87.5-0%	-0.43	1.25	3.02
50N87.5-10%	1.85	1.63	3.15
50N87.5-20%	2.37	1.28	2.70
50N87.5-30%	4.11	0.49	3.86
70N87.5-20%	5.56	1.17	2.53

表 2 歩行負荷軽減率

Condition	Reduction rate[-]		
	0-7% section	10-60% Section	0-100% section
30N87.5-20%	1.53×10^{-1}	-6.57×10^{-1}	-4.84×10^{-1}
50N87.5-0%	1.30×10^{-1}	-5.70×10^{-1}	-8.57×10^{-1}
50N87.5-10%	1.28×10^{-1}	-6.85×10^{-1}	-1.10
50N87.5-20%	1.07×10^{-1}	-7.19×10^{-1}	-8.99×10^{-1}
50N87.5-30%	4.22×10^{-1}	-6.04×10^{-1}	-1.13
70N87.5-20%	1.10×10^{-1}	-1.01	-1.28

2) 1)の関節角度，ワイヤ張力，床反力，ワイヤのモーションデータおよび COP（圧力中心位置）から逆動力学により関節モーメントを算出．

以上より，ワイヤ張力の大きさ・制御方法による支援効果の違いを評価した．

4.2 下肢関節角度差

歩行周期全体における，アシスト有りの場合とアシスト無しの場合の各関節角度差を以下の式で求めた．

$$\theta_d(k)(i) = \frac{\sum_{j}^{N}\left(\theta_{(NA)(j)} - \theta_{(i)(j)}\right)}{N} \quad (1)$$

ここで，i はアシスト条件(30N87.5-20%など)，j は 1 歩行周期中の 1%，k は各関節，NA はアシスト無し条件，N は 1 歩行周期(100%)，θ_d は関節角度差である．

4.3 歩行負荷軽減率

股関節モーメントのアシスト効果を定量的に評価するために以下のように歩行負荷軽減率 γ を定義した．

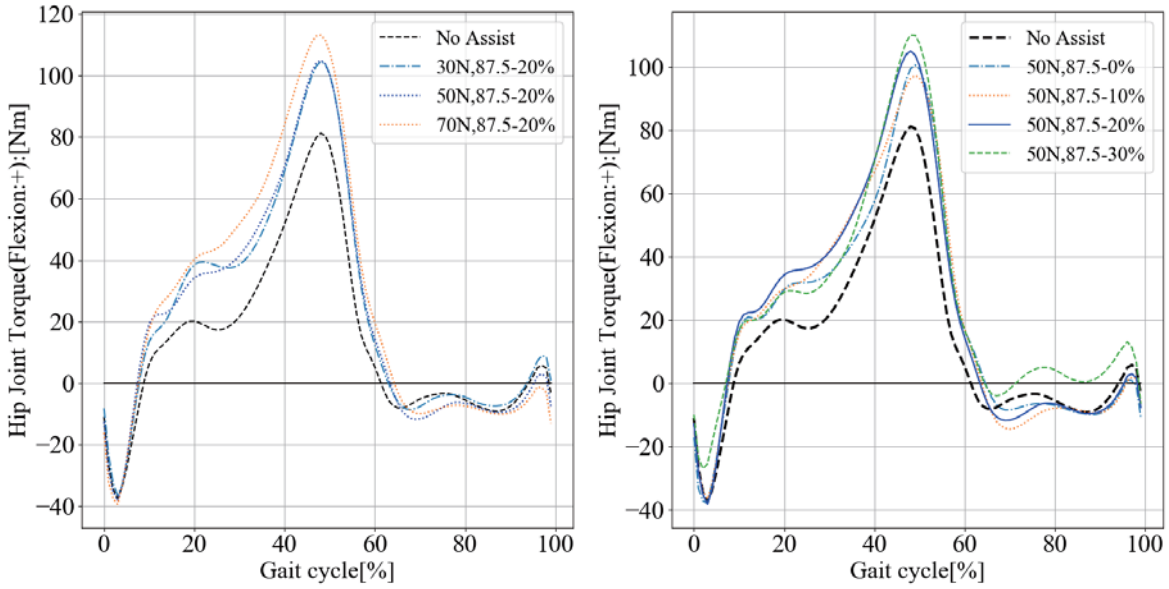


図 3 股関節トルク case Ⅰ （左） および case Ⅱ （右）

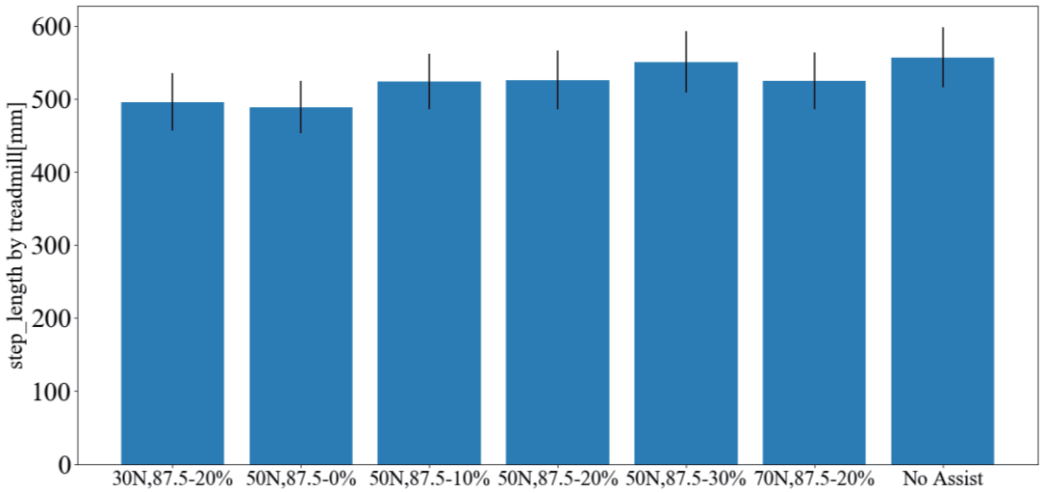


図 4 各条件での歩幅

$$\gamma(i)=\frac{\sum_{j}^{N}\left(1-\frac{\left|\tau_{(i)(j)}\right|}{\left|\tau_{(NA)(j)}\right|}\right)}{N} \qquad (2)$$

ここで，i はアシスト条件，j は評価区間内の 1%，NA はアシスト無し条件，N は評価区間，τ は股関節モーメントである．

なお，式(1)，(2)では 3 セット中の左脚のデータを平均した．

5. 結果および考察

5.1 下肢関節角度差

式(1)により求めた各関節角度差の結果を表 1 に示す．表 1 より，各実験条件において，膝関節角度は屈曲方向，足関節角度は底屈方向に増加した．股関節角度はアシストする区間を長くする，またはワイヤ張力を大きくするにつれて伸展方向に増加することがわかった．これはワイヤが股関節を直接回転させるトルクを発生させることによるものと考えられる．この結果は，本ワイヤ型が股関節に対してアシストするものであることを考えると，ワイヤの制御方法によって特に股関節角度を所望の値に変化できうるのではないかと考えられる．

5.2 歩行負荷軽減率

式(2)により求めた歩行負荷軽減率の結果を表 2 に示す．表 2 より，歩行周期 0-7%では負荷が減少し，10-60%および全体では負荷が増加した．

5.3 アシストタイミングの提案

5.2 より，10-60%では屈曲方向に負荷が増加していることから，ユーザが股関節を屈曲方向に曲げようとしているのに反し，後部ワイヤが股関節の伸展方向に引張動作をしてしまっていることがわかる．

また，I，II各条件における股関節トルクを図 3 に示す．股関節トルクの傾きが負のとき，ユーザは股関節を伸展させようとしているので，後部ワイヤ引張のタイミングとしては，歩行周期の 0-3%，50-63%が適切であると考えられる．また，股関節トルクの傾きが正のとき，ユーザは股関節を屈曲させようとしているので，

歩行周期の 4-50%で前部ワイヤを引っ張るとよいと考えられる. 4-50%で前部ワイヤを引っ張ることで本研究の 10-60%区間で見られた歩行負荷の増加が改善することが考えられる.

5.4 歩幅の変化

条件I, IIにおける, ユーザの歩幅を図 4 に示す. 図 4 より, アシストタイミングを長くする, またはワイヤ張力を大きくするにつれて歩幅が増加する傾向が見られた. また, ユーザがアシストスーツを装着していない状態(No Assist)の歩幅が最も大きくなることから, アシストスーツを装着するとユーザの歩幅が小さくなるということがわかった. したがって, アシストスーツを装着した歩行において, 装着していない状態と同様の歩幅にするためには, より長い区間や大きい力を条件とした実験が必要である. また, 先に述べたように前部ワイヤを引っ張ることで、よりアシストがない歩行に近い歩幅を実現できると考えられる.

6. おわりに

本研究では, 歩行アシストスーツの中で特に近年開発が見られている, 柔軟なワイヤ型の歩行アシストスーツが下肢関節に対して与える影響を歩容と負荷の 2 つの観点から評価した.

歩容に関して, 歩行周期全体の平均をとると, 股関節角度は伸展方向, 膝関節角度は屈曲方向, 足関節角度は底屈方向に増加することがわかった. また, アシストタイミングを長くする, あるいはワイヤ張力を大きくするにつれて, 歩幅が大きくなることが分かった.

負荷に関して, 0-7%では負荷が減少し, 10-60%および歩行周期全体では負荷が増加することがわかった.

今後の課題として, 特に歩行負荷が増加した 10-60%で負荷を減少するための最適なアシストのタイミングおよび入力するワイヤ張力の制御方法を検討する必要がある. また, 今回の実験では被験者が一人であったため, 他の被験者でも同様のアシスト効果が見られるのかは分からなかった. そこで今後はさらに被験者数を増やし, アシストスーツの歩行運動に対する影響の評価を行っていく.

参考文献

1) A. T. Asbeck, S. M. M. De Rossi, K. G. Holt, and C. J. Walsh:A biologically inspired soft exosuit for walking assistance, The International Journal of Robotics Research, **34**-6, pp.744-762,2015.
2) A. T. Asbeck, S. M. M. De Rossi, I. Galiana, Y. Ding, and C. Walsh:Stronger, Smarter, Softer:Next Generation Wearable Robots , Robotics&Automation Magazine , **21**-4 , pp.22-23,2014.
3) V. Bartenback, K. Schmidt, M. Naef, D. Wyss, and R. Riener:Concept of a soft exosuit for the support of leg function in rehabilitation, IEEE International Conference on Rehabilitation Robotic, pp.125-130,2015.
4) Y. Ding, I. Galiana, A. Asbeck, S. De Rossi, J. Bae, T. Santos , V. Araujo , S. Lee , K. Holt , and C. Walsh:Biomechanical and Physiological Evaluation of Multi-joint Assistance with Soft Exosuits, IEEE Transactions on Neural Systems and Rehabilitaion Engineering, **25**-2, pp.119-130,2016.
5) S. W. John, M. Komatsu, K. Murakami, J. Ozawa and M. Yamamoto: Soft hip walking assist experimental system featuring variable compliance control , IEEE International Conference on Consumer Electronics, pp.400-401,2015.

ワイヤ型アシストスーツが荷物持ち歩行に及ぼす力学的影響

Mechanical effects of wire assist suit on human walking during load-carrying

岡田 征剛[*1] 村上 健太[*1] 井上 剛[*1] 遠藤 維[*2] 今村 由芽子[*2] 小澤 順[*2]
Seigo Okada Kenta Murakami Tsuyoshi Inoue Yui Endo Yumeko Imamura Jun Ozawa

[*1] パナソニック株式会社 Panasonic Corporation
[*2] 国立研究開発法人産業技術総合研究所 National Institute of Advanced Industrial Science and Technology

We estimated the mechanical effects of wire assist suit on load-carrying. The wire assist device is a soft exosuit with four independently controllable actuators per assisted joint, with the wires crossed over each other at the front and rear. In this study, we used this assist suit to assist hip extension in stance phase during load-carrying. To estimate mechanical effects on hip moment, we made assist suit model in virtual ergonomic assessment system with human model and solved inverse kinematics. Additionally, we investigated on kinematic parameters to estimate the effects of load-carrying and assist suit on human walking. As a result, the assist suit decreased the hip extension moment in stance phase and the angular impulse during extension torque exertion by 25% compared to load-carrying with no assist device. From a kinematic point of view, the assist suit decreased the step length and the ratio of swing phase during load-carrying.

1. はじめに

近年, ヒトの歩行を支援するための様々なアシストスーツが研究されている. これまで開発されたものとして, ユーザの関節部に装着したアクチュエータによりユーザの動作支援を行う外骨格型[M. Aach 2014], また, 関節を跨いだワイヤを引っ張ることでユーザの運動支援を行うワイヤ型[A.T.Asbeck 2015]が挙げられる. 我々は, 股関節 6 自由度のアシストが可能なワイヤ型アシストスーツを開発してきた[S.W.John 2017]. ワイヤ型のアシストスーツは, 外骨格型に比べて拘束性が低く, 柔軟な動きに対応したアシストが可能であるという特長を持つ. これまで, 通常の歩行に対して支援効果を評価し, 部分的ではあるが一定の効果が認められている[村上 2017].

一方で, 通常歩行だけでなく, 荷物持ち歩行のように, 負荷をかけた状態での動作支援も重要であり, 工場や農業における運搬作業等の荷物持ち歩行を支援するアシストスーツを開発が出来れば, 労働者の身体への負荷を軽減することが出来る. そこで, 本研究では, 先行研究により効果の認められたアシストパターンを荷物持ち歩行に適用し, ユーザへの歩容変化や関節トルク変化について評価を行った.

従来, アシストスーツの評価としては呼気ガスなどの化学的手法が用いられてきた[L.M.Mooney 2014]が, 力学的評価はあまりなされていない. 本稿では, ワイヤ型アシストスーツのワイヤ動作をモデル化・可視化し, 逆動力学シミュレーションにより, アシスト張力制御によるヒト股関節トルクへの影響を評価した結果について述べる. また, 荷物持ち歩行に対する支援についての運動学的知見を得るため, 荷物持ち歩行及びアシストスーツが歩行に及ぼす運動学的影響の評価を行った.

2. 手法

本章ではアシストスーツ, 実験内容, 及び解析手法について述べる.

連絡先：岡田征剛, パナソニック株式会社,
大阪府門真市大字門真 1006 番地 TI 本部西門真
okada.seigo@jp.panasonic.com

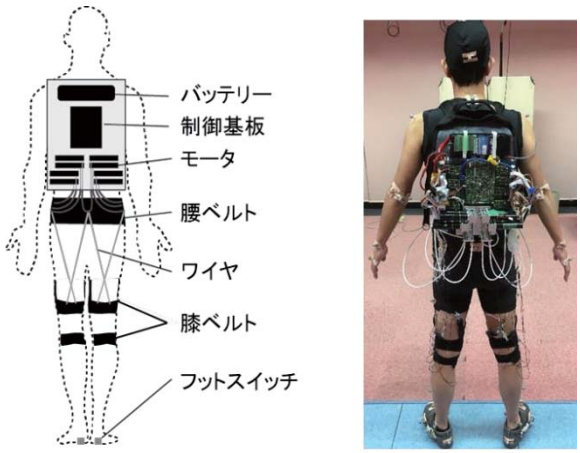


Figure 1. Outline of assist system

2.1 ワイヤ型アシストスーツ

本稿で用いるワイヤ型アシストスーツについて, ハード構成と制御方法について説明する.

(1) ハード構成

本稿で用いるワイヤ型アシストスーツの構成概略図と写真を Figure1 に示す. 本アシストスーツは, リュック形状のモータ駆動システムと, ワイヤをユーザの腰に固定するための腰ベルト, 左右の膝蓋骨を跨って装着し, ワイヤの端点を固定する膝ベルトから構成される. モータ駆動システムには, バッテリー, 制御基板(National Instruments 社 sbRIO-9637 搭載), モータ 8 本(Maxon 社: EC Servo モータ, 22mm-24V-100W, 減速比 16:1 のギアボックス付)とモータドライバ(Maxon 社 ESCON Module 50/5)が設置されている. また, 8 本のワイヤがモータ駆動システムの各モータから腰ベルトの固定点を経由し, 端点は左右の膝ベルトに取り付けられる. そして, もう一方のワイヤ端点は, モータに取り付けられた, 9mm 径のプーリに接着しており, 各ワイヤは, 最大で約 100N の張力を生み出すことが可能である. また,

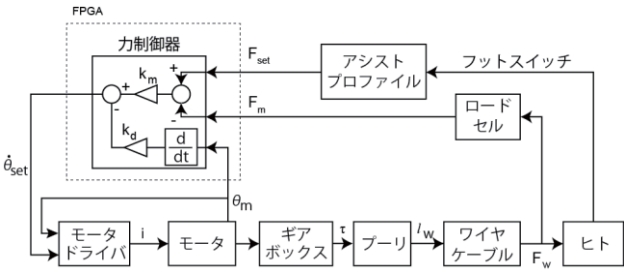


Figure 2. Control system configuration

ワイヤは Figure1 (b)に示すように，各脚の前後に 2 本，交差した形で設置され，モータの回転により，腰ベルト－膝ベルト間にワイヤ張力が発生し，股関節の運動を支援することができる．さらに，ワイヤを交差させ，各ワイヤの張力バランスを変更することで，股関節 3 自由度 6 方向（屈曲・伸展，外転・内転，外旋・内旋）へのアシストが可能となる．

本アシストスーツは，歩行周期（かかと接地から次のかかと接地までの時間）に基づいてワイヤ張力の制御が行われるため，ユーザの歩行周期を計測する必要がある．そこで，Figure1 (a)に示すように，靴のかかと部分にフットセンサを設置し，フットセンサの計測結果はワイヤレスでモータ駆動システムに送信する．また，膝ベルトにおけるワイヤ固定部分に，ロードセルを設置することで，リアルタイムでワイヤ張力の計測とフィードバック制御を行っている．

(2) 制御方法

本ワイヤ型アシストスーツは，Figure 2に示すように，実測した張力F_mと目標張力F_{set}の差を用いた，モータ速度へのP制御を行っており，モータ速度の入力コマンド$\dot{\theta_{set}}$は以下の式により決定する．

$$\dot{\theta_{set}} = K_m(F_{set} - F_m) - K_d\dot{\theta} \qquad (1)$$

ここで，K_mはP制御におけるゲインであり，K_dはモータ速度に対する減衰係数である．

ワイヤの目標張力F_{set}は，フットスイッチの計測結果から次ステップの歩行周期を予測し，あらかじめ設定している入力プロファイルを，各歩行周期100%に対して適応させることで決定される．本実験では，左右の後ろ側に取り付けた各2本ずつのワイヤに対して，歩行周期の87．5%から次ステップの20%まで50Nの張力を加えることで股関節運動の支援を行う．ここで入力プロファイルは正規化されており，実際に与える張力は，これに最大張力ゲインを乗算したものとなる．なお，この支援開始・終了タイミングは先行研究により，呼気ガスによってアシスト効果が確認されたものを用いている．

前節で述べたように，本アシストスーツはワイヤを交差させることで，様々な方向への股関節運動支援を可能にしているが，本稿では，直進歩行の進行方向のみに対してトルク支援を行うため，屈曲・伸展トルクのアシストのみ行った．

2.2 実験内容

荷物持ち歩行時のアシストスーツによる支援の評価を行うため，運動学情報と床反力情報を計測する実験を行った．Figure 3 に実験時の様子を示す．実験は下記の 4 条件で行った．

ⅰ）アシストスーツ装着無，荷物無（Normal）
ⅱ）アシストスーツ装着無，荷物有（Carry）
ⅲ）アシストスーツ装着有，荷物有，支援無（Suit）
ⅳ）アシストスーツ装着有荷物有，支援有（Assist）



Figure 3. Experiment of assist suit

なお，荷物は 8kg とし，荷物を持ち歩く際は，身体の前側に両手で持つように指示した．

被験者は 45 歳の男性で身長・体重はそれぞれ 177cm，体重 73kg である．被験者は，モーションキャプチャーシステム（Vicon 社製）により動きを計測するため，全身に 55 個の反射マーカーを装着し，約 3.6m の区間を歩行する．歩行区間の中央付近の床には 6 台のフォースプレートが（テック技販製）配置されており，1 歩行周期の両足の床反力を計測する．

また，ワイヤの取り付け位置を計測するために，各ワイヤの両端に反射マーカーを配置した．具体的には，膝ベルトへの固定点に 1 個と腰ベルトのワイヤ経路上に 1 個，計 16 個のマーカーを使用した．なお，モーションキャプチャー及びフォースプレートのサンプリング周波数はそれぞれ 200Hz，1000Hz である．

2.3 解析手法

上述の歩行動作計測結果に基づき，実験協力者およびワイヤの動作を計算機上に再現し，逆動力学解析を仮想的に行うことで，ワイヤ張力の大きさ・制御方法による支援効果の違いを評価する．以下にその手順を示す．

1) 立位静止姿勢の状態にて貼付された各マーカー位置情報から，実験協力者の人体モデルを構築し，表皮形状と関節位置・リンクの力学特性を表現する．

2)立位静止姿勢でのアシストスーツのワイヤ走行を再現する．ワイヤ 1 本につき両端点に貼付されたマーカー位置を結び，かつ 1)による人体表皮メッシュ上の最短経路を導出する．さらに，この経路上で走行が凹形となっている区間については，区間の端点を直線で結ぶように修正する（ワイヤ走行経路）．

3) 歩行動作中の各マーカー軌跡情報に基づき，1)で得られた人体モデルの各フレームでの姿勢を，逆運動学によって再現する．ここで，人体姿勢は，リンク構造モデルに含まれる各関節におけるローカル座標系の回転量によって表現される．

4) 3)で得られた各フレームでの人体姿勢に基づき，各フレームでのワイヤ走行経路を 2)の状態から更新する．

5) 以上より，歩行動作中の各フレームにおいて，人体モデルに対する逆動力学解析を行い，各関節に発生する関節間力および関節トルクの状態変化を推定する．その際，人体にかかる外力は，a) 床からの反力，b) アシストスーツの各ワイヤ端点における張力，および c) 各ワイヤの接触力とする．a)についてはフォースプレート，b)については，ワイヤに取り付けられたロードセルから得られた値を使用し，力の方向については 4)で得られたワイヤ走行経路における端点での経路の方向を使用する．c)については，b)を考慮し，各ワイヤにおける内力の総和が 0 となるように接触力を定め，その接触点は，各ワイヤ走行経路での，2 端点を結ぶ直線との距離が最長となる点とする．

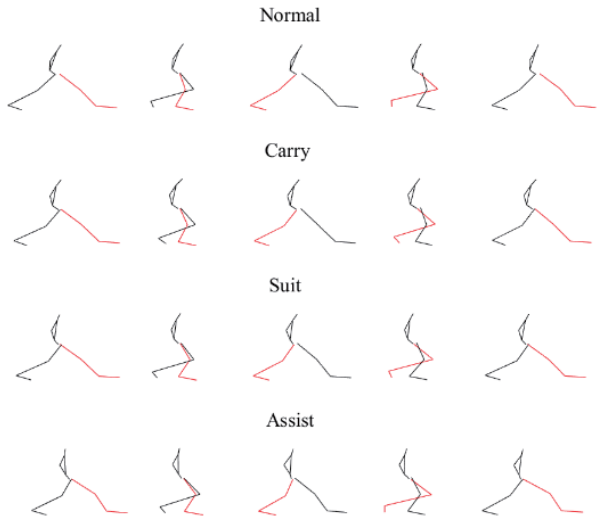


Figure 4. Stick picture of trunk and lower limb

Table 1. Step, stride and velocity

	First Step		Second Step		Stride	
	Length (m)	Time (s)	Length (m)	Time (s)	Length (m)	Velocity (m/s)
Normal	0.671	0.550	0.634	0.560	1.31	1.17
Carry	0.639	0.525	0.617	0.530	1.26	1.18
Suit	0.595	0.515	0.622	0.530	1.22	1.16
Assist	0.543	0.495	0.600	0.465	1.14	1.18

Table 2. Extension and flexion phase of stride

	Extension moment phase(%)	Flexion moment phase (%)
Normal	3~22, 63~96	0~2, 23~62, 97~100
Carry	1~34, 62~96	0, 35~61, 97~100
Suit	1~32, 64~92	0, 33~63, 93~100
Assist	3~26, 68~94	0~2, 27~67, 95~100

本研究における力学的評価対象は，股関節のみであるため，荷物持ち歩行の解析では，荷物のモデル化は行わず，荷物を持つことによって発生する股関節の力学的変化について評価を行った．

なお，本稿では，国立研究開発法人産業技術総合研究所が開発した人体シミュレーションソフトウェア「DhaibaWorks」[Y. Endo 2014]を使用し，上述の人体・アシストスーツのモデル化および力学解析評価を行なった．

3. 結果

Figure 4 に各条件における体幹及び下肢のスティックピクチャを示す． 体幹の傾きや歩幅が条件により変化していることが分かる．本章では，これらの動作について運動学及び運動力学の観点から解析した結果を示す．解析区間は左脚踵接地から次の左脚踵接地までの 1 ストライドとし，左脚について解析した．

3.1 歩幅及び歩行速度

Table 1 に各条件におけるステップの長さ，時間及びストライドの長さ及び歩行速度を算出した結果を示す．Normal 条件と比較して他の 3 条件では 1 歩目（左脚支持脚期）及び 2 歩目（左脚遊脚期）の歩幅が減少し， 4 条件の中では，Assist 条件で最も歩幅が短くなった．また，1 歩目及び 2 歩目に要する時間の合計時間とストライド長から歩行速度を算出した結果，歩行速度に大きな変化は見られなかった．1 ストライドにかかる時間についても，Normal 条件に比べ他の 3 条件で減少し，Assist 条件で最も短くなった．

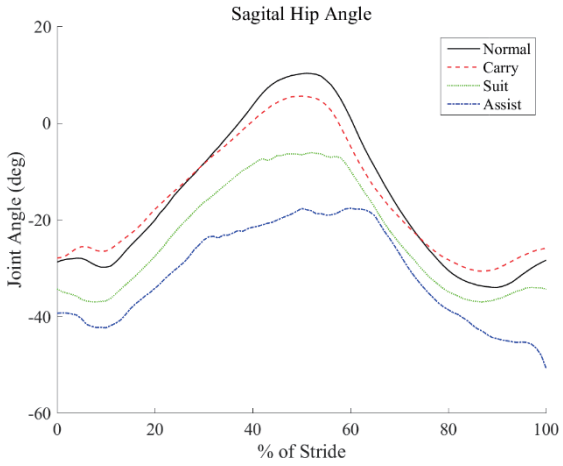


Figure 5. Sagital hip angle

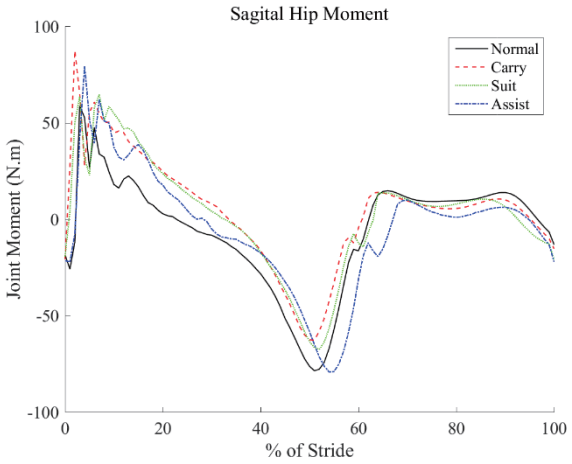


Figure 6. Sagital hip moment

3.2 股関節角度変化

Figure 6 に矢状面における股関節角度の変化を示す．股関節角度は骨盤中心に対する大腿の角度とし，股関節伸展側を正，屈曲側を負としている．Normal 条件と Carry 条件を比較すると，Carry 条件で最大伸展角度は減少し，立脚期に股関節伸展側へ遷移した．Carry 条件と Suit 条件を比較すると，Suit 条件で動作域が歩行周期全体で股関節屈曲側に遷移した．同様に，Suit 条件と Assist 条件を比較すると，股関節角度動作域が歩行周期全体で股関節屈曲側に遷移する結果となった．

3.3 股関節トルク発揮変化

Figure 6 に歩行ストライド中の矢状面における左脚股関節の発揮トルクを 0 から 100%に正規化したグラフを示す．股関節伸展側を正としている．また，Table 2 に 1 ストライドにおける伸展トルク発揮区間及び屈曲トルク発揮区間を示す．

Normal 条件では，踵接地後の股関節伸展トルク発揮区間は 3～22%の範囲であるのに対し，Carry 条件で 1~34%，Suit 条件で 1~32%，Assist 条件で 3~26%と長くなっている．Normal 条件と比較して，立脚期の股関節伸展トルクは，他の 3 条件で大き

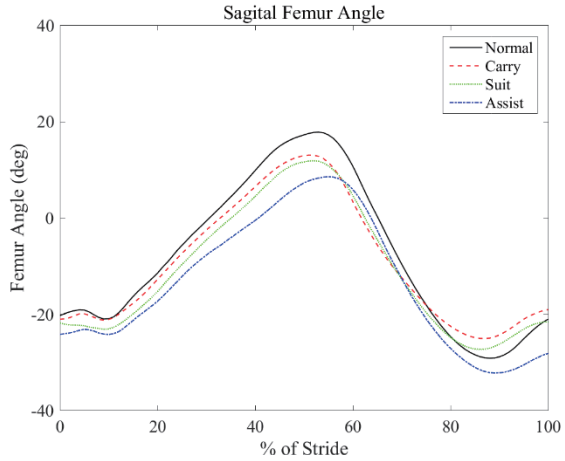


Figure 7. Sagital femur angle

い値となった. また, Carry 及び Suit 条件と比較して, Assist 条件では, 17~26%の区間で伸展トルクの減少が見られた.

屈曲トルク発揮区間に注目すると, 最大屈曲トルク発揮タイミングは, Assist の条件は他の3条件に比べ, 約 5%遅れていた. また, 最大屈曲トルクは, Carry 及び Suit 条件と比較し, Normal 及び Assist 条件で大きい値となった.

4. 考察

4.1 股関節角度変化の要因

3.2 における結果より Assist > Suit > Carry の順に, 股関節角度は屈曲側に遷移していた. 股関節角度の屈曲側への変化の要因としては, グローバル座標における大腿動作域の屈曲側への変化, またはローカル座標の中心となる骨盤の前傾が考えられる.

Figure 5 において, 股関節角度は Normal 条件と比較して, Assist 条件では 1 ストライド内の平均で 16 度屈曲側に変化している. ここで, Figure 7 にグローバル座標における大腿の角度を, 水平面の法線に対して股関節伸展側を正, 屈曲側を負として算出した結果を示す. Normal 条件と比較して, Assist 条件では 1 ストライド内の平均で 5.7 度屈曲側に変化している.

したがって, 股関節角度変化の要因として, 大腿の可動域の屈曲側への移動に加え, 骨盤の前傾の影響が大きいと考えられる. 骨盤が前傾した要因としては, アシストスーツの装着および支援による姿勢の後傾への対応が考えられる.

4.2 最大屈曲トルク発揮タイミング

Figure 6 より, 最大屈曲トルク発揮タイミングは, Assist の条件で他の条件と比較して約 5%遅くなっている. この原因を調べるため, Table 2 より算出した, 1 ストライドに占める立脚期及び遊脚期の時間の割合を Table 3 に示す. Assist 条件では他の 3 条件に比べ遊脚期の割合が小さい.遊脚期の割合が減少したことにより, 最大屈曲トルク発揮タイミングが相対的に遅くなったことが考えられる.

遊脚期の割合が小さくなった原因として, 片方の脚が遊脚期の際にはもう一方の脚は支持脚期で支援されている状態のため, 遊脚期間を短くしてバランスを保つように対応したからではないかと考えられる.

4.3 アシストスーツによる支援効果

最後に, アシストスーツによる力学的効果があったのかどうかを調べるため, Table 4 に示すように, 踵接地後の伸展トルク発揮積分値を算出した. その結果, Normal 条件と比較して Carry 条件は 128%増加, Suit 条件は 114％増加した. これに対し, Assist 条件は Carry 条件と比較して 25%減少, Suit 条件と比較して 20%減少した.

Table 3. Stance and swing phase ratio of stride

	Stance phase (%)	Swing phase (%)
Normal	49.5	50.5
Carry	49.8	50.2
Suit	49.3	50.7
Assist	51.6	48.4

Table 4. Angular impulse of extention period in stance phase

	Angular impulse (10^3*N・m)
Normal	0.947
Carry	2.16
Suit	2.03
Assist	1.62

本研究において支援は歩行ストライドの 87.5~20%に入力しており, 踵接地後の伸展トルク発揮区間の支援が期待されていた. 上述の結果より, この区間においては支援効果があったといえる.

5. おわりに

本研究において, アシストスーツの装着及び支援により, 歩幅の減少及び遊脚期期間の減少という歩容の変化が明らかになった. 支援効果については, 股関節伸展トルク発揮区間においては一定の支援効果が認められた. 今後, ストライド全区間での支援効果を得るため屈曲トルク発揮区間の支援も検討する.

参考文献

[M.Aach 2014] M.Aach, O.Cruciger, M.Sczesny-Kaiser, et al.: “Voluntary driven exoskeleton as a new tool for rehabilitation in chronic spinal cord injury: a pilot study”, *The Spine Journal*, vol.14, no.12, pp.2847-2853, 2014.

[A.T.Asbeck 2015] A.T.Asbeck, S.M.M.De Rossi, K.G.Holt, et al.: “A biologically inspired soft exosuit for walking assistance”, *The International Journal of Robotics Research*, vol.34, no.6, pp.744-762, 2015.

[S.W.John 2017] S.W.John, K.Murakami, M.Komatsu, et al.: “Cross-wire assist suit concept, for mobile and lightweight multiple degree of freedom hip assistance”, International Conference on Rehabilitation Robotics, pp.387-393, 2017.

[村上 2017] 村上, 井上, 岡田・他: “ワイヤ型歩行アシストスーツによる股関節への力学的支援効果”, 計測自動制御学会, 2017.

[L.M.Mooney 2014] L.M.Mooney, E.J.Rouse, and H.M.Herr: “Autonomous exoskeleton reduces metabolic cost of human walking during load carriage”, *Journal of neuroengineering and rehabilitation*, vol.11, no.1, p.80-90, 2014.

[S.W.John 2015] S.W.John, M.Komatsu, K.Murakami, et al.: “Soft hip walking assist experimental system featuring variable compliance control”, *IEEE International Conference on Consumer Electronics*, pp.400-401, 2015.

[Y. Endo 2014] Y.Endo, M.Tada, M.Mochimaru: “Dhaiba: Development of Virtual Ergonomic Assessment System with Human Models” Proceedings of The 3rd International Digital Human Symposium, 2014.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

Learning-based Selective Dual-arm Grasping for Warehouse Picking

Shingo Kitagawa Kentaro Wada Kei Okada Masayuki Inaba

the University of Tokyo, Graduate School of Information Science and Technology

We propose a learning-based system of selective dual-arm grasping and use Convolutional Neural Networks (CNN) for grasping point prediction and semantic segmentation. First, the network learns grasping points with the automatic annotation. and the grasping points are automatically calculated based on the shape of an object and annotated for both single-arm and dual-arm grasping. The robot then samples various grasping points with both grasping ways and learns optimal grasping points and grasping way. As a result of multi-stage learning, the robot learns to select and execute optimal grasping way depending on the object status. In the experiments with the real robot, we demonstrated that our system worked well in warehouse picking task.

1. Introduction

Recently, learning-based approaches have become popular in robot grasping, and self-supervised method and simulation-based one are both commont. However, the main difficulty of the learning-based approaches is the small variety of the grasping motion. These approaches deal only with one arm, but a robot can grasp more various objects with two arms, and many studies show the advantage of dual-arm manipulation [Harada 12, Edsinger 07]. Recent dual-arm robots such as Baxter[*1] are expected to manipulate various objects with two arms. However, learning dual-arm grasping is difficult because a robot needs to sample with both grasping ways for self-supervised approach [Pinto 16, Levine 16], and simulation-based one [Mahler 17, Viereck 17] needs to reproduce the grasping condition of dual-arm grasping, which is more complex than single-arm one. In this paper, we tackle the difficulties of learning to grasp with two arms and propose to combine supervised learning with the automatic annotation and self-supervised learning.

This paper focuses on how to learn to selectively grasp with two arms as shown in Fig.1, and we propose a learning-based system of selective dual-arm grasping. In the system, we use Convolutional Neural Networks (CNN) for grasping point and semantic segmentation. The network first learns grasping points with automatic grasping point annotation, and the automatic annotation is based on the geometric constraints of objects. The robot then samples various grasping points, tries to grasp by both grasping way and learns where to grasp and which grasping way is optimal. In detail, the robot executes both grasping way with various grasping points and collect its grasping data with the trained network, and we train the network again with the sampled data for the real world adaptation. Finally, the robot selects and executes optimal grasping from single-arm and dual-arm ones with the adapted network. The whole system of the multi-stage learning is described in Fig.2, and this learning-based system adapts the network to various objects and requires fewer grasping trials with the real robot. In the experiments, we demonstrated our system worked well in warehouse picking task.

Contact: Shingo Kitagawa, Graduate School of Information Science and Technology, University of Tokyo, 113-8656, 7-3-1, Hongo, Bunkyo-ku, Tokyo, Japan, 03-5841-7416, s-kitagawa@jsk.imi.i.u-tokyo.ac.jp

∗1 http://www.rethinkrobotics.com/baxter/

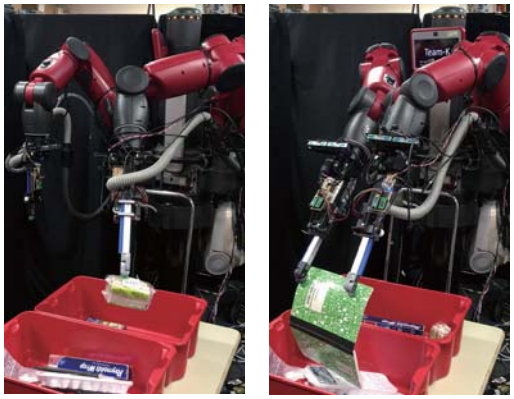


Figure 1: The robot learns how to grasp and whether single-arm or dual-arm grasping is optimal to execute corresponding to the environment. Images are from [Kitagawa 18]

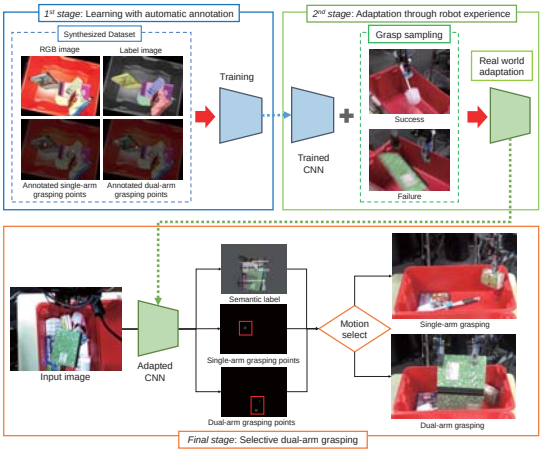


Figure 2: We propose a multi-stage learning system of dual-arm selective grasping. The CNN first learns how to grasp with automatic grasping point annotation, and the robot samples grasping with the trained network and learns with the collected data. Finally, the robot selectively executes dual-arm grasping with the adapted network.

2. Related Work

Learning-based Grasping. Recent approaches use CNN to predict the success probabilities of grasping pose [Pinto 16]

[Mahler 17], and semantic segmentation network is also used for the prediction of grasping pose [Kusano 17]. In this paper, we focus on the grasping ability of a vacuum gripper and predict grasping point with CNN. In order to predict grasping point (x, y) on RGB image, our approach segments whole region into two region; graspable and ungraspable and predicts the success probabilities of for both single-arm and dual-arm grasping for each pixel.

Self-Supervised Learning of Grasping. One main stream of learning-based grasping is self-supervised approach, and the previous study shows its effectiveness with high success rate of grasping [Pinto 16]. This study uses Mixture of Gaussians (MOG) background subtraction algorithm as a primitive algorithm, but it is not efficient enough for sampling, so that it requires more than 300 trials for each object on average, which is time consuming and high workload for robot. In this paper, we give a primitive grasping algorithm beforehand, and a robot samples grasping efficiently and learns grasping in short time.

3. Learning with Automatic Annotation

3.1 Automatic Grasping Point Annotation

For the automatic annotation, we design a primitive grasping algorithm. We prepare several RGB images for each object and calculate the grasping points for both single-arm and dual-arm grasping from geometric conditions of the object. First, we do background subtraction on RGB image to get the object region, and the single-arm grasping point then is calculated as a center point of the region as shown in Fig.3(a). For dual-arm grasping points, we assume that the points are lined in the first principal component of the object region, so that we do PCA on x and y axes of the object region and annotate them as shown in Fig.3(a). Therefore, the background subtraction and geometric analysis such as PCA on the object region is implemented as the primitive algorithm, and the generated images are used for the dataset synthesis.

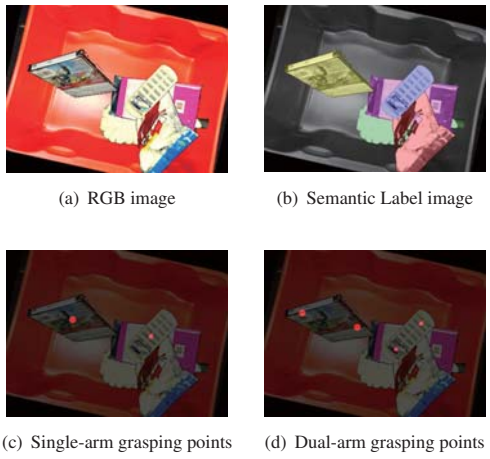


(a) Single-arm grasping point (b) Dual-arm grasping points

Figure 3: The object region is inside the green boundary, and the annotated grasping points are drawn as red crosses. We first do the background subtraction on an original RGB image to get the object region. A single-arm grasping point (a) and dual-arm grasping points (b) are calculated from the primitive grasping algorithm from the region.

3.2 Grasping Dataset Synthesis*2

Using the generated data with the automatic annotation, we synthesize a dataset for semantic and grasping point segmentation. For the dataset synthesis, we do image stacking [Dwibedi 17] and paste subtracted object images randomly on a background image in the real experimental environment. With stacking several RGB images of object images on one background image, the synthesized image reproduces a clutter such as warehouse picking environment, where objects occlude with each other. The pixelwise semantic labels are simultaneously annotated as the RGB image synthesis, and the grasping points are annotated as pixelwise graspable region. The synthesized images of pixelwise semantic labels and graspable label for both single-arm and dual-arm grasping are shown in Fig.4(b), Fig.4(c), and Fig.4(d). If 10% of an object region is hidden by other objects because of overlaps, we regard the overlapped object as ungraspable because of its physical occlusion and do not annotate its grasping points. Therefore, an object 90% of whose region is visible is treated as placed on the top of a clutter and graspable. With the synthesized dataset, we train a CNN to predict and segment the semantic and graspable regions.



(a) RGB image (b) Semantic Label image

(c) Single-arm grasping points (d) Dual-arm grasping points

Figure 4: We stack the subtracted RGB object images and pixelwise semantic labels are simultaneously annotated as (a). The grasping points for both single-arm (b) and dual-arm grasping (c) are also annotated as pixelwise graspable labels. Images are from [Kitagawa 18].

3.3 Pixelwise Graspable and Semantic Segmentation

3.3.1 Network Design

We propose an FCN-based network to predict pixelwise semantic and graspable label simultaneously. The whole structure is based on FCN32s [Long 15] and described in Fig.5. The network has two parts of convolution layers: the former has the same structure as convolution layers of VGG16 [Simonyan 14] and extracts features from RGB image, and the latter splits into each task and separately predicts pixelwise semantic labels and graspable labels of single-arm and dual-arm grasping. Therefore, the network does three segmentation task and outputs three probability images from one RGB image. Semantic segmentation is formulated as same as FCN [Long 15], and it predicts the pixelwise probabilities of semantic labels including the background. For grasping point prediction, we treat it as pixelwise graspable segmentation, and the network predicts the pixelwise probabilities of graspable labels. For the input and the output of the network, we resize RGB image and corresponding label images in 640x480.

3.3.2 Network Training

The loss function of semantic segmentation L_{seg} is calculated with softmax cross entropy SCE for each pixel For graspable segmentation, we define the same loss function for both single-arm and dual-arm grasping. As the graspable regions are much smaller than ungraspable regions, we set a weight w^c_{grasp} for label c based

*2 **The subsections are from [Kitagawa 18]**

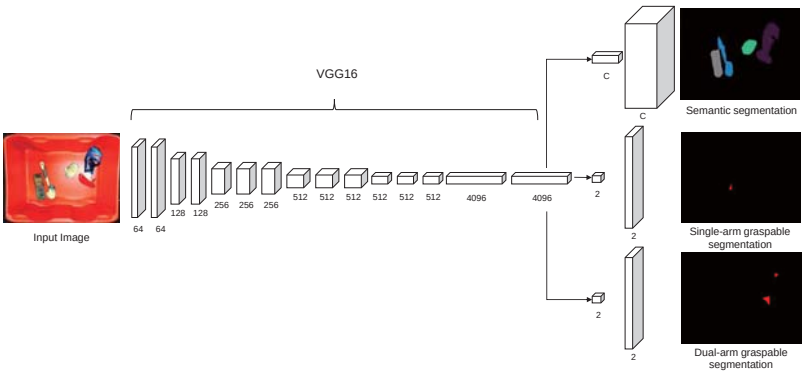


Figure 5: Our network predicts the pixelwise probabilities of semantic and graspable labels simultaneously. C is the number of semantic labels including the background.

on frequency balancing [Badrinarayanan 15], which increases loss value of smaller regions:

$$w^c_{grasp} = \begin{cases} \frac{N_{foreground}}{\alpha_c N_c} & (N_c \neq 0) \\ 0 & (N_c = 0) \end{cases}$$

where $grasp \in \{single, dual\}$ is a grasping way, $N_{foreground}$ is the number of non-background pixels in ground truth image of semantic segmentation, N_c is the number of labels c pixels in ground truth image of grasping segmentation and α_c is a constant parameter for class c. With w^c_{grasp}, the loss of graspable segmentation L_{grasp} for both single-arm and dual-arm grasping is calculated with softmax cross entropy SCE as follows:

$$L_{grasp} = -\sum_{c}^{C_{grasp}} \sum_{x,y}^{W,H} w^c_{grasp} SCE(l^c_{grasp}(x,y), h^c_g(x,y)) \quad (1)$$

where C_{grasp} is the number of grasp labels, l^c_{grasp} is one hot vector of class c at a pixel (x, y) and $h^c_{grasp}(x, y)$ is network output of class c at a pixel (x, y). Since graspable segmentation divides the whole region into two labels: graspable and ungraspable, the number of grasp labels C_{grasp} is fixed as 2. For the whole network, the total loss L_{total} is calculated as the summation of all losses, L_{seg}, L_{single} and L_{dual}, and back-propagated through the network except the deconvolution layer.

For the optimization, learning rate is initially set as $1.0\mathrm{e}{-5}$. We train the network with $\alpha_{graspable} = 20.0$ and $\alpha_{ungraspable} = 1.0$, and the training is done in 200000 iteration with around 20000 synthesized data pairs. In order to make the segmentation robust, we do data augmentation, and random flip, rotation and RGB modification are added in every iteration.

4. Adaptation through the Robot Experience

4.1 Grasp Sampling with Trained Network

For the real world adaptation of the trained network, a robot executes grasping trials in the real world with the network and train and adapt the network with the collected data. In the sampling, we put an object in front of the robot one by one and try to grasp it with both single-arm and dual-arm grasping. The robot samples grasping points by weighted random sampling using graspable segmentation output of the trained network, and we use the pixelwise graspable probabilities inside the object region as the weight of the sampling, The robot records the grasping result with two labels success and failure by air pressure sensors, and the failure consists of grasping failure and self-collision failure. The grasping failures may happen when a robot does not sample appropriate grasping points and occurs in both single-arm and dual-arm grasping cases. On the other hand, the self-collision failure only happens in the case of dual-arm grasping, and two arms of the robot are too close or crossing in this case.

4.2 Adaptation with the Sampled Data

After sampling and collecting grasping data in the real world, we adapt the network by the data. First, we generate an object mask image with semantic segmentation output of the network. For graspable segmentation, we annotate successful grasping points with graspable label and ungraspable label on the rest of the object region. With the annotated data, we synthesize a dataset with the same algorithm in Subsection 3.2, and we do the adaptation of the network with the synthesized dataset.

The learning rate is initially set as $1.0\mathrm{e}{-6}$, and the training is done in 12000 iterations, but all the other parameters for training is same as the training with the automatic annotation. We also do the same data augmentation in this phase.

5. Selective Dual-arm Grasping

5.1 Extracting Object Graspable Region

With the adapted network, a robot selects to execute proper grasping motion for successful grasp, and we design selective dual-arm grasping system shown in Fig.6. In order to evaluate the two grasping motion, we first do pixelwise multiplication of the probabilities of semantic label and graspable label image. With the result of the multiplication, we select object label and grasping way from single-arm or dual-arm grasping with $Argmax$ function for every pixel. Therefore, the robot determines which object to grasp and which grasping way should be executed with $Argmax$ function. After the motion select, we get the selected object region from $softmax$ output of the semantic probabilities. The graspable region is also extracted from the selected graspable probabilities P_{grasp} with the threshold $max(P_{grasp}) - 0.05$. The final graspable region of the selected object is generated by merging the two regions with $PixelwiseAnd$ function.

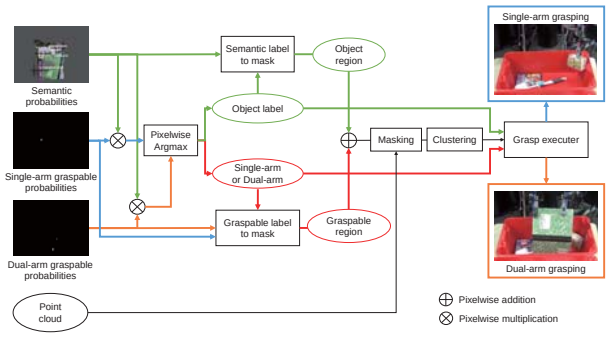


Figure 6: We propose a selective dual-arm grasping system using semantic and graspable segmentation. The robot selects the object and the grasping way from the network outputs and determines grasping points using the region and point clouds.

5.2 Selecting Grasping Points with Point Clouds

From the graspable region, the robot tries to grasp the center of the region. In order to grasp the center of the region, we first extract point clouds in the region by masking. After the masking, we do Euclidean clustering on the extracted point clouds and calculate the each center of each clusters. We use the center of biggest cluster as the grasping point of single-arm grasping, and for dual-arm grasping, we use the centers of two biggest clusters as grasping points. In the end, the robot executes grasping with the calculated grasping points and selected grasping way.

6. Experiments

6.1 Experimental Configuration*2

We chose 9 objects from the target objects in Amazon Robotics Challenge 2017 [Morrison 17], and all the experiments in this paper are conducted in [Kitagawa 18]. For the multi-stage learning, we did the self-supervised adaptation stage twice after learning with the automatic annotation. The robot collected 94 data pairs in the first sampling time and 121 pairs in the second time. Therefore, the network was trained with a dataset synthesized from 94 sampled data and original object data in the first adaptation stage, and it was again trained only with 215 sampled data in the second adaptation stage.

6.2 Warehouse Picking Experiments*2

For the final experiments, we applied our method to warehouse picking task. We put all the 9 objects in one tote, and the robot grasped one object and moved it to the other tote. The objects in tote were cluttered and overlapped with each other, and the robot is required to recognize both semantic and graspable region correctly. We did the picking experiments twice in different settings, and the robot successfully grasped and moved 6 objects in the first configuration and 8 objects in the second one. In the experiments, the robot mostly grasps objects with one arm (Fig.7(a)), but also executed dual-arm grasping once in both trials (Fig.7(b)).

7. Conclusion

In this paper, we propose a multi-stage learning method of dual-arm grasping for warehouse picking and implement it to the real robot. For efficient grasp learning, we propose a multi-stage learning method with the automatic annotation and grasping trials in the real world, and our method achieved high grasping success rate with few trail times. In the experiment, dual-arm grasping was only executed for 10 times because it often failed in the sampling. In order to make the robot choose dual-arm grasping more, we need to normalize the distribution of the sampled data.



(a) (b)

Figure 7: The robot successfully grasped Aluminum foil with one arm (a) and Pink table cloth with two arms (b). Images are from [Kitagawa 18].

References

[Badrinarayanan 15] Badrinarayanan, V., Kendall, A., and Cipolla, R.: SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation, *CoRR*, Vol. abs/1511.00561, (2015)

[Dwibedi 17] Dwibedi, D., Misra, I., and Hebert, M.: Cut, Paste and Learn: Surprisingly Easy Synthesis for Instance Detection, *CoRR*, Vol. abs/1708.01642, (2017)

[Edsinger 07] Edsinger, A. and Kemp, C. C.: Two arms are better than one: A behavior based control system for assistive bimanual manipulation, in *Recent progress in robotics: Viable robotic service to human*, pp. 345–355, Springer (2007)

[Harada 12] Harada, K., Foissotte, T., Tsuji, T., Nagata, K., Yamanobe, N., Nakamura, A., and Kawai, Y.: Pick and place planning for dual-arm manipulators, in *International Conference on Robotics and Automation (ICRA)*, pp. 2281–2286IEEE (2012)

[Kitagawa 18] Kitagawa, S., Wada, K., Okada, K., and Inaba, M.: Multi-stage Learning of Selective Dual-arm Grasping Based on Obtaining and Pruning Grasping Points Through the Robot Experience in the Real World, in *International Conference on Intelligent Robots and Systems (IROS)*IEEE/RSJ (submitted in 2018)

[Kusano 17] Kusano, H., Kume, A., Matsumoto, E., and Tan, J.: FCN-based 6D Robotic Grasping for Arbitrary Placed Objects, in *International Conference on Robotics and Automation (ICRA): Warehouse Picking Automation Workshop 2017: Solutions, Experience, Learnings and Outlook of the Amazon Picking Challenge*IEEE (2017)

[Levine 16] Levine, S., Pastor, P., Krizhevsky, A., and Quillen, D.: Learning Hand-Eye Coordination for Robotic Grasping with Deep Learning and Large-Scale Data Collection, *CoRR*, Vol. abs/1603.02199, (2016)

[Long 15] Long, J., Shelhamer, E., and Darrell, T.: Fully Convolutional Networks for Semantic Segmentation, in *Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 3431–3440 (2015)

[Mahler 17] Mahler, J., Liang, J., Niyaz, S., Laskey, M., Doan, R., Liu, X., Ojea, J. A., and Goldberg, K.: Dex-Net 2.0: Deep Learning to Plan Robust Grasps with Synthetic Point Clouds and Analytic Grasp Metrics, *Robotics: Science and Systems (RSS)* (2017)

[Morrison 17] Morrison, D., Tow, A. W., McTaggart, M., Smith, R., Kelly-Boxall, N., Wade-McCue, S., Erskine, J., Grinover, R., Gurman, A., Hunn, T., Lee, D., Milan, A., Pham, T., Rallos, G., Razjigaev, A., Rowntree, T., Vijay, K., Zhuang, Z., Lehnert, C. F., Reid, I. D., Corke, P., and Leitner, J.: Cartman: The low-cost Cartesian Manipulator that won the Amazon Robotics Challenge, *CoRR*, Vol. abs/1709.06283, (2017)

[Pinto 16] Pinto, L. and Gupta, A.: Supersizing self-supervision: Learning to grasp from 50K tries and 700 robot hours, in *International Conference on Robotics and Automation (ICRA)*, pp. 3406–3413IEEE (2016)

[Simonyan 14] Simonyan, K. and Zisserman, A.: Very Deep Convolutional Networks for Large-Scale Image Recognition, *CoRR*, Vol. abs/1409.1556, (2014)

[Viereck 17] Viereck, U., Pas, ten A., Saenko, K., and Jr., R. P.: Learning a visuomotor controller for real world robotic grasping using easily simulated depth images, *CoRR*, Vol. abs/1706.04652, (2017)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

統合モデルを用いた行動・言語・プランニングの学習

Integrated Model for Learning of Actions, Language and Planning

宮澤 和貴 Kazuki Miyazawa　青木 達哉 Tatsuya Aoki　堀井 隆斗 Takato Horii　日永田 智絵 Chie Hieida　中村 友昭 Tomoaki Nakamura　長井 隆行 Takayuki Nagai

電気通信大学情報理工学研究科
Faculty of Infomatics and Engineering, The University of Electro-Communications

It is very interesting to contemplate how humans learn, plan, and decide behaviors. Correlating, high-level functions, such as action-planning, deciding, language understanding, and thinking, is still an open problem in robotics. Therefore, we propose a framework to simultaneously learn concepts, language, actions, and planning. This can be achieved by integrating various modules and leveraging mainly multimodal categorization by using multilayered multimodal latent Dirichlet allocation (mMLDA). Integration of reinforcement learning and mMLDA enables behavior based on understanding. Furthermore, the mMLDA, in conjunction with grammar learning, based on the Bayesian hidden Markov model, allows the robot to verbalize its own actions and understand a user's utterances. Additionally, by combining mMLDA and the hidden Markov model, planning becomes possible. We verify the potential of the proposed framework through experiments in a simulation environment using real data.

1. はじめに

人間と共存し生活を支援するような知的なロボットの登場が期待されている．このようなロボットを実現するには，人間が活動する実世界において，ロボットが周囲の環境や言語を理解して行動する必要がある．筆者らは，記号創発ロボティクスの視点から言語を含むロボットによる実世界の理解について検討を続けてきた [1]．これらの取り組みでは，ロボットが経験によって取得するマルチモーダル情報をカテゴリ分類し，概念をボトムアップに形成することを基盤としている [2, 3, 4]．これらは，マルチモーダル LDA を概念形成の基盤としており，同様の枠組みで，簡単な言語や行動を扱うことができる．

また近年の深層学習技術の発展に基づき，ロボットの様々なタスクにおいて，深層強化学習の有用性が示されている [5, 6]．我々と同様にマルチモーダルデータを用いた学習や，言語と行動の同時学習も盛んに研究されている [7, 8]．これらのアプローチでは，知能の一部に焦点を当てモデル化することにより，機能単位の知能を獲得している．一方で，実世界のような複雑な環境で動作するロボットを作るには，個々の知能が相互作用するような複雑な知能を考る必要がある．

そこで我々は，複数の知能モジュールを統合した統合モデルを提案した [4]．しかし，この研究においても，概念形成と強化学習の統合のみに留まっている．本稿では，さらにモデルを拡張し，行動と知能獲得のループの中で概念・行動・言語・プランニングを同時に学習する手法を提案する．これを，多層マルチモーダル LDA を中心に様々なモジュールを統合した統合モデルとして実現する．また，実データを用いたシミュレーション環境で実験を行い，提案するモデルの有効性を検証する．

2. フレームワーク

本稿で提案する統合モデルを図 1 に示す．このモデルは，多層マルチモーダル LDA(mMLDA)[9] を中心に複数のモジュールを統合することで成り立っている．形成した概念を利用するモジュールは，言語を扱う Bayesian Hidden Markov Model (BHMM)，即時的な行動決定を行う強化学習 (Direct Policy Search)，行動の時系列をモデル化し長期的なプランニングを行う Hidden Markov Model (HMM) である．統合モデルにおいて，単語情報は，mMLDA を通じて実世界の情報に接地している．この単語情報に BHMM で表現された統語情報を適用することにより，提案されたモデルはセンサ情報に基づき文章を生成することができる．また，文章を分解して実世界の情報を予測することで，ロボットは文章の意味を理解することができる．一方で，行動に関しては，方策に基づいた即時的な行動と，プランニングに基づいた行動を考える．強化学習は，mMLDA が形成した概念を状態空間として扱い，理解に基づいた即時的な行動を決定する．また，HMM に表現される時系列情報とビタビアルゴリズムを用いることで長期的な行動を計画することができる．即時的な行動モデルと行動計画のモデルをサブサンプションアーキテクチャを通して結合することで，多種多様な行動を可能にする．次章では，概念形成，方策学習，言語学習，プランニングの学習について詳細を述べる．

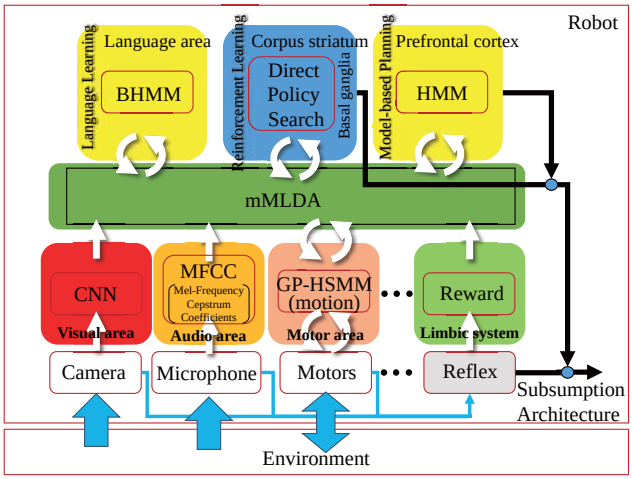


図 1: 提案する統合モデルの概要

連絡先: 宮澤 和貴，電気通信大学，東京都調布市調布ヶ丘 1-5-1，miyazawa@apple.ee.uec.ac.jp

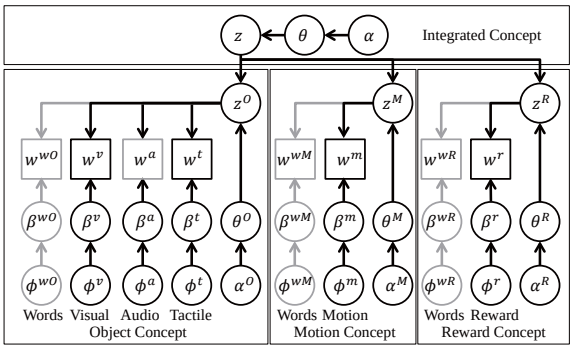


図 2: 概念形成に用いた mMLDA のグラフィカルモデル

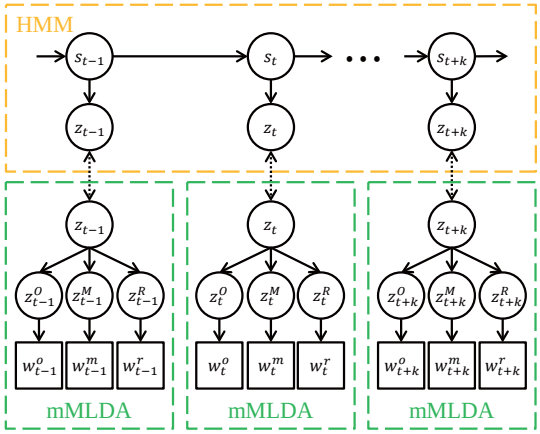


図 3: mMLDA の時間的拡張

3. 提案手法

3.1 概念形成

概念形成には mMLDA を用いる．mMLDA は，下位層に物体，動作，場所などの下位概念を表現するマルチモーダル LDA (MLDA) を，上位層にそれらを統合する MLDA を配置した階層構造をもつ確率モデルである．これにより，動作，場所，物体など各々のカテゴリ分類を行うと同時に，それらの概念間の関係を教師なしで学習することができる [9]．図 2 に，本研究の実験で用いた mMLDA のグラフィカルモデルを示す．図 2 において，z は統合概念を表すカテゴリであり，z^O，z^M，z^R はそれぞれ下位概念に相当する，物体，動作，報酬カテゴリである．上位カテゴリ z は，下位カテゴリ間の関係性を捉えており，ロボットが動作しているシーンを表現する．w^v, w^a, w^t, w^m, w^r, w^{w*} は観測データであり，それぞれ，視覚情報，聴覚情報，触覚情報，動作情報，報酬情報，言語情報である．β^*，θ^* は多項分布のパラメータであり，ϕ^*，α^* はディリクレ分布のパラメータである．以下各々の観測情報について述べる．

視覚情報は，物体画像を畳み込みニューラルネットワーク (CNN) によって変換した 4096 次元の情報を，学習の高速化のため，正規化したのち非負値行列因子分解を行い 500 次元に圧縮した情報を用いた．聴覚情報は，音情報をメル周波数ケプストラム係数 (MFCC) を用いて特徴量ベクトルを抽出し，50 次元のあらかじめ定義したコードブックを用いてベクトル量子化を行い 50 次元の情報とした．触覚情報も聴覚情報のように，15 次元のコードブックを用いて 15 次元のヒストグラムとして変換したものを用いた．動作情報は，ロボットのシミュレーション上での上下左右の動作を 4 次元の $1-of-k$ 表現としたもの用いた．報酬情報は，ロボットが行動することで得た報酬値を利用し，報酬値 r を $r<0, r=0, r>0$ により場合分けして，3 次元の $1-of-k$ 表現としたものを用いた．言語情報は，人から与えられたシーンに対応する文章を，形態素解析を行い，その中に含まれる単語の頻度とした．また，後述する言語モジュールにより，言語情報 w^{w*} はそれぞれの概念に対応した重みづけをする．

mMLDA では，各概念を表す隠れ変数 z，$z^C = \{z^O, z^M, z^R\}$ を同時に学習する．学習にはギブスサンプリングを用い，各概念を表すカテゴリ z，z^C を，観測データ $w = \{w^v, w^a, w^t, w^m, w^r, w^{w*}\}$ を用いてサンプリングする．サンプリングには，$\theta, \theta^C, \beta^m$ を周辺化した事後分布を用いる．学習モデルを用いることで，物体や動作の認識だけでなく，概念間の予測も可能となる．

3.2 方策の学習

方策の学習には，方策勾配法の手法の一つである REINFORCE アルゴリズム [10] を用いる．mMLDA と強化学習の統合は，mMLDA によって形成した物体概念を，強化学習の状態空間として用いることで行う．物体概念 z^O は，観測情報 w^v, w^a, w^t から式 (1) により推定する．推定した物体概念 z^O を用いて，式 (2) により方策を求める．

$$z^O \sim P(z^O|w^v, w^a, w^t) \tag{1}$$

$$\pi_{\theta_{RL}}(a|z^O) = \frac{exp(\theta_{RL}^T \psi(z^O, a))}{\sum_{b \in A}(exp(\theta_{RL}^T \psi(z^O, b)))} \tag{2}$$

ここで，A は全行動，θ_{RL} は方策のパラメータベクトル，$\psi(*)$ は z^O と行動 a によって特徴を計算する関数である．今回は行動が離散のため，方策関数は，ソフトマックス関数を用いる．方策のパラメータ θ_{RL} の更新は以下の式により行う．

$$\theta_{RL}^{t+1} = \theta_{RL}^t + \eta \nabla_{\theta_{RL}} J(\theta_{RL}) \tag{3}$$

$$\nabla_{\theta_{RL}} J(\theta_{RL}) \approx \frac{1}{L}\sum_{l=1}^{L}\frac{1}{T}\sum_{t=1}^{T}\nabla_{\theta_{RL}} \log \pi_{\theta_{RL}}(a_t^l|(z^O)_t^l) R_t^l \tag{4}$$

ここで，η は学習率，R_t^l は l エピソード目の t ステップ目の報酬である．式 (1) では観測情報 w^v, w^a, w^t から物体概念 z^O を求めたが，他の観測情報 w^* から物体概念 z^O を推定して，方策 $\pi_\theta(a|z^O)$ を計算することも可能である．これにより，モダリティ情報が欠損している状態やモダリティの種類が違う状態においても方策の計算ができる．例えば，物体に関する物理的情報 w^v, w^a, w^t が取得できなくても，言語情報 w^{wO} から z^O を推定することで，方策の計算が可能になる．方策から行動の決定には，ϵ-greedy 法を用いる．

3.3 言語の学習

言語学習は，mMLDA と BHMM によって行う [3]．ここで扱う文法とは，各単語の品詞と語順の情報である．品詞は，概念クラスによって表現されると考え，語順はこの概念クラスがどのような順番で並ぶことで文を構成するかをマルコフモデルで表現する．従って品詞推定の問題は，切り出された各単語が，どの概念クラスを表現するのに用いられるのかを推定する問題である．一方 mMLDA では，各概念に教示文から得ら

れる単語情報を与えて学習を行う．つまり，概念を形成するためには各単語の品詞が推定されている必要がある．そこで，文章を単語分割し，mMLDA による概念形成を全ての単語が全ての概念クラスに属すると仮定した上で行う．そして，相互情報量を用いた単語と概念クラスの結び付けを計算することで，再び mMLDA を更新する．これによって mMLDA は新たにどの単語がどの概念クラスから生成されるかを確率的に計算できるため，その情報を初期値として BHMM による品詞推定を再び行う．以上の手順を繰り返すことで，品詞 (概念クラスと単語の結び付け)，文法，概念を学習することができる．

3.4 プランニングの学習

統合概念 z は，あるシーンを表しており，時系列情報を表現できない．そこで，図 3 に示すように，HMM を用いて統合概念 z を時間方向に発展させる．隠れ状態 s，出力確率 $P(z_t|s_t)$，遷移確率 $P(s_t|s_{t-1})$ である HMM を考える．これをバウム＝ウェルチアルゴリズムを用いて学習することで，統合概念系列 $Z = \{z_{t-1}, z_t, ..., z_{t+k}\}$ を考えることができる．そのため，抽象化した概念の時系列上で，プランニングが可能になる．ゴール状態が決定されればビタビアルゴリズムを用いることでゴール状態までのプランニングが行える．さらに，統合概念 z から観測情報 w^* を推定可能なため，時系列的な，報酬情報 w^r，動作情報 w^m，を推定することができる．そのため，求めた Z の将来に得られる累積報酬値を予測することができる．これを用いることでいくつかの Z から，予測される累積報酬値が最も高い Z を選択することができる．さらには，求めた Z から動作情報 $w_t^m \sim P(w_t^m|z_t)$ を求めることでプランニングにおける動作系列まで推定が可能になる．

4. 実験

4.1 実験設定

実験の目的は，迷路の環境内で，ロボットが自ら行動選択を行い情報を取得する中で，概念・行動・言語・プランニングを同時に学習することである．実験は，図 4 に示すシミュレーション環境で行った．迷路の各状態 S は，図 4 に示す物体のカテゴリと対応している．ロボットが迷路のある状態に進むと，その状態に対応するカテゴリの中から，物体がランダムに 1 つ選択される．この物体情報は実ロボットによって事前に取得したものを用いた．ロボットは，動作後に物体と行動に対応した言語情報と報酬を取得する．報酬値は，ロボットがゴールに近づくと +1，離れると −1 とした．迷路での上下左右の移動には，図 4 に示す動詞が割り当てられている．例えば，ペットボトル (S5) を握り (上に移動) 正の報酬を得た場合,「ペットボトルを握るのは良いね」というような言語情報が与えられる．ロボットによる行動は，1) 物体情報の取得，2)mMLDA による概念の計算，3) 概念と方策に基づいた行動選択，4) 物体と行動に対応した報酬と言語情報の取得，のような流れで行った．この流れを 1 ステップとし，1 エピソードが終了するまで繰り返した．1 エピソードは，ロボットがゴールにたどり着くか，50 ステップ行動した場合に終了とした．各エピソードの終了後，取得したマルチモーダルデータを用いて概念と各モジュールのパラメータをオンラインで更新した．この設定で，1000 エピソード学習と行動を行った．

4.2 迷路での行動学習

迷路での行動学習の結果について図 5 に示す．図 5 は，各エピソードにおける獲得した報酬値と 1 エピソードに要したステップ数を示している．太線は移動平均を表しており，細線は各エピソードでの値を表している．これらを見ると，エピソードが進むことで報酬値が上がり，ステップ数が減がっていることが分かる．また表 1 は入力モダリティを変えて行動した結果である．行動選択には全エピソード学習後のパラメータを用いた．また，探索する必要がないため $\epsilon = 0$ として行動を選択した．1000 エピソード迷路で行動させ，平均ステップ数と平均累積報酬値を各モダリティ入力毎に求めた．また，比較のために，ランダムに行動した場合の結果も合わせて求めた．表 1 を見ると，vision,audio,tactile を入力した時に比べて，vision と words の入力における平均累積報酬値は高い．設定した環境での最大累積報酬値は 4 でなので，vision と word の入力では，ほとんどの試行で正しい行動選択ができたといえる．audio と tactile の入力は，vision,audio,tactile の入力に対して累積報酬値は低い．しかし，ランダムに行動した時に比べて，平均累積報酬が高く，平均ステップ数は小さくなっている．



図 4: 実験環境．左上：迷路の形状．左下：行動と動詞． 右：迷路の各状態に対応するカテゴリとその代表物体． 物体数は S0 から S7 までそれぞれ 11,10,11,5,16,26,33,22, 合計 134 個.

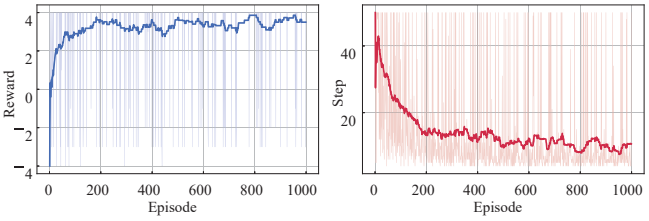


図 5: エピソード毎の行動結果．左:報酬値．右:ステップ数.

4.3 概念の学習結果

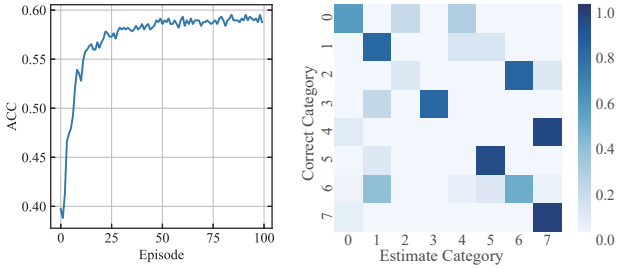
図 6 は物体情報 (vision,audio,tactile) を入力した際の，各エピソードごとのカテゴリ分類精度を示している．図 6(a) を見ると，約 50 エピソード目で精度が 6 割になり，その後ほぼ一様なことが分かる．図 6(b) は，100 エピソードで推定した物体概念の混合行列を示している．図 6(b) をみると，カテゴリ 2 はカテゴリ 6 に，カテゴリ 4 はカテゴリ 7 に混同されている．これは，カテゴリ 2(紙パック) とカテゴリ 6(お菓子 (箱))，カテゴリ 4(スポンジ) とカテゴリ 7(ぬいぐるみ) の特徴が類似していたためと考える．

4.4 言語の学習結果

迷路で行動することで，105 種類の単語を取得した．各物体に対して言語情報以外を入力し，単語の予測確率を求めた．予測した上位 3 単語のうち 1 単語でも正解単語であれば予測を正解とした．その結果 77% の物体に対して正解単語を予測した．図 7(a) は各品詞の上位 7 単語の出力確率 $P(w|C)$ を表しおり，図 7(b) は品詞の遷移 $P(C_{t+1}|C_t)$ を示している．図 7

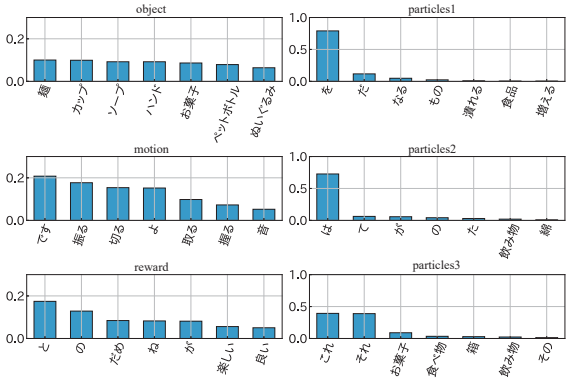
表 1: 各入力モダリティに対する行動結果.

入力モダリティ	平均累積報酬値	平均ステップ数
words	3.95	4.66
vision	3.95	4.86
vision,audio,tactile	3.63	7.39
tactile	2.74	15.31
audio	1.91	19.65
random	1.09	37.84

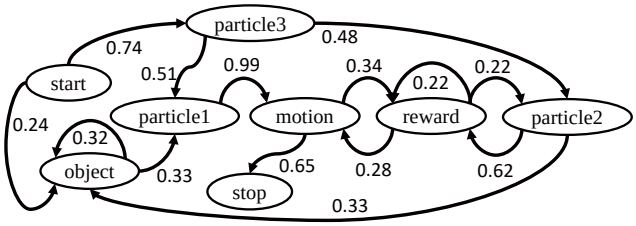


(a) カテゴリ分類精度　(b) 物体概念の混合行列

図 6: mMLDA による物体のカテゴリ分類の結果



(a) 各品詞ごとの単語の出力確率



(b) 文法構造

図 7: BHMM と mMLDA により獲得した言語モデル

を見ると文法として概ね正しいものが獲得できていることがわかる．物体・動作・報酬概念に関する出力確率を見ると，概ね各概念に対応する単語の出力確率が高くなっている．例えば，物体概念では，上位 7 個はすべて，物体に関する単語である．動作については,「握る・切る・取る・振る」という，動詞が上位 7 個に入っている．報酬については,「だめ，楽しい，良い」という報酬に関する単語が上位 7 個に入っている．助詞について見ると，助詞 1 は格助詞の「を」，助詞 2 は「は」，助詞 3 は指示語の「これ・それ」の出力確率が高い．しかし，助動詞「です」や終助詞「よ」は，motion(動詞) に混同されている．このため，品詞の遷移として，motion が stop の前に来ている．これは，品詞数を増やすことで解決可能と考える．

4.5　プランニングの学習結果

プランニングの結果について示す．迷路環境で起こりうるすべてのシーン，536 シーンを初期状態として，そこから予測される累積報酬が最大となるようにプランニングし行動した．全エピソード学習後のパラメータを用いてプランニングした．10 ステップ以内にゴールにたどり着けば，プランニングを成功とした．その結果，成功率は 48% となった．

5.　まとめ

本稿では，行動と知識獲得のループを実現するための統一的な枠組みを mMLDA を中心に組み立て，抽象化した知識を用いた，行動決定，言語理解，行動計画に関する能力を検証し，これらが同時に学習可能なことを示した．しかし各モジュールの相互作用が学習に与える影響は明らかではない．今後はより詳細に検証するとともに，実ロボットに統合モデルを実装し学習することを考えている．

謝辞

本研究は，JST CREST（JPMJCR15E3）の支援を受けて実施したものである．ここに感謝の意を表する．

参考文献

[1] T. Taniguchi, *et al.*, “Symbol Emergence in Robotics: A Survey,” *Advanced Robotics*, Vol.30, 11-12, pp.706-728, 2016.

[2] T. Nakamura, *et al.*, “Grounding of Word Meanings in Multimodal Concepts Using LDA,” *IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 3943-3948, 2009.

[3] M. Attamimi, *et al.*, “Learning Word Meanings and Grammar for Verbalization of Daily Life Activities Using Multilayered Multimodal Latent Dirichlet Allocation and Bayesian Hidden Markov Models,” *Advanced Robotics* 30(11-12), pp.806–824, 2016.

[4] K. Miyazawa, *et al.*, “Integration of Multimodal Categorization and Reinforcement Learning for Robot Decision-Making,” *IROS2017: Workshop on ML-HLCR*, 2017.

[5] S. Levine, *et al.*, “End-to-End Training of Deep Visuomotor Policies,” *Journal of Machine Learning Research*, Vol.17, pp.1-40, 2016.

[6] S. Gu, *et al.*, “Deep Reinforcement Learning for Robotic Manipulation,” arXiv 1610.00633, 2016.

[7] R. Arandjelovi, A. Zisserman, “Look, Listen and Learn,” arXiv 1705.08168, 2017.

[8] F. Hill, *et al.*, “Understanding Grounded Language Learning Agents,” arXiv 1710.09867, 2017.

[9] M. Fadlil, *et al.*, “Integrated Concept of Objects and Human Motions Based on Multi-layered Multimodal LDA,” in proc. of IROS 2013, pp. 2256–2263, 2013.

[10] R. Williams, “Simple statistical gradient-following algorithms for connectionist reinforcement learning,” *Machine Learning*, Vol. 8, Issue 3, pp. 229-256, 1992.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

時系列マルチモーダル情報の分節・分類に基づく物体と動作の統合概念学習

Learning Integration Concept of Objects and Motions Based on Segmentation and Classification of Time Series Multimodal Information

布川 遼太郎 Ryotaro Nunokawa　宮澤 和貴 Kazuki Miyazawa　中村 友昭 Tomoaki Nakamura　長井 隆行 Takayuki Nagai　金子 正秀 Masahide Kaneko

電気通信大学
The University of Electro-Communications

Humans acquire various kinds of information with minimal cognitive load by using concepts and this capability makes it possible to deal with unknown events. Therefore, we consider that concepts also make it possible for robots to predict unobserved information from observable one. We define concepts as categories formed by clustering the perceptual information. In this paper, we propose a method for estimating a temporal segments of multimodal information based on co-occurrence relationship among modalities and classifying them into categories in an unsupervised manner. In the experiment, in which object images and robot's motions obtained by robot's manipulating objects were used, concepts that represents the co-occurrence relationship between objects and behaviors were formed.

1. 前書き

概念は人間の認知において重要な役割を担っている．人は概念を用いることで，知覚情報から最小限の認知的処理で様々な情報を獲得し [Rosch 99]，未知の事象にも対応している．Medin は概念の持つ 7 つの機能として，分類，理解と説明，予測，推理，コミュニケーション，概念の組み合わせ，事例の検索と生成を挙げている [Medin 85]．特に分類の機能は他の機能の基礎となるものとされており，認知心理学において研究されてきた．例えば認知科学の分野では，人は物体を見るとその物体の触感や動作などの関連情報を想像する“embodied simulation”という考え方があり [Barsalou 99]，この考え方を支援する多くの知見が存在している [Bergen 12]．これは人が“embodied simulation”を行うことで可観測情報から自身の経験に基づいて形成された概念を用いて未観測情報を予測していると言える．このことからロボットも概念を用いることによって，一部の可観測情報から未観測情報を予測することが可能となり，様々な事物に対して柔軟に対応することが可能となると考えられる．

そこで我々は，文献 [Miyazawa 16]，[Attamimi 14] においてロボットが物体に対して何らかの操作を行うことで，物体と動作の概念を統合した上位概念を獲得する手法を提案している．文献 [Miyazawa 16] で提案されたモデルでは各下位概念の関係性を表現する上位概念を学習することで，特定の物体に対する実行可能な操作を予測可能にしている．このモデルでは，下位概念の共起性に基づいて上位概念が形成される．しかし，実際にロボットが取得するセンサ情報は時系列情報であり，これらをクラスタリングした複数の下位概念の発生には時間的ズレが生じ，必ずしも共起するわけではない．そのため，ロボットは下位概念のどこからどこまでを共起としてとらえるかを推定する必要がある．本稿では概念を，知覚した情報をクラスタリングすることで形成されるカテゴリと定義し，ロボットが環境とのインタラクションを通じて取得可能な複数の時系列センサ情報を用いて概念形成を行う．そのために，隠れセミマルコフモデルを用いてセンサ情報を分節・分類することで，1 つの概念によって表現されるセンサ情報の時間的な範囲と，そのカテゴリを教師なしで推定する手法を提案する．

マルチモーダル情報を用いた概念獲得に関する研究として文献 [Mangin 15] がある．Mangin らは，概念を高次元のマルチモーダル情報を低次元で表現したパラメータであると定義している．そして，マルチモーダル情報は複数の知覚情報が相互に関係を持っているという考えに基づいて，複数の知覚情報を関連付けたマルチモーダル概念を獲得する手法を提案している．この手法では獲得したマルチモーダル概念を用いることで，可観測情報から未観測情報を予測することを可能にしている．しかし，この研究では文献 [Miyazawa 16] と同様に共起性に基づいて概念が形成されており，マルチモーダル情報の発生の時間的なズレは考慮されていない．

連絡先: 布川遼太郎，電気通信大学知能機械工学科，東京都調布市調布ヶ丘 1-5-1，n1412098@edu.cc.uec.ac.jp

2. 提案手法

2.1 統合概念モデル

図 1 は提案手法のグラフィカルモデルであり，下位概念モデルにおいて観測情報 o_1 と o_2 の分節・分類によって下位概念を形成し，上位概念モデルで上位概念 z_i が下位概念 z_1^* と z_2^* の共起関係を表している．z_i では，下位概念の共起関係と，上位概念で表される下位概念の時間的な範囲を同時に推定する．例えば，観測情報 o_1，o_2 として物体画像とロボットアームの関節角度が観測されたとする．下位概念モデルにおいて o_1 と o_2 を分節化・分類することで物体概念・動作概念といった下位概念のカテゴリ系列を形成する．これらの下位概念のカテゴリ系列を上位概念モデルに送信し，1 つの上位概念で表現される下位概念の時間的な範囲を推定することで各物体と動作の対応関係を表現するような上位概念が形成される．すなわち，提案モデルを用いて学習を行うことでどの物体に対してどのような動作が実行可能であるかを表す上位概念を獲得することが可能となる．

2.2 時系列センサ情報の分節・分類

分節化に関する研究の一つに，ある文字列が与えられた時，これを意味の持つ単語に分割する形態素解析という手法がある．本稿では時系列センサ情報の分節・分類を，形態素解析における文字列をロボットが取得した時系列センサ情報に置き換えた問題と考える．この問題は，系列 $\boldsymbol{s}$ が与えられたとして，これを分割することで求められる単位系列 $\boldsymbol{x} = x_1, x_2$

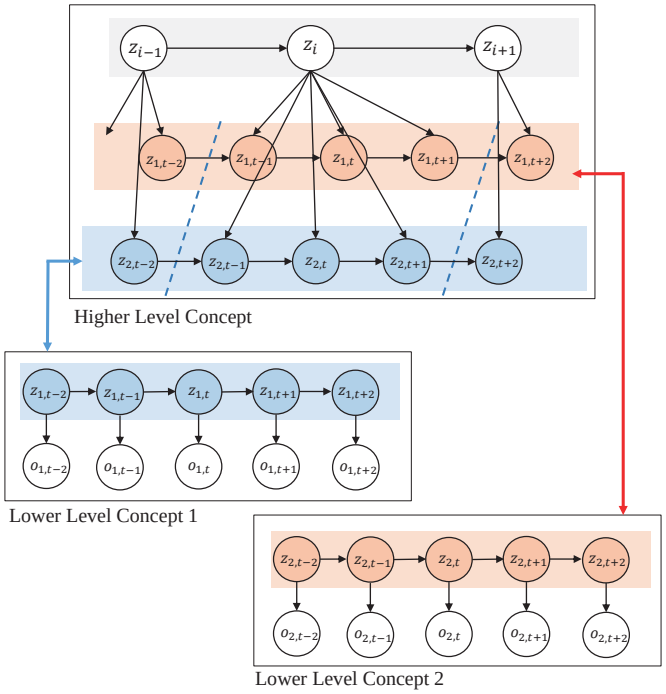


図 1: 時系列情報の分節・分類に基づく統合概念モデル

, $\cdots, x_N$ が生成される確率 $P(\boldsymbol{x}|\boldsymbol{s})$ を最大化する $\overline{\boldsymbol{x}}$ を求める問題に定式化される．

$$\overline{\boldsymbol{x}} = \mathrm{argmax} P(\boldsymbol{x}|\boldsymbol{s}) \tag{1}$$

ここで，$P(\boldsymbol{x}|\boldsymbol{s})$ を最大化することはできるだけ少ない単位系列数であり，かつ各単位系列の発生確率が高くなるような分節位置を推定することと考えられる．このような，時系列センサ情報の分節位置の推定は隠れセミマルコフモデル (HSMM) によって定式化することができる．パラメータ推定には 1 つの観測系列内の単位系列とそのクラスをまとめてサンプリングする Blocked Gibbs Sampler を用いる．また，Blocked Gibbs Sampler の計算を行う際には計算の効率化のために Forward filtering-backward sampling を用いる．

2.3 上位概念のカテゴリ系列の推定

上位概念のカテゴリ系列 $\boldsymbol{z}$ は次式で推定することができる．

$$\boldsymbol{z} \sim \iint P(\boldsymbol{z}|\boldsymbol{z_1}, \boldsymbol{z_2}) P(\boldsymbol{z_1}|\boldsymbol{o_1}) P(\boldsymbol{z_2}|\boldsymbol{o_2}) d\boldsymbol{z_1} d\boldsymbol{z_2} \tag{2}$$

ここで，$\boldsymbol{z}, \boldsymbol{z_1}, \boldsymbol{z_2}, \boldsymbol{o_1}, \boldsymbol{o_2}$ はそれぞれ $z_i, z_{1,t}, z_{2,t}, o_{1,t}, o_{2,t}$ のベクトルである．しかし，$\boldsymbol{z_1}, \boldsymbol{z_2}$ の積分は下位概念モデルから独立した上位概念モデルのみでは直接計算することが困難であるため，近似することで計算する．まず下位概念モデルで，下位カテゴリ系列 $\boldsymbol{z_1^*}, \boldsymbol{z_2^*}$ を推定する．

$$\boldsymbol{z_1^*} \sim P(\boldsymbol{z_1}|\boldsymbol{o_1}) \tag{3}$$

$$\boldsymbol{z_2^*} \sim P(\boldsymbol{z_2}|\boldsymbol{o_2}) \tag{4}$$

これにより上位概念モデルでは，推定された $\boldsymbol{z_1^*}$ と $\boldsymbol{z_2^*}$ を用いて式 (5) を Forward filtering-backward sampling によって計算することができる．

$$\boldsymbol{z^*} \sim P(\boldsymbol{z}|\boldsymbol{z_1^*}, \boldsymbol{z_2^*}) \tag{5}$$

Algorithm 1 上位カテゴリ系列の推定

```
下位カテゴリ系列の推定

// Forward filtering
for t = 1 to T do
  for k = 1 to K do
    for z = 1 to Z do
      α[t][k][z] を計算
    end for
  end for
end for

// Backward sampling
t = T, j = 1
while t > 0 do
  k, z ∼ p(x_j | s_{t−k:t}) α[t][k][z]
  x_j = s_{t−k:t}
  z_j = z
  t = t − k
  j = j + 1
end while
return (x_{J_n}, x_{J_n−1}, ··· , x_1), (z_{J_n}, z_{J_n−1}, ··· , z_1)
```

Forward filtering では，動的計画法を用いて，時刻 t を終点とする分節長 k の単位系列 $\boldsymbol{z}_{*,t-k:t}$ が，クラス z になる確率 $\alpha[t][k][z]$ をあらゆる可能性について計算する．

$$\alpha[t][k][z] = P(\boldsymbol{z}_{1,t-k:t}|z) P(\boldsymbol{z}_{2,t-k:t}|z) \sum_{k',z'} \alpha[t-k][k'][z'] \tag{6}$$

式 (6) における $P(\boldsymbol{z}_{1,t-k:t}|z)$ と $P(\boldsymbol{z}_{2,t-k:t}|z)$ はクラス z から分節長 k の単位系列が出力される確率を表しており，次式のように表される．

$$P(\boldsymbol{z}_{m,t-k:t}|z) = \prod_{t'=t-k}^{t} \frac{N_{z,z_{m,t'}} + \alpha}{N_z + Z\alpha} \tag{7}$$

ただし，$N_{z,z_{m,t'}}$ は下位概念モデル m において下位カテゴリが $z_{m,t'}$ となったもののうち上位概念 z に分類された個数を，N_z は上位カテゴリ z に分類された下位カテゴリの総数を表している．α 及び Z はそれぞれディリクレ事前分布のパラメータ，カテゴリ数を表す．Backward sampling では，計算された $\alpha[t][k][z]$ からサンプリングすることで系列の分節位置を決定する．以上のアルゴリズムを，Algorithm 1 に示す．K は最大の分節長である．

3. ロボットによる概念学習実験

3.1 実験設定

前章で説明したモデルを用いて，実際にロボットが物体を操作し得られる時系列マルチモーダル情報を分節・分類することで概念の学習を行った．下位概念としては物体概念と動作概念を用いた．図 2 のようにロボットはマルチモーダル情報を取得する．操作毎にロボットの頭部に取り付けた Kinect によって操作対象の物体の画像を取得し，LDA[Blei 03] を用いて分類することで得られる物体 ID を物体概念とした．また，物体操作時のロボットアームおよびハンドの関節角度を GP-HSMM[Nakamura 17] によって分節することで得られる動作プリミティブを動作概念とした．すなわち，ロボットはどの物体に対してどのような動作を実行可能か表す上位概念を学習することになる．実験には図 3 に示した物体を用い，表 1 に示す動作を各物体に対して行った．実際のロボットによるマルチモーダル情報の取得は以下の流れで行った．

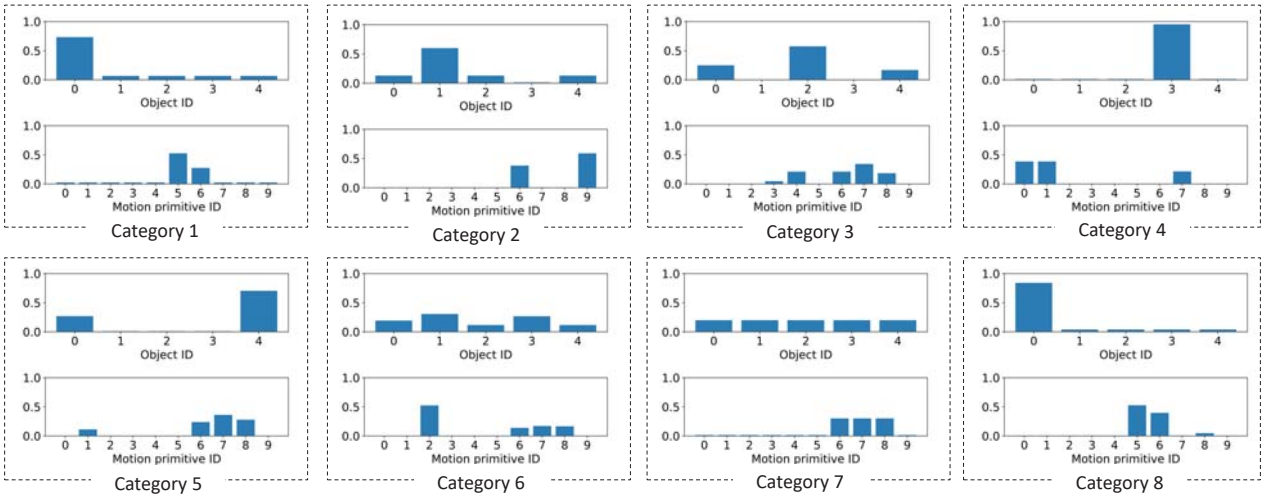


図 5: 各カテゴリにおける物体と動作プリミティブ系列の発生確率

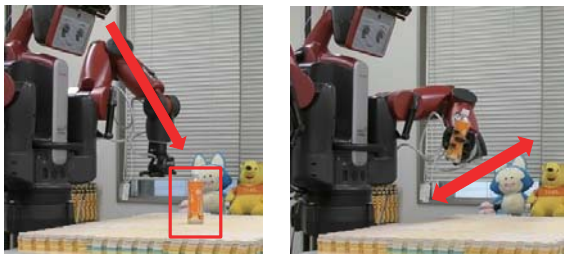


図 2: ロボットによるマルチモーダル情報の取得

表 1: 物体と動作の対応

物体 (ID)	動作内容	動作プリミティブ系列
ぬいぐるみ (0)	握る・なでる	7,8,7,8,6・5,5,6
ボタン (1)	押す	9,9,6
おもちゃ(2)	左に置く	7,3,6
ペットボトル (3)	振る	7,1,0,1,0,7,8,6
スポンジ (4)	持ち上げる	7,1,7,8,6
おもちゃ・スポンジ	擦る	7,4,7,4,8,6
全物体	観察する	7,2,2,2,8,6

1. ロボットアームを人が操作し，各物体に対して行う操作の関節角情報を取得する．
2. GPHSMM を用いて関節角情報から動作プリミティブを生成する．
3. 以下の操作を各物体に対して繰り返し行う
   - **(a)** ロボットが机上の物体の画像情報を取得する．
   - **(b)** 物体に対応する動作を動作プリミティブを組み合わせて生成し，ロボットに行わせる．
   - **(c)** 取得した画像情報と動作情報を保存する．
   - **(d)** 人が新たに物体を机に置き (a) に戻る

図 4 が取得した画像と関節角の 2 つの連続的な情報を分節・分類することで得られる物体 ID と動作プリミティブの時系列



図 3: 実験に用いた物体

データの一部である．図 4 において横軸はタイムステップを，縦軸は物体 ID 及び動作プリミティブの ID を表しており，縦軸の値が −1 である状態は物体については物体情報を観測していない状態を，動作に関してはロボットが動作を行っていない状態であることを表している．破線で囲まれた範囲が一つの上位概念によって表現される範囲を表しており，これを教師なしで推定する．

3.2 結果

図 5 が実際に分節・分類することで得られた，各カテゴリにおける物体 ID と動作プリミティブ系列の発生確率である．Category 1 において，物体 0 に対して正解である動作プリミティブ 5・6 によって構成される動作が行われることが学習されている．同様に Category 2・3・5・6 においても，各物体に対応する実行可能な動作が正しく学習されていることがわかる．

一方で Category 1 と Category 8 の両方で，物体 0 に対してプリミティブ 5・6 で構成される動作が実行可能であることが学習されており，正解であるプリミティブ 6・7・8 で構成さ

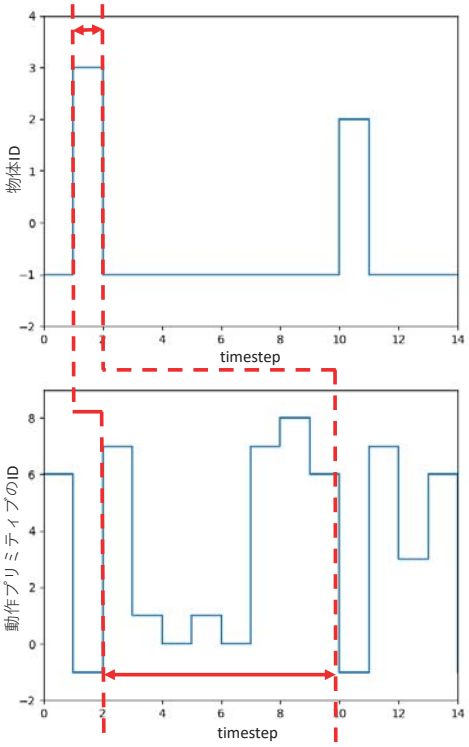


図 4: 取得された物体 ID(上) と動作プリミティブ (下)

れる動作が実行可能であることを表現する結果は得られなかった．これは，物体 0 に対して実行可能なプリミティブ 6・7・8 で構成される動作（7,8,7,8,6）と，物体 4 に対して実行可能なプリミティブ 1・6・7・8 によって構成される動作 (7,1,7,8,6) が非常に似ているため，学習が正しくできなかったことが原因であると推察される．その結果，Category 5 に，プリミティブ 1・6・7・8 によって構成される動作が実行可能な物体として，正解である物体 4 に加えて正解でない物体 0 が学習結果として表れている．

Category 4 では物体 3 に対して，想定した動作プリミティブ 0・1・6・7・8 で構成される動作が実行可能であることをある程度学習できているものの，動作プリミティブ 6・8 の発生頻度が非常に低くなってしまっていた．これは想定した動作において動作プリミティブ 6・8 の発生回数が 0・1・7 に比べ少なく，また，8 種類の操作のうち 5 種類の操作にプリミティブ 6・7・8 が含まれているため，プリミティブ 0・1・6・7・8 で構成される動作がプリミティブ 6・7・8 で構成される動作と同じカテゴリに一部含まれてしまったことが原因であると考えられる．

物体 2 に対して実行可能なプリミティブ 3・6・7 で構成される動作が実行可能であることが学習されていない．そこで，Category 3 を見ると動作プリミティブ 3 が発生していることがわかる．このことから，プリミティブ 3・6・7 で構成される動作がプリミティブ 4・6・7・8 で構成される動作と同じカテゴリに含まれてしまい，学習が正しく行えなかったと考えられる．

実験結果より 8 つのカテゴリ中，5 つのカテゴリについて学習を正しく行うことができることが確認された．また，正しく学習が行えなかった 3 つのカテゴリのうち 2 つのカテゴリではある程度学習が正しく行えており，提案手法を用いることでロボットが時系列マルチモーダル情報から概念を学習可能であるとわかった．

4. 結び

本稿では，ロボットが物体を操作し得られる時系列マルチモーダル情報を分節・分類することによって概念を学習する手法を提案した．実際にロボットを用いた実験を行い，提案手法によって上位概念の学習が可能であることを示した．今後の課題として，今回の実験結果で見られたような，似ている動作が行われた場合に学習が正しく行えない点を改善することや，上位概念モデルと下位概念モデルが相互に影響しあい，各モデルのパラメータ推定を行うモデルの実装などが挙げられる．

参考文献

[Rosch 99] Rosch, B.: Principles of Categorization, Concepts: core readings, pp.189-206 (1999)

[Medin 85] Eysenck, M. W., Ellis, A., Hunt, E. and Johnson-Laird, P. N.: The Blackwell dictionary of cognitive psychology, Blackwell Pub (1985)

[Barsalou 99] Barsalou, L. W.:Perceptual symbol system, Behavioral and Brain Sciences, vol. 22, pp.277-660 (1999)

[Bergen 12] Bergen, B. K.: Louder Than Words, The New Science of How the Mind Makes Meaning. Basic Books (2012)

[Mangin 15] Mangin, O., Filliat, D., Bosch, L. T., Oudeyer, P. Y.: MCA-NMF: Multimodal Concept Acquisition with Non-Negative Matrix Factorization, PLoS ONE 10(10): e0140732. doi:10.1371/journal. pone.0140732 (2015)

[Miyazawa 16] 宮澤 和貴, 青木 達哉, 日永田 智絵, Mata, D., 岩田 健輔, 中村 友昭, 長井 隆行：多層マルチモーダル LDA を用いた概念形成と強化学習，計測自動制御学会システム・情報部門 学術講演会, O1-2 (2016)

[Attamimi 14] Attamimi, M., Fadlil, M., Abe, K., Nakamura, T., Funakoshi, K., and Nagai, T.: Integration of various concepts and grounding of word meanings multi-layered multimodal LDA for sentence generation, in IEEE/RSJ International Conference on Intelligent Robots and Systems, pp.2194-2201 (2014)

[Blei 03] Blei, D. M., Ng, A. Y., and Jordan, M. I.: Latent Dirichlet Allocation, Journal of Machine Learning Research, Vol. 3, pp.993-1022 (2003)

[Nakamura 17] Nakamura, T., Takayuki, N., Daichi, M., Ichiro K., Hideki, A., Masahide, K.: Segmenting Continuous Motions with Hidden Semi-markov Models and Gaussian Processes, Front. Neurorobot, doi: 10.3389/fnbot.2017.00067 (2017)

Oral presentation | NFC Session | [NFC Session] NFC-2 UEPD (Development of fundamental technology for understanding emotions of people with dementia and its applications to communication support)

[1G1-NFC-2a] [NFC Session] NFC-2 UEPD (Development of fundamental technology for understanding emotions of people with dementia and its applications to communication support)

座長:竹林 洋一（静岡大学）

Tue. Jun 5, 2018 1:20 PM - 3:00 PM Room G (5F Ruby Hall Hiten)

[1G1-NFC-2a-a] Aim of the session

Yoichi TAKEBAYASHI[1] （1: Shizuoka University / The Society of Citizen Informatics for Human Cognitive Disorder）

1:20 PM - 1:40 PM

[1G1-NFC-2a-b] (Panel discussion) The results of "Development of fundamental technology for understanding emotions of people with dementia and its applications to communication support"

Shogo Ishikawa[1], Hideki Ueno[2], Shinya Kiriyama[1] （1: Shizuoka University, 2: Chiba University Hospital / The Society of Citizen Informatics for Human Cognitive Disorder）

1:40 PM - 3:00 PM

©The Japanese Society for Artificial Intelligence

1:20 PM - 1:40 PM (Tue. Jun 5, 2018 1:20 PM - 3:00 PM Room G)

[1G1-NFC-2a-a] Aim of the session

Yoichi TAKEBAYASHI[1] (1: Shizuoka University / The Society of Citizen Informatics for Human Cognitive Disorder)

1:40 PM - 3:00 PM (Tue. Jun 5, 2018 1:20 PM - 3:00 PM Room G)

[1G1-NFC-2a-b] (Panel discussion) The results of "Development of fundamental technology for understanding emotions of people with dementia and its applications to communication support"

Shogo Ishikawa[1], Hideki Ueno[2], Shinya Kiriyama[1] (1: Shizuoka University, 2: Chiba University Hospital / The Society of Citizen Informatics for Human Cognitive Disorder)

©The Japanese Society for Artificial Intelligence

Oral presentation | NFC Session | [NFC Session] NFC-2 UEPD (Development of fundamental technology for understanding emotions of people with dementia and its applications to communication support)

[1G2-NFC-2b] [NFC Session] NFC-2 UEPD (Development of fundamental technology for understanding emotions of people with dementia and its applications to communication support)

座長:竹林 洋一（静岡大学）

Tue. Jun 5, 2018 3:20 PM - 5:00 PM Room G (5F Ruby Hall Hiten)

[1G2-NFC-2b-a] (Panel discussion) Toward Development of Citizen Informatics for Human Cognitive Disorder

Koiti HASIDA[1], Ko ISHIYAMA[2], Seiji BITO[3] （1: Tokyo University, 2: ExaWizards Inc., 3: Tokyo Medical Center）

3:20 PM - 3:40 PM

[1G2-NFC-2b-b] Conclusion

Yoichi TAKEBAYASHI[1] （1: Shizuoka University / The Society of Citizen Informatics for Human Cognitive Disorder）

3:40 PM - 5:00 PM

©The Japanese Society for Artificial Intelligence

3:20 PM - 3:40 PM (Tue. Jun 5, 2018 3:20 PM - 5:00 PM Room G)

[1G2-NFC-2b-a] (Panel discussion) Toward Development of Citizen Informatics for Human Cognitive Disorder

Koiti HASIDA[1], Ko ISHIYAMA[2], Seiji BITO[3] (1: Tokyo University, 2: ExaWizards Inc., 3: Tokyo Medical Center)

3:40 PM - 5:00 PM (Tue. Jun 5, 2018 3:20 PM - 5:00 PM Room G)

[1G2-NFC-2b-b] Conclusion

Yoichi TAKEBAYASHI[1] (1: Shizuoka University / The Society of Citizen Informatics for Human Cognitive Disorder)

©The Japanese Society for Artificial Intelligence

Oral presentation | Organized Session | [Organized Session] OS-13

[1H1-OS-13a] [Organized Session] OS-13

Tue. Jun 5, 2018 1:20 PM - 3:00 PM Room H (10F Sky Hall)

[1H1-OS-13a-01] Annotating Expression of Roles and Exercise of Special Abilities to the Werewolf BBS

○Michimasa Inaba[1], Yoshinobu Kano[2], Hirotaka Osawa[3], Takeshi Otsuki[4], Daisuke Katagami[5], Fujio Toriumi[6] (1. Hiroshima City University, 2. Shizuoka University, 3. University of Tsukuba, 4. Yamagata University, 5. Tokyo Polytechnic University, 6. The University of Tokyo)

1:20 PM - 1:40 PM

[1H1-OS-13a-02] Performance Evaluation of AI Wolf Using Neural Network

○Hiroaki Doguro[1], Hitoshi Matsubara[1] (1. Future University Hakodate)

1:40 PM - 2:00 PM

[1H1-OS-13a-03] Improvement of Role Estimation using Machine Learning in werewolf AI

○Yuta Kimura[1], Takeshi Ito[1] (1. University of Electric Communication)

2:00 PM - 2:20 PM

[1H1-OS-13a-04] Development of Werewolf-game Agent Using Differentiable Neural Computer

○Ryo Iehara[1], Atsushi Hirota[1], Kazuaki Tanaka[1], Masahiro Araki[1], Natsuki Oka[1] (1. Kyoto Institute of Technology)

2:20 PM - 2:40 PM

[1H1-OS-13a-05] Analysis of Agents' Information Sharing with Evolutionary Computation

○Bohao Wang[1], Hirotaka Osawa[1], Ken Satoh[2] (1. University of Tsukuba, 2. National Institute of Informatics)

2:40 PM - 3:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

人狼BBSに対する役職表明・能力行使報告情報のアノテーション

Annotating Expression of Roles and Exercise of Special Abilities to the Werewolf BBS

稲葉 通将 *1 Michimasa INABA
狩野 芳伸 *2 Yoshinobu KANO
大澤 博隆 *3 Hirotaka OSAWA
大槻 恭士 *4 Takashi OTSUKI
片上 大輔 *5 Daisuke KATAGAMI
鳥海 不二夫 *6 Fujio TORIUMI

*1 広島市立大学 Hiroshima City University
*2 静岡大学 Shizuoka University
*3 筑波大学 University of Tsukuba
*4 山形大学 Yamagata University
*5 東京工芸大学 Tokyo Polytechnic University
*6 東京大学 The University of Tokyo

In this study, we constructed the Werewolf BBS annotation corpus. We annotated the utterances concerning "expression of own role" and "report of the result of special abilities". This corpus can be used as a language resource for utterance semantic analysis and utterance generation in the werewolf game, and is useful for strategy analysis of human players. Annotator were recruited via crowdsourcing. The Corpus is published on GitHub.

1. はじめに

プレイヤー同士の議論によりゲームを進行する人狼ゲームに関する研究が近年活発に行われている [大川 17, 風間 16, 西野 15]．人狼ゲーム研究の目的の一つとして，人間と対戦可能なエージェントの実現が挙げられる [片上 15]．しかし現状，エージェント構築を目指した研究は人狼知能プロトコル [大澤 14] と呼ばれるコマンドにより会話を行うものがほとんどである [Hirata 16, 今野 17, 大川 17]．自然言語を用いたエージェントの研究も行われているものの [箕輪 17]，その数は非常に少ない．その原因として，自然言語により対戦可能なエージェントの実現には，発話意味理解，発話生成など多くの課題が存在するが，その学習のためのコーパスなどは整備されておらず，統計的な手法を適用することは困難であることが挙げられる．

そこで本研究では，人間同士による人狼ゲームのログに対しアノテーションを行い，コーパスの構築を行った．本コーパスは人狼 BBS[*1] で行われたゲーム中におけるプレイヤーの発話のうち，ゲームの戦略上特に重要である「自分の役職の表明 (役職 CO)」，および「特殊能力を行使した結果の報告」に関する発話に対してアノテーションを行ったものである．本コーパスは，先に述べた人狼ゲームにおける発話意味理解，発話生成のための学習データとすることができるほか，人間のプレイヤーの戦略分析などへの応用が考えられる．

2. 人狼 BBS

人狼 BBS はオンライン上で誰もが参加可能な Web ゲームとして公開されており，現在までに延べ 7000 回以上のゲームが行われてきた．また，そのゲームログは全て公開されている．人狼 BBS ではこれまでに数回ルールと役職構成の変更が行われているが，本研究では現時点での最新版である人狼 BBS:G で行われたゲームを対象とした．

人狼 BBS のゲーム画面を表 1 に示した．図に示したように人狼 BBS では，プレイヤーは「負傷兵 シモン」「神父 ジムゾン」といったあらかじめ用意されたキャラクターに自動的に割り振られ，ゲームに参加する．このキャラクター名のほか，参加者が自由に設定できるユーザ ID も存在するが，ユーザ ID はゲーム終了時まで非公開である．そのため，本研究で構築したコーパスでもキャラクター名をプレイヤー名として使用する．

人狼 BBS の発言には全員が閲覧できる「通常発言」のほか，ゲームから除外されたプレイヤーだけが閲覧できる「うめき」，人狼のみが閲覧できる「ささやき」，自分だけが閲覧できる「独り言」の 4 種類があるが，アノテーション対象とするのは通常発言のみである．さらに，ゲーム開始前と終了後に行われる参加者の交流を目的とした「プロローグ」・「エピローグ」のログも公開されているが，これもアノテーション対象からは除外する．

また，アノテーション対象としたゲームログは，人狼 BBS でプレイされたゲームのうち，突然死が発生していないゲームとした．突然死は人狼 BBS 特有のルールであり，1 日に一度も発言しなかったプレイヤーがゲームから除外されるというものである．人狼ゲームのルールには多くのバリエーションが存在するが，突然死が採用されることは人狼 BBS(およびそのクローンゲーム) 以外にはあまりみられない．また，勝敗に与える影響も非常に大きいことから，突然死が発生したゲームはアノテーションの対象外とした．

3. アノテーション

アノテーション対象とした発話は「自分の役職の表明 (役職 CO)」および「特殊能力を行使した結果の報告」に関連する以下の 6 種類の意味内容 (対話行為) のいずれかを含む発話とした．

CO
: 自分がどの役職であるか表明した発言．ただし，表明した役職が村人の場合，および「私は占い師ではありませ

連絡先: 広島市立大学
〒 731-3194 広島市安佐南区大塚東 3-4-1
E-mail: inaba@hiroshima-cu.ac.jp

*1 http://www.wolfg.x0.com/



図 1: 人狼 BBS

ん」のような特定の役職であることを否定する発言は対象外とした．アノテーションの際には，表明した役職名も付与する．

CO 撤回
: 一旦村人以外の役職 CO を行ったプレイヤーが，後になってその CO を撤回することを表明した発言．ただし，例えば占い師 CO した後，その占い師 CO については何も言わずに霊能者 CO した場合など，撤回を明言していない場合は対象外とした．アノテーションの際には，撤回した役職名も付与する．

占い結果
: （真の，あるいは偽の）占い師が過去に誰を占い対象として選び，その結果が何であったかという発言．占い対象者，および占い結果もアノテーションする．

占い結果撤回
: （真の，あるいは偽の）占い師が過去に報告した占い結果を撤回した発言．撤回した占い対象者，および占い結果もアノテーションする．

霊能結果
: （真の，あるいは偽の）霊能者が得た，誰の霊能結果が何であったかという発言．霊能対象者，および霊能結果もアノテーションする．

霊能結果撤回
: （真の，あるいは偽の）霊能者が過去に報告した霊能結果を撤回した発言．撤回した霊能対象者，および霊能結果もアノテーションする．

護衛先
: （真の，あるいは偽の）狩人が過去に誰を護衛したかという発言．護衛対象者もアノテーションする．

護衛先撤回
: （真の，あるいは偽の）狩人が過去に報告した護衛先を撤回した発言．撤回した護衛対象者もアノテーションする．

各アノテーションには上で述べたものに加え，人狼 BBS における発言日，発言 ID，発言者名を各項目共通で付与した．

表 1: コーパスに含まれる対話行為の統計情報

対話行為	出現頻度
CO	1688
CO 撤回	191
占い結果	2310
占い結果撤回	8
霊能結果	1067
霊能結果撤回	3
護衛先	308
護衛先撤回	3

4. コーパス構築

本コーパスの構築にあたり，作業者を CrowdWorks[*2] で募集した．作業者は人狼ゲーム経験者であることを条件とした．

本研究におけるアノテーションでは，1 ゲームにつき 1000～1500 個程度の発話の中から，アノテーション対象となる発話を探す必要がある．そのため，アノテーションのミス・見逃しが発生しやすい．そこで，コーパス構築の際には，1 名がゲームログに対してアノテーションを行い，別の 1 名がそのアノテーションのチェックを行うことで，正確なアノテーションを目指した．

コーパス構築の手順は以下のとおりである．まず最初に 1 ゲームにつき 1 名がアノテーションを行い，アノテーションデータを収集する．次に，アノテーションのチェックのため，10 ゲームのアノテーションデータを 1 セットとし，各セット内の 1 ゲームに対し，誤りを含むように著者がアノテーション結果を改変した．チェックを行う作業者には 1 ゲームに対し結果を改変したことを伝えた上で，10 ゲームに含まれるアノテーション結果の誤りを全て報告するよう指示した．作業者には，著者が改変したものを含む誤りを報告してきた場合のみ報酬を支払うこととし，アノテーションの正確性を確保した．最後に，チェックが完了したデータをプログラムで扱いやすい JSON 形式に変換した．

現在までに 300 ゲームのアノテーションおよびチェックが完了しており，完成した人狼 BBS アノテーションコーパスは GitHub で公開中である [*3]．また，本コーパスに含まれる対話行為の統計情報を表 2 に示す．なお，コーパスには人狼 BBS のログデータそのものは収録されていない．

5. まとめ

本研究では，人狼 BBS のデータに対してアノテーションを行い，人狼 BBS アノテーションコーパスを構築した．アノテーションはゲームの戦略上特に重要である「自分の役職の表明」，および「特殊能力を行使した結果の報告」に関する発話に対して行った．

今後は，さらに人狼 BBS アノテーションコーパスの拡張を進める予定である．また，本コーパスの構築にあたっては，アノテーションのチェック作業を行ったが，アノテーションの誤りや抜けはまだ残っていると思われる．そういったアノテーションミスは発見され次第，適宜修正していく．その他，本コーパスでは発話単位でアノテーションを実施したが，発話内のどの箇所かまではアノテーションされていない．人狼 BBS では 1 回の発話として長文が投稿されることも多いことから，

*2 https://crowdworks.jp/
*3 https://github.com/aiwolf/wolfbbs_annotations

今回行ったアノテーションが発話中のどの箇所に相当するかという情報を追加する予定である．

謝辞

本研究を行うにあたり，人狼 BBS のデータ使用を許可していただいた ninjin 氏に感謝いたします．なお，本研究は JSPS 科研費 15K12180 の助成を受けたものです．

参考文献

[Hirata 16] Hirata, Y., Inaba, M., Takahashi, K., Torikumi, F., Osawa, H., Katagami, D., and Shinoda, K.: Werewolf game modeling using action probabilities based on play log analysis, in *International Conference on Computers and Games*, pp. 103–114 (2016)

[今野 17] 今野伸浩, 大槻恭士：機械学習による人狼知能の陣営推定能力向上, エンタテインメントコンピューティングシンポジウム 2017 論文集, pp. 64–69 (2017)

[西野 15] 西野順二：自然な人狼の勝率, 研究報告ゲーム情報学 (GI), Vol. 2015, No. 18, pp. 1–5 (2015)

[大川 17] 大川貴聖, 吉仲亮, 篠原歩：深層学習を用いて役職推定を行う人狼知能エージェントの開発, ゲームプログラミングワークショップ 2017 論文集, pp. 50–55 (2017)

[大澤 14] 大澤博隆, 鳥海不二夫, 片上大輔, 篠田孝祐, 稲葉通将：人狼ゲームのプロトコル設計: 推理と説得のプロコトル, インテリジェントシステム・シンポジウム講演論文集, Vol. 2014, No. 24, pp. 78–81 (2014)

[風間 16] 風間祥光, 棟方渚, 畑雅之, 松原仁：人狼ゲームにおけるプレイヤーの思考過程の分析, Technical Report 19, 公立はこだて未来大学, 北海道大学, 株式会社 HiSC, 公立はこだて未来大学 (2016)

[片上 15] 片上大輔, 鳥海不二夫, 大澤博隆, 稲葉通将, 篠田孝祐, 松原仁：人狼知能プロジェクト, 人工知能, Vol. 30, No. 1, pp. 65–73 (2015)

[箕輪 17] 箕輪峻, 滝波秋穂, 小川ちひろ, 三原直樹, 真木裕子, 柴淳, 狩野芳伸 他：プロトコルを用いた意味理解による人狼知能の自然言語エージェント, *SIG-SLUD*, Vol. 5, No. 02, pp. 58–61 (2017)

A　コーパス収録データ

人狼 BBS アノテーションコーパスでは 1 ゲームに対するアノテーションが 1 つの JSON ファイルに収録されている．JSON に含まれる各要素の説明を表 2 に示す．なお，role が配列となっているのは，同一人物が複数の役職を同時に表明する例 *4 が存在するためである．また，species と target が配列となっているのは，1 回の発言で 2 つ以上の結果を報告する場合があるためである．例えば「青年 ヨアヒムと旅人 ニコラスを占って，ヨアヒムは人間でニコラスは人狼だった」という発言があった場合，species には [”青年 ヨアヒム”, ”旅人 ニコラス”] が，target には [”人間”, ”人狼”] が格納される．

以下に，コーパスに含まれるデータの例として，G794 村 *5 のデータを示す．

*4　ギドラ CO と呼ばれる

*5　http://www.wolfg.x0.com/index.rb?vid=794

表 2: JSON のデータ形式

village_id	人狼 BBS におけるゲーム ID（村番号）
annotation	アノテーションが時系列順に入った配列
action	対話行為
comment	アノテータによるコメント
day	ゲーム内日付
id	人狼 BBS における発話 ID
speaker	発話を行ったプレイヤー名
role	表明した役職名が入った配列
species	占い，および霊能結果が入った配列
target	占い，霊能，護衛の対象となったプレイヤー名が入った配列


```
{
    "annotations": [
        {
            "action": "CO",
            "comment": "",
            "day": 1,
            "id": 113,
            "role": [
                "占い師"
            ],
            "speaker": "青年 ヨアヒム"
        },
        {
            "action": "CO",
            "comment": "",
            "day": 1,
            "id": 118,
            "role": [
                "占い師"
            ],
            "speaker": "旅人 ニコラス"
        },
        {
            "action": "CO",
            "comment": "",
            "day": 1,
            "id": 160,
            "role": [
                "霊能者"
            ],
            "speaker": "負傷兵 シモン"
        },
        {
            "action": "占い結果",
            "comment": "",
            "day": 2,
            "id": 304,
            "speaker": "青年 ヨアヒム",
            "species": [
                "人間"
            ],
            "target": [
                "パン屋 オットー"
```

```
        ]
    },
    {
        "action": "占い結果",
        "comment": "",
        "day": 2,
        "id": 305,
        "speaker": "旅人 ニコラス",
        "species": [
            "人間"
        ],
        "target": [
            "パン屋 オットー"
        ]
    },
    {
        "action": "占い結果",
        "comment": "",
        "day": 3,
        "id": 518,
        "speaker": "青年 ヨアヒム",
        "species": [
            "人間"
        ],
        "target": [
            "羊飼い カタリナ"
        ]
    },
    {
        "action": "占い結果",
        "comment": "",
        "day": 3,
        "id": 519,
        "speaker": "旅人 ニコラス",
        "species": [
            "人狼"
        ],
        "target": [
            "羊飼い カタリナ"
        ]
    },
    {
        "action": "占い結果",
        "comment": "",
        "day": 4,
        "id": 670,
        "speaker": "旅人 ニコラス",
        "species": [
            "人狼"
        ],
        "target": [
            "ならず者 ディーター"
        ]
    },
    {
        "action": "CO",
        "comment": "",
        "day": 4,
        "id": 692,
        "role": [
            "狩人"
        ],
        "speaker": "農夫 ヤコブ"
    },
    {
        "action": "護衛先",
        "comment": "",
        "day": 4,
        "id": 702,
        "speaker": "農夫 ヤコブ",
        "target": [
            "旅人 ニコラス",
            "パン屋 オットー"
        ]
    },
    {
        "action": "占い結果",
        "comment": "",
        "day": 5,
        "id": 796,
        "speaker": "旅人 ニコラス",
        "species": [
            "人間"
        ],
        "target": [
            "行商人 アルビン"
        ]
    }
  ],
  "village_id": "G794"
}
```

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

ニューラルネットワークを用いた人狼知能における性能評価

Performance Evaluation of AI Wolf Using Neural Network

堂黒浩明 *1　　松原仁 *1
Hiroaki DOGURO　　Hitoshi MATSUBARA

*1公立はこだて未来大学
Future Univercity Hakodate

Machine learning techniques are often used to make strong AI game programs. We can make AI Wolf strong programs using machine learning techniques. This works investigates whether neural network techniques are effective for 15 person AI werewolf programs. Experimental results shows neural network techniques are effective.

1. はじめに

人工知能の研究にはゲームを題材としたものも数多く存在する．その中でも，勝ち負けで性能の評価がしやすいといった要因から，強くすることを目指した研究は古くから行われてきた．

近年，不完全情報ゲームである人狼ゲームが人工知能研究の題材として注目を集めている．人狼知能プロジェクト *1 も発足され，人狼ゲームをプレイする AI である人狼知能において，強さを競う人狼知能大会というものも開催されている．人狼ゲームには嘘の情報を扱うことや，プレイヤ同士の議論によってゲームが進行することといった特徴がある．そのため，人狼ゲームをプレイする人工知能の研究を進めることで，そうした分野の人工知能技術の発展が期待される．そこで，本研究では人狼ゲームを題材として，強い人狼知能を作ることを目指す．

強いゲーム AI にはしばしば機械学習の技術が利用されてきた．人狼知能においても，機械学習を適用し性能の向上を図った研究がいくつかある．教師なし学習では，梶原らが強化学習によって人狼ゲームの最適戦略抽出を図った研究 [梶原 14] がある．教師あり学習では，梶原らが SVM を用いて人狼知能の性能向上を図った研究 [梶原 16] や，大川らが 5 人人狼において，ニューラルネットワークを用いて SVM を用いたものと比較した研究 [大川 17] がある．また，堂黒らは 15 人人狼でニューラルネットワークを用いて，大川らの研究で言及されていなかった各プレイヤの投票先情報を追加して人狼投票率が上がるかを確かめた [堂黒 18]．堂黒らの研究では，学習したエージェントが学習していないものより人狼投票率が高くなっているか示されていなかった．そのため，本研究ではランダムで投票するエージェントと比較し，どれだけニューラルネットワークを用いることで人狼投票率が高くなるかを確かめる．

2. 分析準備

2.1 用意した AI

分析する AI は堂黒らと同じものを使用した．用意した 3 つの AI の特徴を表 1，各 AI に用いられたニューラルネットワークの構成を表 2 に示す．各 AI の人狼投票率を確かめるために，GAT2017 と CEDEC2017 で登録されていた人狼知能を対戦相手として使用した．用意した AI のゲーム中の挙動は，発言はせず，1 日の初めにニューラルネットワークによる分類を行い，生存している中で出力値が最も高いエージェントを人狼として投票することとした．

表 1: 各 AI の特徴

AI の種類	特徴
AI1	各プレイヤの投票先を入力とした AI
AI2	占い師数，霊媒師数，被占い結果，占い結果，CO 順番，投票変更数，日にち，推定発言数を入力とした AI
AI3	AI1 と AI2 を組み合わせた AI

表 2: 用意した AI のニューラルネットワークの構成

	AI1	AI2	AI3
入力次元	225	588	813
出力次元	15	15	15
中間層数	1	1	1
中間ユニット数	300	850	850
中間活性化関数	Sigmoid	Sigmoid	Sigmoid
出力活性化関数	Softmax	Softmax	Softmax

2.2 ニューラルネットワーク

ニューラルネットワークの活性化関数である Softmax 関数の特徴として，算出した数値を確率で表現できるという点がある．この特徴から，本研究に適用した例で言うと，Softmax 関数を用いることで最も人狼の確率が高いプレイヤを割り出すことができると言える．本研究では，GAT2016 と GAT2017 の 15 人人狼におけるログを教師データとして用いた．そうして，投票先情報が出る 2 日目以降を対象に，1 日毎のデータから 15 人のプレイヤの内 1 人を人狼として分類するように学習を行った．

3. 分析結果

3.1 用意した AI とランダム投票の比較

用意した AI とランダム投票とした AI でそれぞれ 1000 回の対戦を行った．その対戦から得られた，分類を行った 2 日目以降での各 AI の人狼投票率を表 3 に，日にち毎の人狼投票率を図 1 に示す．この際，7 日目からはデータ数が少ないため 7

連絡先: 堂黒浩明，公立はこだて未来大学松原仁研究室，〒 041-8655，北海道函館市亀田中野町 116 番地 2 号，TEL:0138-34-6125，E-mail:g2117031@fun.ac.jp

*1 http://aiwolf.org/

表 3: 用意した AI の人狼投票率

用意した AI	人狼投票率
AI1	26.51%
AI2	31.67%
AI3	30.62%
Random	25.22%

日目以降の人狼投票率を合計した時の割合を表示した．

表 3 の内容から，Random と各 AI の間でカイ二乗検定を行った結果，AI2 と AI3 は Random よりも人狼投票率が有意に高かった (p<.01)．このことから，入力情報によっては 15 人人狼においても，ニューラルネットワークによって性能が向上することがわかった．

次に図 1 の内容を見ると，6 日目以降だとニューラルネットワークを用いた AI は Random よりも人狼投票率が下がっていた．こうした結果になる要因として．まず，Random は序盤の人狼投票率が低いため，6 日目や 7 日目に人狼が複数残っていて人狼投票率が高くなるのではないかと考えられる．また，最後まで生き残る人狼はあまり人狼らしい特徴を持たないため，ニューラルネットワークによる分類の際にうまくいかないのではないかと考えられる．

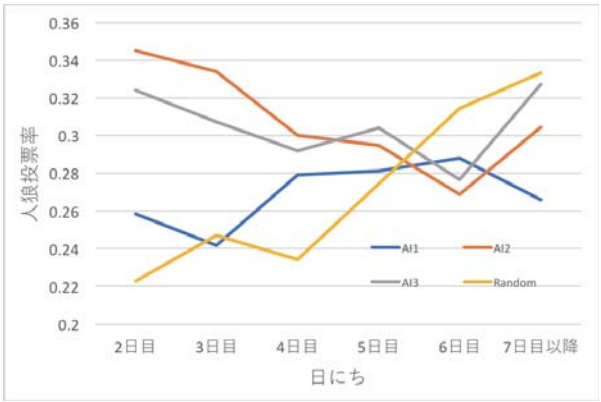


図 1: 各 AI 毎の日にちによる人狼投票率

3.2 6 日目以降の投票方法変更

ニューラルネットワークを用いて学習した AI が，ゲーム終盤において低い人狼投票率を得た．この理由として，最後に生き残っている人狼は人狼らしい特徴を持たないことが考えられる．

ニューラルネットワークの出力値は，対応するプレイヤが人狼の確率が高いほど値も大きくなる．そのため，出力値が低いエージェントは人狼だと分類されていないものだと言える．出力値の低い方から投票すると，本来その値に対応するプレイヤは人間であるため人狼投票率は低くなると考えられる．しかし，反対にその投票方法で人狼投票率が高くなった場合は，用意した AI は生存しているプレイヤの中で，人狼を最も人狼らしくないプレイヤとして頻繁に分類していることが言える．

人狼投票率の変化を確かめるために，6 日目以降は分類時の出力値が低い方から投票するように各 AI の内容を変更し再度対戦を行った．6 日目と 7 日目以降でそれぞれ 1000 回の投票を行った時の割合を表 4 に示す．表 4 の内容から，各 AI の投票方法変更前と後でカイ二乗検定を行ったところ，6 日目は AI2 と AI3 で，7 日目以降では全ての AI で変更後の方が人狼投票率が有意に高くなった (p<.01)．

表 4: 変更前と後の人狼投票率

	AI1	AI2	AI3
6 日目の通常の投票	29.8%	28.0%	27.8%
6 日目の変更後投票	33.5%	36.0%	33.3%
7 日目以降の通常の投票	31.0%	31.1%	31.2%
7 日目以降の変更後投票	38.5%	40.7%	37.7%

こうした結果により，用意した AI はゲーム終盤に人間に対して人狼だと分類して投票しているケースが多いことがわかった．このことから，用意した AI に使用した入力情報はゲーム終盤の分類において適切でないことが考えられる．

4. まとめ

本研究では，15 人人狼にニューラルネットワークを適用した際に，どれだけ人狼知能の性能が向上しているかを調べた．

本研究における分析から，ニューラルネットワークを用いることで，ランダムで投票するものより高い人狼投票率を得られることが示された．しかし，ゲーム終盤においては人狼をうまく分類できていないことが判明した．その原因として，強い人狼が生き残った場合，あまり人狼らしい特徴を持たないためうまく分類ができなかったと考えられる．さらに，人狼知能大会の上位エージェントには，人狼投票率が高いプレイヤを襲撃するという特徴を持つものが確認できた．このことから，人狼を推定できていないプレイヤばかりがゲーム終盤で生き残っており，そうしたプレイヤの間違った情報が多くなることによって，分類がうまくいかないようになったと考えられる．

今後の展望として，本研究で用いた入力情報を 1 種類ずつ除いて学習した AI を用意し，どういった情報が誤った分類に繋がるのかを検証する必要がある．

参考文献

[堂黒 18] 堂黒浩明, 松原仁: ニューラルネットワークを用いた人狼推定における投票先情報の有効性評価, GAT2018 論文集.

[梶原 14] 梶原健吾, 鳥海不二夫, 大橋弘忠, 大澤博隆, 片上大輔, 稲葉通将, 篠田孝祐, 西野順二: 強化学習を用いた人狼における最適戦略の抽出, 第 76 回全国大会講演論文集 2014(1), pp. 597-598, 2014-3-11.

[梶原 16] 梶原健吾, 鳥海不二夫, 稲葉通将, 大澤博隆, 片上大輔, 篠田孝祐, 松原仁, 狩野芳信: 人狼知能大会における統計分析と SVM を用いた人狼推定を行うエージェントの設計, 第 30 回人工知能学会全国大会 (2016).

[大川 17] 大川貴聖, 吉仲亮, 篠原歩: 深層学習を用いて役職推定を行う人狼知能エージェントの開発, ゲームプログラミングワークショップ 2017, pp. 50-55, 2017-11-10.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

人狼 AI における機械学習を用いた役職推定の改良

Improvement of Role Estimation using Machine Learning in werewolf AI

木村勇太[*1]
Yuta Kimura

伊藤毅志[*1]
Takeshi Ito

[*1] 電気通信大学
University of Electric Communication

. Role estimation by existing werewolf AI agents had been heuristically decided by the developer. In this research, we introduced an agent using SVR (Support Vector Regression), which is one of machine learning, to the estimated part of the existing agent and verified its effectiveness. As the result, it was possible to realize estimation rates exceeding the existing method after the middle game. Also, we developed a combined agent that used the existing method in the opening game and the proposed method in the middle game and later. The combined agent gave a significantly higher win rate than the existing agent.

1. はじめに

「汝は人狼なりや？」(以下、人狼と呼ぶ)というゲームは、プレイヤ同士のコミュニケーションが中心となる多人数不完全情報ゲームである. 人狼で勝つためには嘘をつく能力や, 情報の真偽を見極める推理をする論理的思考能力が要求される. 人狼をプレイするエージェントを開発するためにはこれらの能力を解析, 実装する必要があり, 人工知能における様々な重要な要素を含んでいる. 人狼を知的にプレイする AI の開発を目的として, 2015 年に「人狼知能プロジェクト」が発足した[1].

プロジェクトは人狼を行うエージェントの対戦環境として人狼知能プラットフォームを提供しており, これを用いた大会も開催されている. 大会の決勝へ出場したエージェントは人狼知能プロジェクトのサイトで公開されており, 既存エージェントを改良する研究や作成したエージェントを大会と同じ環境で対戦実験を行うことが可能である[2].

人狼では対戦相手の中から人狼を推定する能力が勝つために重要になっている. 本研究では既存エージェントの人狼推定部分に機械学習を適用させ, その有効性を検証することを目的とする.

2. 人狼

2.1 人狼ゲームのルール

人狼とは, 参加者にランダムに割り振られた人狼陣営と村人陣営の役職をプレイヤ相互が知りえない状況からゲームが開始される. その後役職によって知り得た情報を参考にしながら, コミュニケーションを通じて情報を共有して, それぞれの陣営の勝利を目指すゲームである. プレイヤの中に潜んでいる人狼を全員排除すれば村人陣営の勝利, 人狼の数が生存している村人の数と同じになれば人狼陣営の勝利となる.

プレイヤは生存プレイヤ全員の投票によって「追放」されるか, 人狼に「襲撃」されるかのどちらかの方法でゲームから除外される.

ゲームの進行は, 議論により追放者を多数決で決める昼フェーズと, 人狼が襲撃先を決めたり特殊能力を持ったプレイヤが能力を使用したりすることのできる夜フェーズがある. これをどちらかの陣営が勝利条件を満たすまで繰り返す.

人狼には特殊能力を持った役職がある. 夜フェーズに一人だけ自分以外のプレイヤが人狼か否かを知ることができる「占い師」, 追放されたプレイヤが人狼か否かを知ることができる「霊媒師」, 一日に一回指定したプレイヤを人狼の襲撃から守る「狩人」である. また, 人狼陣営には人狼に加えて, ゲームの進行中は村人として扱われるが人狼陣営が勝利したときに勝利になる「裏切り者(狂人)」という役職がある. それ以外のプレイヤは、特殊能力を持たない「村人」である.

2.2 AI 人狼のルール

人狼では会話が重要な要素を担う. AI が人狼をプレイするための環境として, 人狼知能プロジェクトでは AI 同士の人狼を実現する「人狼知能プラットフォーム」というものが提供されている.

人狼の中で現れる発言には, 「私は占い師です」といったカミングアウト発言, 「私は○○に投票します」といった投票宣言などの人狼ゲーム特有の発言がある. 人狼知能プラットフォーム上ではこれらの発言を「人狼知能プロトコル」という形で定義しており, AI 間でやりとりが可能になるように簡素化した形で表現している.

人狼知能プロジェクトではこのプロトコルを用いた大会を開催しており, 本研究ではその大会における標準ルールに則った人狼 AI について議論する. この標準ルールは 15 人でプレイする 15 人人狼となっており, 参加者の役職は「村人 8・狩人 1・占い師 1・霊媒師 1・狂人 1・人狼 3」という構成となっている.

3. 先行研究

3.1 人狼エージェント「Udon」

過去 2 回の人狼知能大会を連覇している有力な人狼エージェントの 1 つとしてチーム饂飩が開発したエージェント「Udon」がある[3]. 「Udon」が持つ大きな特徴は, 「内訳」という概念を用いて人狼と狂人を推定しているところにある.

「内訳」とは人狼陣営の役職の組み合わせのことである. 人狼 3 人と狂人 1 人の組み合わせを{人狼、人狼、人狼、狂人}というエージェント番号のリストで表現する. 「Udon」は最初に全パターンの内訳のリストを作成する. 人狼知能大会の標準ルールにおいては, 参加エージェント 15 人中 3 人の人狼と 1 人の狂人を選び出す組み合わせになるので, 5460 (=15C3×12) 通りの内訳リストを保持することになる. しかし, ゲーム中に新しい情報を得ることで, 論理的にありえない内訳は排除されていく. その後, 次の手順で内訳のスコアを求め, これを基にエージェントの行動を決定する.

1. 全てのエージェントに対して，それぞれの人狼/狂人スコアを求める.
2. 内訳に含まれるエージェントの人狼/狂人スコアを乗算する.
3. エージェント間でのやり取り(例：投票行動)から補正する.

1 で求める人狼/狂人スコアは以下の式で算出される.

$$\text{人狼スコア} = 1.00 \times x(A) \times x(B) \times \ldots \times x(Z) \quad (1)$$

x(A)とはエージェントが行動 A を行った際の，A の人狼らしさを表す値である. しかし，「Udon」では、この値は開発者によってヒューリスティックに決められているため，この部分に機械学習を導入することで，より良い推定が可能になるかも知れない.

3.2 人狼エージェントに機械学習を導入した研究

ルールベースに設計された人狼推定を機械学習に変更することで人狼推定精度を研究したものとして梶原らの研究がある[4].

この研究では人狼知能大会の対戦ログデータを SVM で学習させ人間か人狼かを判別する SVM 判定器を作成した. 判定器作成後，以下の 3 つのエージェントを作成し，それぞれ 16 年大会の上位 14 エージェントと 10000 回対戦実験を行い，人狼への投票率と勝率を比較した.

1. 自分に人狼判定を出した占い師 CO 者がいた場合，そのエージェントに投票を行う(ルールベース AI)
2. 判定器が人狼と判断したエージェントに投票を行うエージェント(SVM 推定 AI)
3. 2 に加えて，人狼と判断した相手への投票宣言を行うエージェント(SVM 推定&発話 AI)

対戦実験の結果，人狼への投票率，推定率ともに 2, 3 のエージェントの方が高くなることが確認された. この研究により，投票行動への SVM の導入の有効性が示された. しかし，比較対象となったルールベース AI の実力は低く，「Udon」のようにルールベースに設計されていても強力なエージェントに対しての有効性は示されていない. 加えて，有効性が示されたのは投票行動という 1 部分のみである.「人狼ゲーム」には投票行動以外にも占い，護衛，襲撃といった行動が存在する. したがって，SVM を用いた人狼推定がこれらの行動においても有効であるか検証する必要があると考えられる.

4. SVR

SVR(Support Vector Regression) は SVM(Support Vector Machine)を回帰問題に適用させた手法である. SVR ではソフトマージンによって小さな誤差を無いものとして扱うため，回帰関数への影響が小さい.

人狼ゲームにおいて，人狼が村人を騙っているような状況では，人狼と村人の特徴の差は微々たるものになる. そのため小さな誤差が生まれやすい. 人狼ゲームのデータを学習させるには小さな誤差が回帰関数へ与える影響の少ない手法を用いる必要がある. したがって，SVR は人狼ゲームのデータの学習に適していると考えられる.

本研究では，既存の有力な人狼エージェントである「Udon」の人狼スコア算出部分に機械学習の一つである SVR を導入する.「Udon」では人狼スコアが変わると内訳のスコアも変更されるため，「Udon」が取る行動に変化が生まれる.「Udon」と SVR を導入したエージェントの推定率と勝率を比較し，その有効性を検証する.

5. 提案手法

5.1 学習方法

SVR で学習を行うために人狼スコアを以下のように定義した.

$$\text{人狼スコア} = w_A x_A + w_B x_B + \cdots + w_Z x_Z \quad (2)$$

x_Aとは A が行動 A を行った時に 1，行わなかった場合 0 となる. ただし日付やカミングアウト数といった情報を用いる際は連続値となる. SVR では重み w を学習データから決定する.

学習させた特徴は「Udon」の人狼スコア決定アルゴリズムと先行研究[4]を参考にして，表 1 のように列挙した.

表 1　学習した特徴

特徴量	入力
日付(4 日目以降)	スコア算出時の日付
生死	生存なら 0，死亡なら 1
死因	追放なら 1，襲撃なら -1
襲撃されたものによる投票を受けている	Yes なら 1，no なら 0
無効なカミングアウト	Yes なら 1，no なら 0
配役にない役を CO	Yes なら 1，no なら 0
人狼と判定されてから占い師 CO	Yes なら 1，no なら 0
人狼と判定されてから霊媒師 CO	Yes なら 1，no なら 0
CO したタイミング	CO したときの日付
前日までに CO された役職を CO	Yes なら 1，no なら 0
襲撃された占い師から人間判定	Yes なら 1，no なら 0
襲撃された占い師から人狼判定	Yes なら 1，no なら 0
村人を CO	Yes なら 1，no なら 0
狩人を CO	Yes なら 1，no なら 0
霊媒師を CO	Yes なら 1，no なら 0
占い師を CO	Yes なら 1，no なら 0
狂人を CO	Yes なら 1，no なら 0
人狼を CO	Yes なら 1，no なら 0
占い師 CO 数	Yes なら 1，no なら 0
霊媒師 CO 数	Yes なら 1，no なら 0
人間判定を出した数	連続値
人狼判定を出した数	連続値
受けた人間判定数	連続値
受けた人狼判定数	連続値
投票宣言から実際の投票先の変更	連続値

5.2 教師データと実装

「Udon」を含む過去の大会に出場した 8 つのエージェントと参考文献[3]に実装手法が載っているサンプルエージェント 7 つ用意した. これらのエージェントを 10,000 回対戦させ，対戦ログデータを作成した. 対戦ログデータを直接学習させることはできないため，対戦ログデータから特徴を抽出し学習データを作成するためのプログラムを作り，学習データを作成した. 人狼はゲームが進むにつれて明らかにされる情報が増えて行くゲームである. そのため，日によって特徴量として使われる情報の量が違い，入力に差が生まれる. この状態ですべてをひとまとめに学習させてしまうと回帰関数がうまく作れない可能性がある. 加えて，学習にかかる時間も大幅に増えることになる. したがって本

研究では学習データをそれぞれ 1 日目, 2 日目, 3 日目, 4 日目以降の 4 種類に分割し個別に学習を行った.

学習時点で用いた人狼プラットフォームはバージョン 4.9 である. 学習にはオープンソースライブラリ libsvm ver3.22 を使用した.

学習後に出力されるモデルファイル読み込み, ゲーム中から得た特徴とモデルファイルを用いて人狼スコアを算出するよう「Udon」のプログラムを書き換え, これを提案エージェントとした.

6. 評価実験 1:人狼スコアの推定率の比較

6.1 目的

提案手法,「Udon」それぞれのエージェントが求める人狼スコアの推定率を比較する.

6.2 実験方法

学習データ作成の時と同じ 14 エージェントを用いた 15 人村環境で,「Udon」, 提案手法それぞれで 1,000 回ずつ対戦を行い, 推定率を求めた.

6.3 結果

日ごとの推定率を図 1 に示す. 実験の結果,「Udon」はどの日付でも 3 割程度の推定率を維持し続けており, 1 日目から 3 日目においては提案手法より推定率は高いことがわかった. 対して, 提案手法の推定率は初日から 9 日目まで上昇し続け, 4 日目から「Udon」を上回ることがわかった. しかし, 10 日目では大幅に推定率が下がり,「Udon」よりも低くなった.

χ^2検定の結果, 1, 2 日目において「Udon」の方が有意に推定率が高くなったのに対して, 5, 6, 7, 8 日目においては提案手法の方が有意に推定率が高くなった.

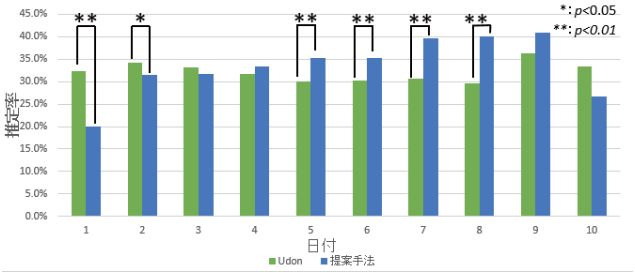


図 1 日ごとの推定率

6.4 考察

人狼の性質上, 日ごとに得られる情報は序盤に少なくゲームが進むにつれ増えてくる. 序盤では「Udon」の推定率が高いことから,「Udon」の人狼スコア算出モデル式(1)の方が序盤の少ない情報に適していると考えられる. 対して, 5 日目から 8 日目は提案手法の推定率が高いことから, 提案手法の SVR を用いた算出モデル式(2)の方がある程度情報の出揃っている中盤以降に適していることが示唆される.

7. 評価実験 2:勝率の比較

7.1 目的

評価実験1の結果より, 既存手法の推定率が高い序盤は既存手法を用い, 提案手法の推定率が高くなる中盤以降は提案手法を用いる組み合わせエージェントを構築すれば, 既存のエージェントよりも強くなるのではないかと考える. そこで, スコア算出に 3 日目までは既存手法, 4 日目以降は提案手法を用いる組み合わせエージェントを作成し, このエージェントと「Udon」の勝率を比較する.

7.2 実験方法

学習データ作成の時と同じ 14 エージェントを用いた 15 人村環境で,「Udon」と組み合わせエージェント, それぞれで 10,000 回ずつ対戦を行い, それぞれの勝率を求めた.

7.3 結果

対戦実験の結果を表 2 に示す. χ^2 乗検定の結果, 組み合わせエージェントの方が「Udon」より1%の有意水準で勝率が高いことが示された.

表 2 各エージェントの勝率

エージェント	勝率
既存手法	53.2%
組み合わせエージェント	55.2%

7.4 考察

推定率が高い手法を組み合わせることで, エージェントの勝率が上がる結果が確認できた. このことから, 中盤以降における既存手法の有効性が示唆された.

8. おわりに

本研究では不完全情報ゲームの1つである人狼を行うエージェントに対して SVR を導入することで, 人狼に対する推定率を上げる手法を提案した. 提案手法を 2015 年, 2016 年人狼知能大会優勝エージェントである「Udon」に組み込み, 対戦実験を行った. その結果, ゲーム中の 4 日目以降では推定率が上がることが確認できた. この結果にもとづき, 日付で手法を変えるエージェントを作成することで,「Udon」よりも高い勝率を出すことができた.

以上のことより, 中盤以降は, SVR を「Udon」の人狼スコア算出に適用する手法の有効性が示唆された.

しかし, 今回の実験で対戦を行ったエージェントは, 学習データに含まれるエージェントと同じであった. 実際に 2018 の 3 月に行われた人狼知能プレ大会@GAT2018 では 18 エージェント中 13 位と良い成績を残すことができなかった. この結果から提案手法エージェントには汎用性に問題があることが考えられる. このことを確認するために, 今後は未学習のエージェントとの対戦実験を行い, 本研究と同様に推定率と勝率を求め, 汎用性について検証する予定である.

未学習エージェントとの対戦実験の結果によっては汎用性の低さを改善していく必要が生まれる. 改善策の 1 つとしては本研究で学習していないエージェントも学習データに加えるという方法が考えられる. しかし, この方法だけでは対応できるエージェントが増えるだけで, 未学習のエージェントが多いような状況では, 今回参加した大会と同じような結果になってしまう可能性がある. よって学習データの幅を増やすだけではなく, 未学習エージェントにも対応できるように対戦中に学習を行い, ゲームが終わるごとに新しく得た情報を用いて学習結果を更新していくという手法も検討している.

参考文献

[1] 人狼知能プロジェクト. Artificial Intelligence based Werewolf(オンライン), 入手先 (http://aiwolf.org/),(参照 : 2018-1-29).

[2] 鳥海不二夫, 稲葉通将, 大澤博隆, 片上大輔, 篠田孝祐:ゲームプログラミング大会を用いた集合知的ゲーム AI 開発手法, デジタルゲーム学研究, Vol.9, No 1, pp.1-11 (2016).

[3] 狩野芳信, 大槻恭二, 園田亜斗夢, 中田洋平, 箕輪峻, 島海不二夫. 人狼知能で学ぶ AI プログラミング, 株式会社マイナビ出版(2017).

[4] 梶原健吾,島海不二夫,稲葉通将,大澤博隆,片上大輔,篠田孝祐,松原仁,狩野芳信. 人狼知能大会における統計分析と SVM を用いた人狼推定を行うエージェントの設計, 人工知能学会全国大会論文集, vol.30(2016).

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

Differentiable Neural Computerを用いた人狼知能の開発

Development of Werewolf-game Agent Using Differentiable Neural Computer

家原　瞭　Ryo Iehara
廣田　敦士　Atsushi Hirota
田中　一晶　Kazuaki Tanaka
荒木　雅弘　Masahiro Araki
岡　夏樹　Natsuki Oka

京都工芸繊維大学
Kyoto Institute of Technology

Werewolf-game is a table game with imperfect information. It is a new challenge for artificial intelligence to play Werewolf-game. We developed a Werewolf-game AI using Differentiable Neural Computer (DNC) (Graves et al., 2016). The system predicted the actions of Werewolf-game agents. As an evaluation index of prediction, we used whether information identifying the behavior matches that of the actual behavior. The evaluation result showed that speech behavior could be predicted with an accuracy of 66.8%. However, behaviors other than speech could be predicted only at the chance level.

1. 緒言

人工知能の分野では昔からチェスや将棋，囲碁といったゲーム AI の研究が盛んにおこなわれている．最近では 2017 年に Google DeepMind の AlphaGo[Silver 16] が柯潔九段に囲碁で勝利したことが話題になった．囲碁という情報空間の広いゲームにおける人工知能の勝利によって，完全情報ゲームでは人間を超えたと言える．そこでゲーム AI の次の挑戦として人狼ゲームが挙げられている [鳥海 16][篠田 14]．鳥海らは，人狼ゲームを人工知能分野の新たなグランドチャレンジとしている．具体的には，AI 同士での人狼ゲームの対戦を行えるようなサーバーの開発 [鳥海 14] や，大会の開催などを行い，様々な方向から人狼ゲームを行う AI（以下人狼知能）の発展を目指している．人狼ゲームは不完全情報ゲームであり，またコミュニケーションを通してやり取りするという点で，今までの人工知能研究の対象と性質が違うゲームといえる．本研究では，人狼知能に対する新たなアプローチとして完全学習型のエージェントの開発を目指す．完全学習型とは，行動の選択や発言内容までエージェントの行動選択を全て学習して選択するものを指す．また，本論文ではその第一段階として現存する強いエージェントの行動を学習のみで予測できることを示す．

2. 人狼ゲーム

2.1 基本ルール

人狼ゲームは 10 数人のプレイヤーによって行われるパーティーゲームである．ゲームスタート時に各プレイヤーには役職が割り振られる．役職ごとに陣営があり，プレイヤーは各陣営に分かれる．陣営ごとの役職は以下のようになっている．

村人陣営： 村人，占い師，霊媒師，狩人

人狼陣営： 人狼，狂人

最終的には以下の勝利条件を満たしたチームが勝利となる．

村人陣営の勝利条件： 人狼をすべて追放する．

人狼陣営の勝利条件： 村人の数を人狼以下にする．

連絡先: 家原　瞭，京都工芸繊維大学，iehara@ii.is.kit.ac.jp

人狼ゲームは，ゲームの世界における半日単位で進行し，以下のような行動が行われる．

昼： 各プレイヤー間で自由に対話を行い，その後全プレイヤーの投票により，人狼容疑者 1 名を追放する．

夜： 人狼により村人が一人襲撃され殺される．役職による能力の使用もこの時に行われる．

追放および襲撃にあったプレイヤーは，それ以降ゲームには参加できない．よって追放と襲撃によってプレイヤーが減っていき，いずれ村人陣営と人狼陣営のどちらかの勝利条件が満たされることになる．各勝利条件を満たすための方針として，村人陣営は昼の対話や占い師や霊媒師の能力を使い，人狼を見つけて，その人物を投票によって追放することを目指す．また，村人陣営のほうが人数が多いため，人狼陣営は自分が人狼であるとばれないように相手をだまし，追放によって村人陣営のプレイヤーを減らしていく必要がある．

2.2 役職説明

村人： 特別な能力なし．

占い師： 夜のフェーズに 1 人のプレイヤーを指定して，人狼か否かを知ることができる．

霊媒師： 夜のフェーズに昼のフェーズに追放したプレイヤーが人狼か否かを知ることができる．

狩人： 夜のフェーズに 1 人のプレイヤーを指定して，護衛することができる．守られているプレイヤーが人狼による襲撃にあった場合，襲撃は失敗となりプレイヤーが減ることはない．

人狼： 夜に 1 人のプレイヤーを指定して襲撃することができる．襲撃されたプレイヤーは以降ゲームに参加できなくなる．また，人狼同士は互いが人狼であることを知っていて，夜のフェーズに人狼内で秘密の会話を行うことができる．

狂人： 特別な能力なし．人狼陣営であるため，人狼にうまく協力する必要がある．

2.3 ゲーム AI としての人狼ゲーム

人狼ゲームはパーティーゲームとして広く受け入れられているが，ゲーム AI の題材としてはどうであろうか．緒言で述べたように，完全情報ゲームでは人間の到達できるレベルを超えてしまったと考える．一方で，ゲームの中には情報の一部が全体に公開されないようなゲームも多く存在する．このようなゲームを不完全情報ゲームと呼ぶ．人狼ゲームはこの不完全情報ゲームであり，新たな挑戦として取り組まれているものの一つである．また，人狼ゲームはコミュニケーションのみによって成り立ち，盤面などの評価が存在しないという点で，他のゲームとは大きく異なる．自然言語対話の中で論理や思考を読み取り，嘘や説得といった要素を含む高度なゲームであり，自然言語対話などに向けた足がかりとなる人工知能のグランドチャレンジとみなされている [鳥海 16][篠田 14]．

2.4 人狼知能にかかわる研究

人狼知能プロジェクト [鳥海] では，人間同士の対戦における行動の解析や人狼知能の大会などを開いている．人間同士の対戦における行動の解析では，熟練度によって勝率が上昇することが示されている．じゃんけんなどの学習不可能な運にのみ依存するゲームでは人工知能にプレイさせることに意味がないが，人狼ゲームは熟練の要素が存在することが示されている [鳥海 16]．

また，同じく人狼知能プロジェクトは，集団知による人狼知能の構築を目指して人狼知能大会を開催している．人狼知能大会は 2017 年に第 3 回人狼知能大会が開催されている．そこでは，人狼ゲーム用の会話プロトコルを用意しており，そのプロトコルを用いた大会が行われている．また，第 3 回からは自然言語を用いた大会も行われている．それにともなって人狼知能エージェントを戦わせることのできるサーバーとそのサーバーで戦わせることのできるサンプルの構築と公開を行っている [鳥海 14]．

3. 構築した学習システム

3.1 システムの目的

本研究で作成したシステムは，人狼ゲームのシステム同士での対戦におけるログデータから，プレイヤーの行動を予測できるよう学習することが目的である．ログデータから一人のプレイヤーを選択し，そのプレイヤー以外の行動のうち観測可能な情報を入力とし，そのプレイヤーの行動を推測する．

3.2 システム概要

システムの概要を図 1 に示す．

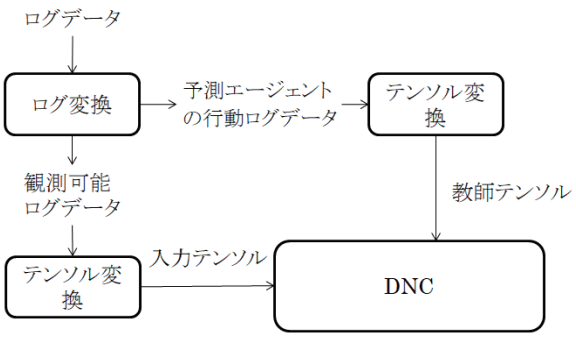


図 1: 構築した学習システムの概要

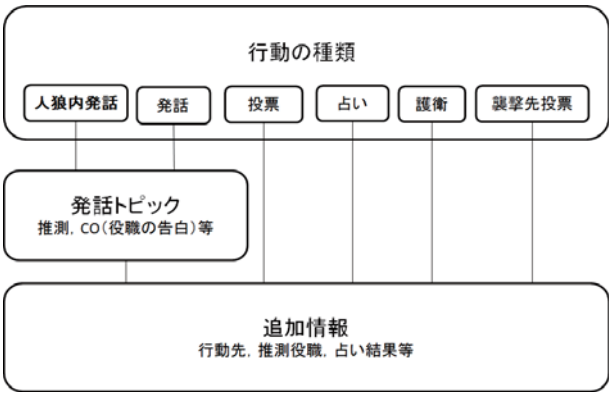


図 2: ログデータの概略

3.3 ログデータ

第 3 回人狼知能大会時でのプロトコル (人狼知能プロトコル ver2.01) を採用した [鳥海]．各エージェントについて順番に行動が回っていき，その時に行える 1 つの行動が 1 行に対応する．ログは階層構造になっており，図 2 に示すような情報を含んでいる．

3.4 ログ変換

ログデータには，すべてのプレイヤーのすべての行動，処刑や護衛先の役職などの非公開情報などプレイ中は手に入らない多くの情報が含まれている．よってこのログから適切な情報を抽出する必要がある．今回扱うタスクはあるプレイヤーの行動をそのプレイヤーの観測情報から予測できるかというものであるので，入力としては，あるプレイヤーから観測できる周りの情報を抽出する必要がある．Differentiable Neural Computer には出力を再び入力に入れるような再帰構造があるため，自分のこれまでの行動は情報として入力されるがログデータから明示的に入力として与えることはない．また，出力，つまり教師データとしてはそのプレイヤーの行動情報を抽出する必要がある．よって，まずランダムに一人のプレイヤーを選択し，そのプレイヤーの視点で獲得できる情報を選別する．プレイヤーを定めたのち，ログデータに含まれる情報は 5 種類に分類される．

1. 自分の行動情報
2. 他人の行動情報（観測可能）
3. 他人の行動情報（観測不可能）
4. システムからの情報（観測可能）
5. システムからの情報（観測不可能）

自分の行動情報とは選択したプレイヤーの投票先や護衛先，発言内容といった内容である．他人の行動（観測可能）というのは，選択したプレイヤー以外の発言内容や投票先といった情報で，プレイ中に選択したプレイヤーが知ることが可能な他人の行動である．他人の行動（観測不可能）というのは，選択したプレイヤー以外の護衛先，占い先など，本人のみに告げられ，他人（選択したプレイヤーを含む）には知らされない行動である．システムからの情報（観測可能）というのは選択したプレイヤーの役職や日付，ゲームの進行などのシステム側から与えられる情報のうち観測が可能なもののことである．人間同士で

の人狼ゲームでは全体や自分に向けてゲームマスターが公開した情報のことである．システムからの情報（観測不可能）というのは選択したプレイヤー以外の役職，自分以外の占い師の占い結果などのゲームマスター，あるいはシステム側から与えられる情報であるが，選択したプレイヤーには公開されない情報のことである．以上のように分類を行ったとき，学習モデルへの入力として他人の行動（観測可能）とシステムからの情報（観測可能）を抽出する．また，学習モデルへの教師データとして自分の行動情報を抽出する．

3.5 Differentiable Neural Computer

今回学習モデルとして Differentiable Neural Computer (DNC)[Graves 16] を利用する．DNC は通常の neural network とは異なり，外部メモリを持つ点が特徴である．外部メモリへの入出力制御まで学習することが可能であり，今までのネットワークでは扱えないような地下鉄の路線図から最短経路を探索するタスクやパズルの解法などの複雑なものを学習することが可能であると報告されている [Graves 16]．

4. 実験内容

4.1 実験仮説

1. 1 種類のエージェントを 15 体用意し，そのエージェントで 15 人人狼ゲームを行ったとき，選択した一人のエージェントの行動が予測できる．

2. 第 3 回人狼知能大会決勝のログデータについて，選択した一人のエージェントの行動が予測できる．

4.2 モデルの入出力

ログデータからシステムのログ変換機能を使って，入力データと教師データを作成する．具体的な入力の形状として，(バッチサイズ) ×（ログデータの行数）×（ 1 行当たりのベクトル長) の 3 次元テンソルを入力する．今回はミニバッチ学習を用いたため，並列に学習できるようなネットワーク構造をしている．そのため，入力はバッチサイズとして指定した数のゲームを変換したテンソルを入力とする．また，ログデータの行数の次元を系列として扱うようになっている．つまり，1 行を一つのベクトルに変換し，そのベクトルを系列として扱う．出力も同様のものを要求する．出力が不要の行については教師データはすべて 0 になっているが，誤差関数の計算には含まれない．よってどのような出力をしても誤差に影響されないものとする．

4.3 評価方法

行動が正しく予測できたかの基準について述べる．各行動ごとに行動をとるのに必要な情報が一致しているかを予測できたかの判断基準として定めた．行動の種類はゲーム進行の都合によって決まり，ゲームマスター側からの指定があってプレイヤー側では選択出来ないため，一致しているかどうかを行動の評価基準には含めない．

4.4 実験

以下に示すログＡとログＢのそれぞれの全体の予測結果の一致率について同一のハイパーパラメータを用いて学習させて比較する．ただし学習に用いたデータ数は異なる．

ログＡ： 人狼知能プラットフォーム 0.4.9 に付属するサンプルエージェントを 15 体用意し，15 人人狼を行った場合のログデータ

ログＢ： 第 3 回人狼知能大会決勝でのログデータ

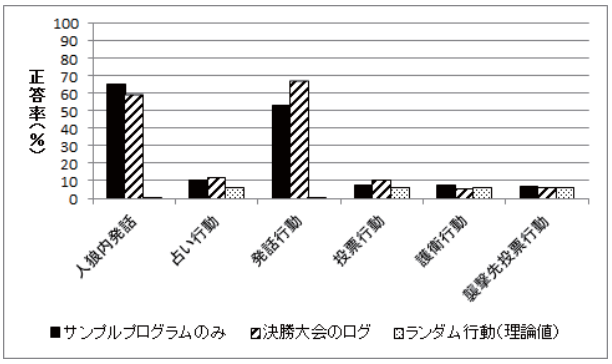


図 3: 行動の種類ごとの正答率の比較

上記のログＡとログＢでの各行動ごとの予測結果の一致率についても同一のハイパーパラメータを用いて学習させて比較する．また各行動ごとの難易度の基準として，行動を行う場合に必要な選択肢を，すべてランダムに予測した場合の一致率についての理論値との比較も行う．

4.5 データ数

サンプルプログラムのみ： 学習データ 1350, テストデータ 150

決勝大会のログ： 学習データ 517500, テストデータ 37500

5. 実験結果

学習結果として表 1 図 3 のような結果が得られた．ランダム行動は，行動に必要な情報をすべてランダムに予測した場合の正答率について理論値を計算したものである．

表 1: 各ログの予測一致率

	サンプルプログラムのみ	決勝大会のログ
一致率	49.15%	62.68%

6. 考察

6.1 実験結果に対する考察

まず，全体の正答率について考える．

タスクの難易度としてサンプルプログラムのみの行動予測と決勝大会のログの行動予測では，サンプルプログラムのみの行動予測のほうが簡単であるはずである．理由として，1 つのエージェントにつき一つのアルゴリズムが存在するため，決勝大会のログには複数の行動指針が含まれることが挙げられる．今回のシステムには，人狼ゲームでの共通の思考要素を学習することを期待していたため，エージェントの種類の情報を与えていない．そのため，複数の行動指針が含まれるような場合，あるエージェントにとってはこの行動が正解であるが，ほかのエージェントにとっては違う行動が正解であるといったような複数の正解パターンが生まれる場合もある．

今回の結果を見てみるとサンプルプログラムのみ 49.15%，決勝大会のログ 62.68%となっている．ここから，考えていたタスクの難易度とは逆の結果が得られた．この結果について以下の 3 つの原因が考えられる．

1. 学習データ数が大きく違うこと

2. バッチサイズが小さすぎる

3. 学習の打ち切りタイミングが固定である

学習データが多くなれば，その分様々な場面のデータが含まれるため，より精度よくモデルを近似できると考えられる．今回は少ないデータでも過学習を起こしていなかった．そのため，大きな問題はないと考えていたが，この影響を無視することはできない．また，時間と資源の都合（この実験は GPU は使わず学習した）上バッチサイズを小さくしていた．しかしクロスエントロピー誤差が大きく増減していたため打ち切ったタイミング次第で正答率も大きく変わると考えられる．その為，学習の打ち切りタイミングが固定であることは問題となっていると考えられる．

次に，各行動ごとの予測精度の比較を行う．どちらのログから学習した場合でも，発話行動と人狼内発話の 2 つの行動についての予測精度は，ランダム予測と比べて非常に高い．一方でほかの行動に関してはランダム行動時とほぼ変わりがない．人狼内発話と発話行動はともに会話にかかわる行動であり，どちらの行動も “日付，行の種類（人狼内発話か発話行動），発話 ID，ターン番号，発話エージェント番号，発話内容” といった同一のプロトコルで扱われる．よって，人狼内発話と発話行動に用いるプロトコル（以下，発話プロトコル）に関しては学習ができたと考えられる．逆にそれ以外は学習できていないと考えられる．これは全行動に占める割合に着目すると説明できる．発話プロトコルを用いる行動数はサンプルプログラムのみ，決勝大会のログどちらでも全体の 9 割以上である．多く出現する行動をまず学習するというのは誤差を小さくするうえで妥当であると考えられる．よって，まず発話プロトコルを十分に学習し，そののちほかの行動を学習すると考えられる．今回は学習を規定回数で止めているため，発話プロトコル以外が十分に学習されなかったのではないかと考える．よって，より規模の大きい学習が必要であるだろう．そこで現在，GPU マシンでバッチサイズを 2 から 64 に大きくして学習中である．学習途中の結果として今回とほとんど変わらない結果しか得られていないが，クロスエントロピー誤差がほぼ線形に下がり続けているため学習量が十分ではないと考えられる．一方で学習ステップ自体は今回の実験より少ないもののバッチサイズが非常に大きくなり，学習時間も数倍になってもほとんど結果が向上しないことを考えると学習の規模では大きな改善が得られないと予想される．

発話行動以外の行動の一致率が低い原因の一つについて，図 2 に示す行動の種類についての情報の内，自分の行動に関するものを，入力に含めなかったことが考えられる．行動の種類はプレイヤーが自由に選択できるものではなく，ゲームの進行の都合によって固定される．そのため，本来学習対象ではない．そこでその情報を入力として与えないのは適切ではない．これは通常の人狼ゲームでは会話の時間が終わり，投票の時間が始まったことを指示されないこと等に相当する．周りの人が投票を始めたことで，投票しなければならないことに気づくかもしれないが，指示がない分だけ判断が難しくなることは明らかである．自分の行動の種類が判断しづらくなったため，すべての行動を発話行動だとみなして行動し発話行動以外の確率が下がったのではないかと考える．

6.2 今後の展望

まず必要となるのが会話プロトコル以外の学習可能性や会話プロトコルかどうかの判断に対する学習可能性を調べるため，クロスエントロピー誤差が収束する程度までは学習させる必要がある．次に，自分の行動の種類をシステムからの情報に含めて，行動時の入力に含める必要があると考える．

また，今回発話の学習可能性が示せたため，それを利用したエージェントとして，勝利エージェントのみを学習させることで強い発話行動を持ったエージェントが作れるのではないかと考えている．もし，会話プロトコル以外も学習できることが示せれば，目標としていた行動すべてを学習によって行うエージェントが作成できるのではないかと期待している．

7. 結言

今回，DNC を用いた学習によって，発話にかかわる行動を学習できることを示した．また，今回は発話以外の行動に関しては学習可能であることを示すことができなかった．それには学習規模と入力情報の選択の 2 つの要因が考えられる．学習規模については現在調査中で，ある程度の大きくしても結果は向上しなかったが，クロスエントロピー誤差が下がり続けているため，学習を続ける必要がある．今後，入力情報の選択に関しても調査していく必要がある．また，勝利エージェントのみによる学習等を用いて，目標である行動すべてを学習によって行う人狼知能エージェントの作成に向けて取り組んでいきたい．

参考文献

[Graves 16] Graves, A., Wayne, G., Reynolds, M., Harley, T., Danihelka, I., Grabska-Barwińska, A., Colmenarejo, S. G., Grefenstette, E., Ramalho, T., Agapiou, J., et al.: Hybrid computing using a neural network with dynamic external memory, *Nature*, Vol. 538, No. 7626, p. 471 (2016)

[Silver 16] Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., Van Den Driessche, G., Schrittwieser, J., Antonoglou, I., Panneershelvam, V., Lanctot, M., et al.: Mastering the game of Go with deep neural networks and tree search, *nature*, Vol. 529, No. 7587, pp. 484–489 (2016)

[篠田 14] 篠田孝祐, 鳥海不二夫, 片上大輔, 大澤博隆, 稲葉通将：汎用人工知能の標準問題としての人狼ゲーム, 人工知能学会全国大会論文集, Vol. 28, pp. 1–3 (2014)

[鳥海] 鳥海 不二夫, 稲葉 通将, 大澤 博隆, 片上 大輔, 松原 仁, 狩野 芳伸, 大槻 恭士, 園田 亜斗夢：人狼知能プロジェクト, http://aiwolf.org/

[鳥海 14] 鳥海不二夫, 梶原健吾, 大澤博隆, 稲葉通将, 片上大輔, 篠田孝祐 他：人狼知能サーバの構築, ゲームプログラミングワークショップ 2014 論文集, Vol. 2014, pp. 127–132 (2014)

[鳥海 16] 鳥海不二夫, 片上大輔, 大澤博隆, 稲葉通将, 篠田孝祐, 狩野芳伸：人狼知能　だます・見破る・説得する人狼知能, 森北出版 (2016)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

進化シミュレーションを用いたエージェントにおける情報共有の分析

Analysis of Agents' Information Sharing with Evolutionary Computation

汪 博豪[*1] 大澤 博隆[*2] 佐藤 健[*3]
Bohao Wang Hirotaka Osawa Ken Satoh

[*1] 筑波大学大学院システム情報工学研究科
Graduate School of Systems and Information Engineering, University of Tsukuba

[*2] 筑波大学システム情報系 [*3] 国立情報学研究所
Faculty of Engineering, Information and Systems, University of Tsukuba National Institute of Informatics

This paper introduced analysis of agents' information sharing with evolutionary computation. We focus on a method that human adds a hidden meaning to our word for sharing information only with cooperators in subgroup. In this paper, we defined 3 player version of werewolf game, and run a 10000 generations evolutionary computation. Then, we classified villager's strategies with label of "rational", "irrational" and "ambiguous". We suggested that when villager used an "irrational" strategy and won the game, seer and villager used the above information sharing method. As the result, the above method appeared in both case of wolf fixed and wolf evolved. In the case of wolf fixed, seer added hidden meaning to a fixed word in 99.2% of times to share information only with the villager. In the case of wolf evolved, in 26.4% of times, seer succeed to share information only with the villager by the above method and seer started to change word with hidden meaning for keeping avoid sharing information with the wolf.

1. はじめに

我々人間の情報共有の手段の一つとして，言語的コミュニケーションは効率的だと考えられる．人間以外の動物と異なり，我々は言語との物に意味を付けて，外部世界や自身の心理活動などの情報を共有する．しかし，言語は話者間で固定的ものではなく、話者間の望みにより移り変わっていく．例えば，あるグループの中で、情報を共有する友人と情報を共有するわけにはいかない他者がいる場合，友人と情報を共有するため，言語の裏の意味を創り出し，友人に裏の意味解釈を誘導させることが起きうる．例としては，恥ずかしがりやの人物が好きな人物に「月が綺麗ですね」と言う場合に，実際は「好きです」という裏の意味を伝える例が考えられる．この場合には、好きな人物以外に好きだという原意を知らせたくないため，「月が綺麗ですね」と言うプロセスが発生している．発話者は情報を共有されてない他人に単なる月の話と考えさせ，裏の意味を共有せず，恥ずかしい雰囲気を生み出すことを回避している．

我々は，上記の言語から裏の意味を創り出し，あるグループの中で友人とのサブグループに情報を共有する手法が，エージェント同士のコミュニケーションにおいて発生すると考えている．本研究は進化シミュレーションを用いてエージェントにおける情報を共有する手法を調べた．本研究は人工知能やエージェントなどの様々な研究で用いられている不完全情報ゲームであり，正体隠匿型ゲームに分類されるコミュニケーションゲーム人狼を用いた[Katagami 14][Bi 16][Hung 10]．我々は以前の研究により[大澤 17]，最小系の 3 人人狼ゲームを定義し，進化シミュレーションを行った．上記の裏の意味を創り出しの情報共有の手法における分析のため，我々は村人の視点を中心として，協力者/友人の占い師の発話内容が裏の意味を持つかどうかにより，村人と敵対者の人狼の戦略を分類した．占い師の言葉に裏の意味を持つと考えていた戦略は「不合理的」な戦略と呼び，村人が「不合理的」な戦略を用い，ゲームを勝利した場合は，村人と占い師における言語の裏の意味を創り出し，情報共有の手法が発生したと考えられる．

連絡先：筑波大学大学院システム情報工学研究科， 茨城県つくば市天王台 1−1−1，hailabsec@iit.tsukuba.ac.jp

2. 3 人人狼の定義

2.1 人狼ゲームとは

人狼ゲームは嘘を見抜くコミュニケーションゲームの一種である．各プレイヤーは村人陣営と人狼陣営に分かれてプレイを行う．人狼ゲームにおける村人陣営には夜のフェーズに誰が人狼であるかを見分ける占い師という役職が存在する．人狼ゲームは昼と夜のフェーズが交互に進み，以下の勝利条件を満たすことでゲーム終了する．昼フェーズでは自由議論を行い多数決投票による追放対象が決定される．夜フェーズでは人狼の襲撃，占い師の占いが行われる．すべての人狼が追放された場合に村人陣営が勝利となり，人狼の数が村人と同数以上になった場合に，人狼陣営の勝利になる．

2.2 3 人人狼ゲーム

上記人狼ゲームの最もシンプルな構成が，3 人人狼である．人狼ゲームはその性質上，2 人では遊べない．本研究では，村人および占い師は村人陣営となり，人狼が人狼陣営となる 3 人人狼ゲームを扱った．本研究では簡易化のため，人狼ゲームにおける昼フェーズでは，各プレイヤーが一回しか発話できない．人狼が村人を襲撃することで昼フェーズに進む前にゲーム終了してしまうので，本研究では人狼が襲撃できない．一方，占い師に事前にどちらが狼であるかの情報を与えてゲーム開始することを定義するため，夜のフェーズが存在しない．占い師は，誰が人狼であるかをゲーム開始前に知っている．そのためいかなる状況であっても，占い師の追放先は必ず人狼である．従って，本研究で村人と人狼の投票先により，ゲーム結果は表1のとおりとなる．村人の選択が人狼投票になる場合に，村人側はかな

らず勝利する. 占い師に投票を 2 票集められる場合に人狼側が勝利する. これ以外の場合, ゲーム結果は引き分けとなる.

表1:ゲーム結果の分類

Villager's Vote	Werewolf's Vote	Game Result
Werewolf	Seer	Villager wins
Werewolf	Villager	Villager wins
Seer	Seer	Werewolf wins
Seer	Villager	Draw

3. シミュレーションの説明

3.1 会話の定義

人狼ゲームにおける最も難しい要素が, 会話の定義である. 人狼ゲームでは, 自由会話を行われている. シミュレーションでは自由会話の完全対応が難しい. 従って, 本研究で扱う会話形式は, 下記の 3 通りである.

- 「私は村人である」
- 「私は占い師であり, 左のプレイヤーが人狼であった」
- 「私は占い師であり, 右のプレイヤーが人狼であった」

3.2 シミュレーションの手続き

我々は以前の研究で提案した各プレイヤーが合理的な初期手[大澤 16]を設定された 3 人人狼の進化シミュレーションを行い, どのような戦略があるかどのような現象が起きるかを求めた. 手続きを図 1 に示す. 各プレイヤーはまず, 自身の内部状態から発言内容を決定する(genecode1). 入力となる内部状態は 2 種類であり, 発言は 3 種類である. 次に, 各プレイヤーは他のプレイヤーの 2 つの発言から, 自身の内部状態を更新する(genecode2). 他プレイヤーの各発言は 3 通りであるため, genecode2 の入力は 9 種類, 更新する内部状態は 2 種類となる.

進化されたエージェントの数により, 3 条件に分けて 7 種類の進化シミュレーションを行った. 各種類において, エージェントを 10000 世代に渡って進化させた. 各世代において, エージェントはランダムで 5000 試合を行う. 試合後, 勝率, 嘘をついた割合, 占い師として CO した割合の計算を行った. 各種類のシミュレーションを 100 回行い, その結果の平均値をとって分析を行った.

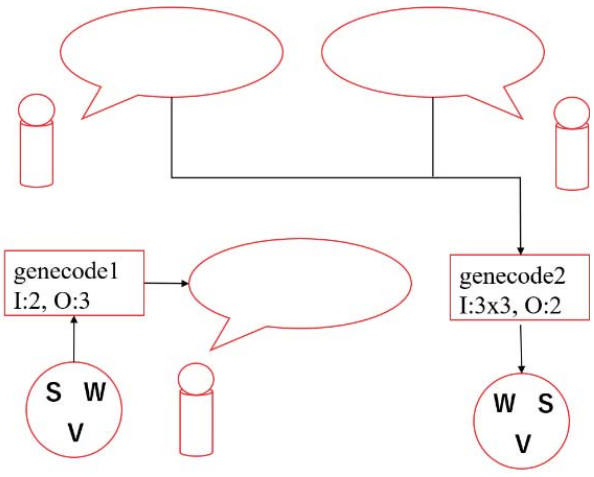


図1:シミュレーションのプロセス

4. 戦略の分類

本研究では, 占い師が嘘をついているかを予想することで村人と狼の戦略を, 「合理的(rational)」や「不合理的(irrational)」や「あいまい(ambiguous)」に分類した. 例えば, 占い師として CO したプレイヤーの発言内容を考え, 自分が村人として指されたらそのプレイヤーを占い師に考える場合に, 合理的な戦略である. それに対し, 狼に考える場合に, 不合理的な戦略である. 両方のプレイヤーの発話内容が同様である場合に, あいまいな戦略だと定義する.

表 2:村人の戦略分類

P1's talk			P2's talk				P0's status
P1	P2	P0	P2	P0	P1	D	
V			V			0	Ambiguous
						1	Ambiguous
S	V	W	V			0	Irrational
						1	Rational
S	W	V	V			0	Rational
						1	Irrational
V			S	V	W	0	Irrational
						1	Rational
S	V	W	S	V	W	0	Irrational
						1	Rational
S	W	V	S	V	W	0	Ambiguous
						1	Ambiguous
V			S	W	V	0	Rational
						1	Irrational
S	V	W	S	W	V	0	Ambiguous
						1	Ambiguous
S	W	V	S	W	V	0	Rational
						1	Irrational

表 3:人狼の戦略分類

P1's talk			P2's talk				P0's status
P1	P2	P0	P2	P0	P1	D	
V			V			0	Ambiguous
						1	Ambiguous
S	V	W	V			0	Irrational
						1	Rational
S	W	V	V			0	Ambiguous
						1	Ambiguous
V			S	V	W	0	Ambiguous
						1	Ambiguous
S	V	W	S	V	W	0	Irrational
						1	Rational
S	W	V	S	V	W	0	Ambiguous
						1	Ambiguous
V			S	W	V	0	Rational
						1	Irrational
S	V	W	S	W	V	0	Ambiguous
						1	Ambiguous
S	W	V	S	W	V	0	Rational
						1	Irrational

5. シミュレーションの結果分析

図2の通り, 人狼エージェントのみ進化しない場合には, 村人と占い師における言語の裏の意味を創り出した情報共有の手法が発生し, 99.2%の世代で上記の手法が用いられていた. 一方, 全エージェントを進化させる場合には, 全世代中, 上記の手法の発生率は 26.4%となる.

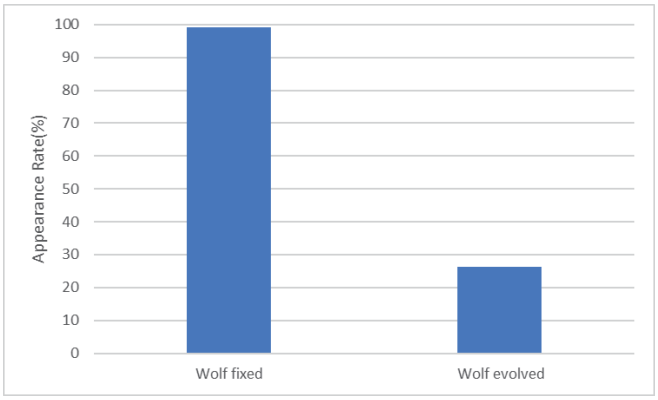


図 2:全世代における村人が「不合理的」な戦略を選択したゲーム勝利の状況の発生率

5.1 考察

結果より，予想していた占い師が嘘をつき，村人が不合理的な戦略を選んで村人と占い師における言語の裏の意味を創り出しの情報共有の手法が発生していた．村人陣営のみ進化する場合に，村人と占い師が互いに相手の思考モデルを学習でき，占い師が村人騙り，村人が村人騙りの占い師の正体を常に見つけて村人陣営の勝率を確保した．占い師は「私は村人である」に「私は占い師である」の意味を付け，村人が進化により，占い師の発話の裏の意味を解釈でき，協力者同士に情報を共有できた．人狼エージェントは進化しないため，常に占い師の発話の裏の意味を把握できず，村人と占い師における言語の裏の意味を創り出した情報共有の手法が 99.2%の世代に用いられていた．全エージェントが進化する場合に，狼が占い師の発話の裏の意味を解釈でき始め，村人と占い師のみの裏の情報共有は常に発生することがなかった．故に，26.4%の世代に上記の情報共有の手法が出現していた．狼は占い師と村人の裏の情報共有の手法を把握でき，占い師と同様に村人が騙り始め，占い師と村人の裏の情報共有を破壊した．しかし，占い師も狼に情報を共有しないため，ほかの発話内容に裏の意味を付け始め，再びに村人と情報を共有した．狼はその新たな意味を理解し，占い師はまた新しい意味を創り出すことで，エージェント同士でも人間と同じく，言語が進化する過程が発見できた．

6. おわりに

本研究では 3 人人狼ゲームのモデル化を行った後，エージェントにおける協力者同士に言語の裏の意味を創り出す情報共有の手法が出現するかについて，進化シミュレーションの手法を用いて戦略を分類し，分析を行った．分析結果より，村人陣営のみ進化する場合に，占い師は常に固定な言葉に裏の意味を創り出し，村人とのサブグループのみに情報を共有した．全エージェントが進化する場合に，占い師は一時的に村人のみと情報を共有していた．占い師は狼に情報を共有しないように新たな言葉を創り出し，エージェントのコミュニケーションにおいて人間と同じく言語の意味が進化した．

本研究は 3 人グループにおける上記の情報共有の手法について調べた．従って，グループに協力者と敵対者は各一人しかいない条件での分析となる．実世界には，グループ内で協力者と敵対者が複数人がいる状況がより一般的だと考えられるため，今後の課題としては，協力者と敵対者が多人数の条件で上記の情報共有の手法について調べたいと考えている．

謝辞

本研究は JSPS 科研費 26118006 および公益財団法人 人工知能研究振興財団の助成を受けたものです．

参考文献

[Katagami 14] Katagami, D., Takaku S., Inaba, M., Osawa, H., Shinoda, K., Nishino, J., and Toriumi F.: Investigation of the effects of nonverbal information on werewolf. In IEEE International Conference on Fuzzy Systems, pp. 982-987, (2014)

[Bi 16] Bi, X. and Tanaka, T.: Human-side strategies in the werewolf game against the stealth werewolf strategy. In Lecture Notes in Computer Science, Vol. 10068, pp. 93-102, (2016)

[Hung 10] Hung H. and Chittaranian G.: The Idiap Wolf Corpus: Exploring Group Behaviour in a Competitive Role-playing Game. In Proceedings of the 18th ACM International Conference on Multimedia, pp. 879-882, (2010)

[大澤 17] 大澤博隆，汪博豪，佐藤健：進化シミュレーションを用いた 3 人人狼の分析，日本ソフトウェア科学会第 34 回大会講演論文集，2017

[大澤 16] 大澤博隆，佐藤健：3者間人狼における戦略の検討，人工知能学会全国大会，2016，pp. 25-30

Oral presentation | Organized Session | [Organized Session] OS-13

[1H2-OS-13b] [Organized Session] OS-13

Tue. Jun 5, 2018 3:20 PM - 5:00 PM Room H (10F Sky Hall)

[1H2-OS-13b-01] Evaluation of topic n-gram model for the utterance of AIWolf agent

○Takashi OTSUKI[1] （1. Yamagata University）

3:20 PM - 3:40 PM

[1H2-OS-13b-02] Role Estimation in Werewolf BBS using Distributed Representation

Yurie Kimura[1], ○Tomonobu Ozaki[1] （1. Nihon University）

3:40 PM - 4:00 PM

[1H2-OS-13b-03] Natural Language Task in AI Werewolf Contest

○Yoshinobu Kano[1], Michimasa Inaba[2] （1. Shizuoka University, 2. Hiroshima City University）

4:00 PM - 4:20 PM

[1H2-OS-13b-a] Special program

4:20 PM - 5:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

人狼知能におけるトピック n-gram モデルの評価

Evaluation of topic n-gram model for the utterance of AIWolf agent

大槻 恭士
Takashi OTSUKI

山形大学 学術研究院
Academic Assembly, Yamagata University

AIWolf project presents "Are You a Werewolf?", the communication game with incomplete information, as a new standard game problem in the AI field. The project has also held competitions to realize the collective intelligence with participants. In recent competition, the champion agent uses the probabilistic model trained in advance. Therefore, it will be essential to utilize the more precise pre-trained models. In this article, we investigate the employment of topic n-gram model as the probabilistic model for the utterances generated by AIWolf agents. The evaluation of topic n-gram models of each role was carried out varying n from 1 to 4. It is shown that the perplexity of 2-gram model is far less than the one of 1-gram, and this concludes that we ought to use topic 2-gram model which brings good efficiency and robustness at the same time.

1. はじめに

人狼知能プロジェクト [aiwolf 2015] では，不完全情報コミュニケーションゲーム「人狼」を次なる人工知能の標準問題として提案している．特に，人狼をプレイする人狼知能エージェントの実現を目指すための集合知的アプローチとして，2015 年から毎年「人狼知能大会」を開催している．

開催当初は人間プレイヤーの戦術をそのまま実装したルールベースのエージェントが主流であったが，回を重ねるに従い，徐々に学習機能の実装が浸透し，直近の大会では単純ベイズモデルではあるが，事前に学習した確率モデルを用いて役職の推定を行うエージェントが優勝している．今後は，より精密な対戦相手モデルの構築が不可欠となることが予想される．

本稿では，人狼知能エージェントの発言生成モデルとしてトピックの n-gram モデルを用いることを検討する．なお，ここでの発言とは機械処理が容易な記号列である人狼知能プロトコル [狩野 2017] のことを指す．人狼知能プロトコルに準拠した発言にはトピックがあらかじめ付与されているため，自然言語処理と異なり発言からトピック列を容易に求めることが可能である．本稿では，各役職について 1-gram から 4-gram までのモデルを学習し，それらを perplexity で評価して考察する．

2. トピック n-gram モデルとその評価法

人狼知能エージェントをトピック列を生成する情報源と考え，以下のように記号を定義する．

U ：真のトピック列生成モデル

M ：トピック n-gram モデル

$t_i \quad (i = 1, 2, \cdots, K)$ ：K 種類のトピック

T_j ：トピック時系列の j 番目が t_{i_j} である事象

T ：長さ L のトピック時系列 $T_1 T_2 \cdots T_L$

$T_{j,k}$ ：T の部分列 $T_j T_{j+1} \cdots T_k$

連絡先: 大槻恭士，山形大学学術研究院，山形県米沢市城南 4-3-16，otsuki@yz.yamagata-u.ac.jp

トピック n-gram モデル M では，真の確率

$$P(T) = P(T_1)P(T_2|T_1)P(T_3|T_{1,2}) \cdots P(T_L|T_{1,L-1}) \quad (1)$$

を次式のように n 重マルコフモデルで近似する．

$$P_M(T) = P(T_1)P(T_2|T_1) \cdots P(T_i|T_{i-n+1,i-1}) \cdots P(T_L|T_{L-n+1,L-1}) \quad (2)$$

n-gram 確率 $P(T_i|T_{i-n+1,i-1})$ は大量のゲームログより抽出したトピック列より推定する．n を大きくすれば近似能力は高まるが，確率の推定精度を維持するのに必要なデータの量も増加し，ゼロ頻度問題に対処するための平滑化も重要になってくる（スパースネスの問題）．

U における 1 トピック当りのエントロピーは

$$H(U) = -\sum_{T \Leftarrow U} \frac{1}{L} P(T) \log_2 P(T) \quad (3)$$

で与えられる．ここで $T \Leftarrow U$ は T が U から生成されることを表す．また，1 トピック当りの M による U のクロスエントロピーは

$$H(M, U) = \lim_{L \to \infty} -\frac{1}{L} \log_2 P_M(T) \quad (4)$$

のように十分長いトピック列から推定できる．両者の間には

$$H(U) \leq H(M, U) \quad (5)$$

の関係があり，近似精度の高い M ほど $H(U)$ に近いことから，$H(M, U)$ の小ささにより M を評価することができる．

また，M によって次のトピックを決める際の平均分岐数

$$PP = 2^{H(M,U)} \quad (6)$$

は perplexity と呼ばれ，これが小さいほどトピックの予測が容易，すなわち高精度なモデルであることを意味している．

3. トピック n-gram モデルの学習とその評価

使用する発言トピックは，人狼知能プロトコルで定義されているものから通常は人狼以外には聞こえない「囁き」で発言される ATTACK(襲撃先宣言) を除いた 12 種に，ゲームの進行に関するイベント 3 種 (START, DAY, END) を加えた 15 種とする．これらを表 1 に示す．

第 3 回人狼知能大会決勝のゲームログ 37,000 ゲーム分をトピック列に変換し，役職別のトピック n-gram モデルを学習した．なお，平滑化手法としては，すべての n-gram の出現頻度に 1 を加算するラプラススムージングを便宜的に採用した．

学習に用いたトピック列より推定したクロスエントロピーから perplexity を求め，モデルを評価した．表 2 に各役職の 0-gram から 4-gram モデルについての perplexity を示し，図 1 に n に対する各モデルの perplexity の変化を示す．

0-gram モデルとは各トピックの出現確率を等確率とした，すなわち学習を行っていないモデルのことを指し，どの役職においても perplexity は分岐先になり得ない START を除いたトピックの種類数 14 となる．

トピックの出現確率を用いる 1-gram モデルの場合，村人，狩人，人狼の perplexity が他の役職より低い．狩人は黙って護衛を行うのが普通で，発言は村人と変わらないということが数字にも現れている．また，他の役職を騙ることが多い人狼の perplexity が村人並みに低いことも興味深い．能力者である占い師とそれを騙ることが多い裏切り者の perplexity が村人より 1 程度高いのは，トピック DIVINED の分と考えられ，霊媒師の perplexity が最も高いのも興味深い結果である．

トピック 2-gram モデルになると占い師，裏切り者，霊媒師の perplexity が激減し，1-gram から様相は逆転する．理由としては，これら 3 役職では関連する複数のトピックを続けて発言する（例：占い結果→投票宣言）機会が他の役職に比べ多いことが考えられる．

3-gram, 4-gram と考慮する長さが伸びるにつれて perplexity は減少する．しかし，1-gram から 2-gram に伸ばしたときの減少に比べるとはるかに緩やかである．

以上のことから，現在の人狼知能エージェントにおいて他者のモデルとしてトピック n-gram モデルを用いる場合，2-gram モデルを採用するのが妥当 [*1] であるといえる．

4. おわりに

人狼知能プロトコルを用いるエージェントであれば容易に利用可能なトピック n-gram モデルについて，役職ごとに n と perplexity の関係を調べ，考察を行った．その結果，最短でも 2-gram モデルを利用すべきであるという結論を得た．

今後，トピック n-gram モデルを用いるエージェントを作成し，その強さによる評価を行う予定である．その際には，トピックの設定や n などのモデル構造，学習用データの量，モデルの平滑化手法，モデルを用いた役職推定手法などについて検討する必要がある．

参考文献

[aiwolf 2015] 人狼知能プロジェクト, http://aiwolf.org/

[狩野 2017] 狩野芳伸, 大槻恭士, 園田亜斗夢, 中田洋平, 箕輪峻, 鳥海不二夫: 人狼知能で学ぶ AI プログラミング, 株式会社マイナビ出版 (2017)

*1 2018 年 3 月に開催された人狼知能プレ大会において，トピック 2-gram を用いたチームが優勝している．

表 1: 使用したトピック一覧

トピック (*はイベント)	説明
START*	ゲーム開始
DAY*	日付変更
END*	ゲーム終了
ESTIMATE	推測発言
COMINGOUT	カミングアウト
DIVINATION	占い先宣言
DIVINED	占い結果報告
IDENTIFIED	霊媒結果報告
GUARD	護衛先宣言
GUARDED	護衛結果報告
VOTE	投票先宣言
AGREE	同意発言
DISAGREE	不同意発言
OPERATOR	要望発言
SKIP	様子見

表 2: 役職 n-gram モデルと perplexity の関係

役職	0-gram	1-gram	2-gram	3-gram	4-gram
村人	14.0	4.98	2.94	2.71	2.47
占い師	14.0	6.51	2.55	2.28	2.19
霊媒師	14.0	7.10	3.02	2.67	2.45
狩人	14.0	5.14	2.97	2.70	2.45
裏切り者	14.0	6.17	2.43	2.13	2.07
人狼	14.0	5.16	3.08	2.69	2.44

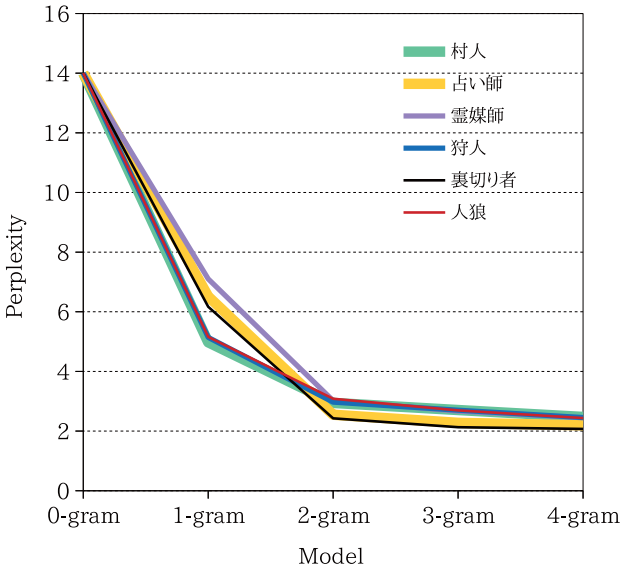


図 1: 役職 n-gram モデルと perplexity の関係

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

単語埋め込み技術を用いた人狼BBSにおける役職推定

Role Estimation in Werewolf BBS using Distributed Representation

木村 優里絵　　尾崎 知伸
Yurie Kimura　　Tomonobu Ozaki

日本大学 文理学部
College of Humanities and Sciences, Nihon University

The Werewolf game is a conversation-based multi-player incomplete information game. It is an important factor to estiate other players' role correctly to win the game. In order to improve the accuracy of the role estimation, in this paper, we propose to convert players utterances into real vectors by combining plural distributed representations. The effectiveness of the proposal is evaluated using log data in the Werewolf BBS.

1. はじめに

不完全情報ゲームの一つである人狼ゲーム [1, 2, 3] では，各プレイヤがそれぞれ役職を持ち，村人陣営と人狼陣営に分かれてゲームを行う．ゲームはプレイヤ間の会話を中心に進められる．各プレイヤは，会話の内容から他プレイヤの役職や陣営を推定するとともに，時には説得や騙しあいを行いながら，村人陣営は人狼を見つけ出し全滅させることを，人狼陣営は村人陣営を騙して襲撃することをそれぞれ目標とする．このため，他プレイヤの役職を正確に推定することはゲームをプレイする上で重要な要素となる．

人狼ゲームにおける役職推定に関しては，これまでにもいくつかの方向から研究が行われている．例えば文献 [4] では，潜在的ディリクレ配分法 (LDA)[5] を用いてトピック分析を行い，トピックごとの単語分布を用いて役職を推定する手法を提案している．一方文献 [6] は，分散表現技術 [7] の一つである word2vec[8, 9] を用いてプレイヤの発言をベクトル化する．また文献 [10] では，役職推定問題を制約充足問題の枠組みで定式化している．

これらの研究を踏まえ，本論文では，役職推定の更なる精度向上を目的とし，複数のベクトル表現と多様な集計方法を用いて各プレイヤの発言をベクトル化する手法を提案する．また人狼 BBS [*1] のログデータを対象に，種々の分類モデルを用いて提案手法を評価する．

2. 発言のベクトル化

2.1 概要

本論文では，1 日単位での役職推定を前提とする．すなわち，各プレイヤの 1 日の発言を一つのベクトルで表現し，役職推定の入力とする．

提案手法の全体像を図 1 にまとめる．また，全体の概要は以下の通りである．

1. 基本的な前処理として，各発言に含まれる半角カタカナを全角カタカタに，全角英数字を半角英数字に統一する．その後，形態素解析により名詞のみを抽出する．これにより，発言を単語集合（系列）に変換する．なお，出現数が閾値（30 回）未満の単語は排除している．
2. 単語集合である発言に対して LDA を適用し，そのトピック分布を求める．なお，予備実験の結果を踏まえ，トピック数は 20 とした．また，トピック分布を並べることで得られるベクトルを LDA による発言ベクトルと呼び，発言 U に対する発言ベクトルを $\overrightarrow{U}_{\mathrm{lda}}$ と表記する．
3. word2vec を用いて発言に含まれる単語のベクトル表現を求める．なお，先行研究 [6] に従い，次元数は 100，ウィンドウ幅は 5 とした．その後，得られた単語ベクトルを集約することで，word2vec による発言ベクトル $\overrightarrow{U}_{\mathrm{w2v}}$ および $\overrightarrow{U}_{\mathrm{ww2v}}$ を獲得する（詳細は後述する）．
4. 各プレイヤ毎に，1 日を単位に LDA 及び word2vec による発言ベクトルを集約し，最終的な日単位発言ベクトル $\overrightarrow{\mathrm{U}}^{\mathrm{Y}}_{\mathrm{X}}(X \in \{\mathrm{lda}, \mathrm{w2v}, \mathrm{ww2v}\}, Y \in \{\mathrm{mean}, \mathrm{median}, \mathrm{max}\})$ を得る（詳細は後述する）．
5. 日単位発言ベクトルを学習データとし，種々の分類モデルを用いて役職推定モデルを構築する．なお役職推定時には，人狼ゲームにおける明示的な制約を考慮した逐次決定 [6] を適用する．

以下，単語ベクトルの集約による発言ベクトルの獲得および発言ベクトルの集約による日単位発言ベクトルの獲得について説明する．

2.2 単語ベクトルの集約による発言のベクトル化

word2vec により得られた単語 w に対するベクトルを $\overrightarrow{w}$ と表記する．また，単語の集合である発言を $U = \{w_1, \cdots, w_{|U|}\}$ と表記する．本論文では，発言 U に対するベクトル表現 $\overrightarrow{U}$ の獲得に関し，下記の 2 種類の単語ベクトル集約手法を考える．

第一の手法は，U を構成する単語のベクトル $\overrightarrow{w}$ の（次元ごとの）平均値を U に対するベクトルとする手法である．すなわち

$$\overrightarrow{U}_{\mathrm{w2v}} = \frac{1}{|U|} \sum_{w \in U} \overrightarrow{w}$$

である．

連絡先: 尾崎 知伸，日本大学 文理学部 情報科学科，〒 156-8550 東京都世田谷区桜上水 3-25-40，tozaki@chs.nihon-u.ac.jp

*1 http://www.wolfg.x0.com/

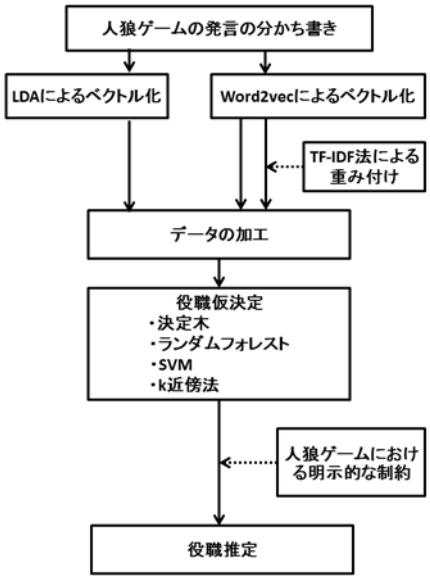


図 1: 役職推定の流れ

第二の手法は，各単語ベクトル $\overrightarrow{w}$ の TF-IDF 法による重み付き平均を U に対するベクトルとする．

$$\overrightarrow{U}_{\mathrm{ww2v}} = \frac{1}{|U|}\sum_{w\in U}\frac{n(w,U)}{\sum_{w_i\in U} n(w_i,U)} \times \log\frac{N}{df(w,U^N)} \times \overrightarrow{w}$$

ここで，$n(w,U)$ は文書 U における w の出現回数である．また $df(w,U^N)$ は，他プレイヤを含めた U の直近 N 発言のうち，単語 w を含む発言数である（今回は $N=10$ としている）．TF-IDF 法を用いて，直前の発言集合に対する特徴的な単語を重視するとともに多くの発言で頻繁に利用される単語の影響を抑制することで，より発言の特徴を捉えたベクトルの獲得が期待できる．

2.3 発言ベクトルの日単位発言ベクトルへの集約

各プレイヤは一般に，1 日に複数の発言を行うので，これらを集約し日単位発言ベクトルを生成する．本論文では，あるプレイヤのある一日における発言の集合 $\mathbb{U}$ に対し，下記の 3 つの集約手法を準備した．

平均値： 各発言ベクトルの平均値 $\overrightarrow{\mathbb{U}}^{\mathrm{mean}}_{\mathrm{X}} = \frac{1}{|\mathbb{U}|}\sum_{\overrightarrow{U}_{\mathrm{X}}\in\mathbb{U}}\overrightarrow{U}_{\mathrm{X}}$ を日単位発言ベクトルとする．

中央値： 例外的な値を考慮する目的で，各発言ベクトルの中央値 $\overrightarrow{\mathbb{U}}^{\mathrm{median}}_{\mathrm{X}} = \widetilde{\overrightarrow{U}_{\mathrm{X}}}$ を採用する．

最大値： 値が大きいベクトルは発言の特徴をより表していると考え，各発言ベクトルの最大値 $\overrightarrow{\mathbb{U}}^{\mathrm{max}}_{\mathrm{X}} = \max_{\overrightarrow{U}\in\mathbb{U}}\overrightarrow{U}_{\mathrm{X}}$ を用いる．

3. 評価実験

実験では，人狼 BBS の G 国に含まれる 1,439 ゲームの白ログ（発話総数 1,274,649）を対象とし，全体の 70%を学習データ，10%を評価データ，20%をテストデータとして利用した．$X\in\{\mathrm{lda},\mathrm{w2v},\mathrm{ww2v}\}$ と $Y\in\{\mathrm{mean},\mathrm{median},\mathrm{max}\}$ の全組み合わせである 9 種類の日単位発言ベクトル $\overrightarrow{\mathbb{U}}^{\mathrm{Y}}_{\mathrm{X}}$ に加え，

表 1: 手法毎の F 値

	DT	RF	SVM	2-NN	15-NN	平均
$\overrightarrow{\mathbb{U}}^{\mathrm{mean}}_{\mathrm{lda}}$	0.309	0.333	0.314	0.299	0.271	0.305
$\overrightarrow{\mathbb{U}}^{\mathrm{mean}}_{\mathrm{w2v}}$	0.270	0.152	0.319	0.171	0.251	0.233
$\overrightarrow{\mathbb{U}}^{\mathrm{mean}}_{\mathrm{tfidf}}$	0.376	0.246	0.122	0.135	0.176	0.211
$\overrightarrow{\mathbb{U}}^{\mathrm{mean}}_{\mathrm{lda+w2v}}$	0.282	0.190	0.286	0.209	0.305	0.254
$\overrightarrow{\mathbb{U}}^{\mathrm{mean}}_{\mathrm{lda+ww2v}}$	0.271	0.182	0.202	0.280	0.243	0.236
$\overrightarrow{\mathbb{U}}^{\mathrm{median}}_{\mathrm{lda}}$	0.291	0.309	<u>0.380</u>	0.291	0.262	0.307
$\overrightarrow{\mathbb{U}}^{\mathrm{median}}_{\mathrm{w2v}}$	0.371	0.203	0.090	0.369	0.200	0.247
$\overrightarrow{\mathbb{U}}^{\mathrm{median}}_{\mathrm{tfidf}}$	<u>0.382</u>	0.199	0.089	0.343	0.276	0.258
$\overrightarrow{\mathbb{U}}^{\mathrm{median}}_{\mathrm{lda+w2v}}$	0.323	0.201	0.089	<u>0.391</u>	0.199	0.241
$\overrightarrow{\mathbb{U}}^{\mathrm{mean}}_{\mathrm{lda+ww2v}}$	0.337	0.213	0.199	0.323	0.247	0.264
$\overrightarrow{\mathbb{U}}^{\mathrm{max}}_{\mathrm{lda}}$	0.269	0.315	0.319	0.292	0.268	0.293
$\overrightarrow{\mathbb{U}}^{\mathrm{max}}_{\mathrm{w2v}}$	0.289	0.299	0.338	0.334	0.359	0.324
$\overrightarrow{\mathbb{U}}^{\mathrm{max}}_{\mathrm{tfidf}}$	0.288	0.290	0.183	0.309	0.316	0.277
$\overrightarrow{\mathbb{U}}^{\mathrm{max}}_{\mathrm{lda+w2v}}$	0.296	0.298	0.346	0.343	<u>0.363</u>	0.329
$\overrightarrow{\mathbb{U}}^{\mathrm{max}}_{\mathrm{lda+ww2v}}$	0.293	<u>**0.394**</u>	0.322	0.286	0.257	0.310
$\overrightarrow{\mathbb{U}}$	0.310	0.255	0.240	0.292	0.266	0.272
$\overrightarrow{\mathbb{U}}_{\mathrm{lda}}$	0.290	0.319	0.338	0.294	0.267	0.301
$\overrightarrow{\mathbb{U}}_{\mathrm{w2v}}$	0.310	0.218	0.249	0.291	0.270	0.268
$\overrightarrow{\mathbb{U}}_{\mathrm{ww2v}}$	0.349	0.245	0.131	0.262	0.256	0.249
$\overrightarrow{\mathbb{U}}_{\mathrm{lda+w2v}}$	0.300	0.230	0.240	0.314	0.289	0.275
$\overrightarrow{\mathbb{U}}_{\mathrm{lda+ww2v}}$	0.300	0.263	0.241	0.296	0.249	0.270
$\overrightarrow{\mathbb{U}}^{\mathrm{mean}}$	0.302	0.221	0.249	0.219	0.249	0.248
$\overrightarrow{\mathbb{U}}^{\mathrm{median}}$	0.341	0.225	0.169	0.343	0.237	0.263
$\overrightarrow{\mathbb{U}}^{\mathrm{max}}$	0.287	0.319	0.302	0.313	0.313	0.307

LDA によるベクトルと word2vec によるベクトルを連結した $\overrightarrow{\mathbb{U}}^{\mathrm{Y}}_{\mathrm{lda+w2v}}$ 及び $\overrightarrow{\mathbb{U}}^{\mathrm{Y}}_{\mathrm{lda+ww2v}}$ の 6 種類の計 15 種類を対象に比較を行う．また分類器として，決定木 (DT)，ランダムフォレスト (RF)，サポートベクトルマシン (SVM)，K-近傍法 (2-NN および 15-NN) を用いる．なお最終的な役職の推定には，文献 [6] で提案された逐次決定と同様の方法を用い，ルール上の制約（占い師・霊媒師・狩人・狂人は各 1 名以下，人狼は 3 名以下かつ生存プレイヤの半数未満）を満たすように調整を行う．

実験結果として，(重み付き）F 値を表 1 に示す．表中において，下線は各分類器での最良値を表す．また，$\overrightarrow{\mathbb{U}}_{\mathrm{X}}$ は発言ベクトル作成方法 $X\in\{\mathrm{lda},\mathrm{w2v},\mathrm{ww2v}\}$ 毎の平均を表す．同様に $\overrightarrow{\mathbb{U}}^{\mathrm{mean}}$，$\overrightarrow{\mathbb{U}}^{\mathrm{median}}$，$\overrightarrow{\mathbb{U}}^{\mathrm{max}}$ は，日単位発言ベクトルへの集計時に平均値，中央値，最大値を利用した場合の平均を表す．$\overrightarrow{\mathbb{U}}$ は手法全体の平均である．なお平均列は，各分類器の F 値の平均である．

実験結果より，(分類器上での）平均という点では，$\overrightarrow{\mathbb{U}}_{\mathrm{lda}}$ の 0.301，$\overrightarrow{\mathbb{U}}^{\mathrm{max}}$ の 0.307，$\overrightarrow{\mathbb{U}}^{\mathrm{max}}_{\mathrm{lda+w2v}}$ の 0.329 がそれぞれの範囲で最良であった．また，全体を通じての最良値は，$\overrightarrow{\mathbb{U}}^{\mathrm{max}}_{\mathrm{lda+ww2v}}$ と RF の組み合わせの 0.394 であった．この結果より，LDA によるベクトルと重みを考慮した word2vec によるベクトルを併用することの有用性，また日単位への集計において最大値を取ることの効果が確認できる．

第二の結果として，日単位発言ベクトルへの集計方法として

最大値を利用した場合の各役職毎の再現率，適合率，F 値を表 2 に示す．表中において，下線は役職内での最良値を表す．表から，村人に関しては再現率と適合率がともに高いことが分かる．また概ね，村人，霊媒師，人狼，狂人，占い師，狩人の順で，予測精度が高いことが分かる．占い師と狩人に関しては，再現率，適合率が共に低いが，これは，狩人はその役職の立場から自分の役職を明かさず 村人の中に隠れる傾向にあり，また占い師は人狼や狂人に騙られることが多い役職であるためと考えられる．一方，狂人に関しては，再現率は高いものの，適合率が極端に低く，正確に当てることが難しい役職であることが分かる．

4. まとめと今後の課題

本論文では，単語埋め込み技術を用いて人狼 BBS の発言をベクトル化し，役職推定を行う手法を提案した．既存研究 [4, 6] と比較し必ずしも高い精度は得られなかったが，今回提案した TF-IDF による重みを考慮した集約手法や，最大値を利用した日単位発言ベクトルへの集約，LDA と word2vec の併用が有効であることを確認した．

今後の課題としては，役職予測精度の更なる向上を目指し，各役職に特有な知識・視点の利用や，処刑・襲撃による役職構成の変化を考慮した逐次決定の導入などが挙げられる．

参考文献

[1] 鳥海 不二夫，片上 大輔，大澤 博隆，稲葉 通将，篠田 孝祐，狩野 芳伸 :『人狼知能』，森北出版，2016.

[2] 狩野 芳伸，大槻 恭士，園田 亜斗夢，中田 洋平，箕輪 峻，鳥海 不二夫（著），人狼知能プロジェクト（監修）:『人狼知能で学ぶ AI プログラミング』，マイナビ出版，2017.

[3] G. Chittaranjan and H. Hung : Are you a werewolf? Detecting deceptive roles and outcomes in a conversational role-playing game, *2010 IEEE International Conference on Acoustics, Speech and Signal Processing*, pp.5334–5337, 2010.

[4] 荒木 大輔，鳥海 不二夫，菅原俊治 : トピックモデルを用いた人狼ゲームの会話に基づく役職別のプレイヤ推定法，情報処理学会第 79 回全国大会, pp.481–482, 2017.

[5] D. Blei, A. Ng, and M. Jordan : Latent Dirichlet Allocation, *Journal of Machine Learning Research*, Vol.3, No.3/1/2003, pp.993–1022, 2003.

[6] 阪本 真基，上野敦志，田窪朋仁 : プレイヤの発言に基づいた人狼ゲームの役職推定，情報処理学会研究報告ゲーム情報学 (GI), Vol.2016-GI-35, No.12, pp.1–6, 2016.

[7] Y. Bengio, A. Courville and P. Vincent : Representation Learning: A Review and New Perspectives, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.35, No.8, pp.1798–1828, 2013.

[8] T. Mikolov, K. Chen, G. Corrado and J. Dean : Efficient Estimation of Word Representations in Vector Space, arXiv preprint, arXiv:1301.3781, 2013.

[9] T. Mikolov, I. Sutskever, K. Chen, G. S. Corrado and J. Dean : Distributed Representations of Words and Phrases and their Compositionality, *Advances in Neural Information Processing Systems 26*, pp.3111–3119, 2013.

[10] 林 友超，呉 双，板東 勇樹，宇津呂 武仁 : 制約充足による人狼ゲームの役職絞り込み，人工知能学会第 31 回全国大会，1N1-1in2, 2017.

表 2: 役職毎の再現率，適合率，F 値

	再現率					適合率					F 値				
	DT	RF	SVM	2-NN	15-NN	平均	DT	RF	SVM	2-NN	15-NN	平均	DT	RF	SVM	2-NN	15-NN	平均
村人																		
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{lda}}$	0.381	0.457	0.481	0.442	0.391	0.430	0.527	0.542	0.556	0.531	0.528	0.537	0.442	0.496	0.515	0.483	0.449	0.470
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{w2v}}$	0.421	0.433	0.500	0.512	0.596	0.492	0.526	0.521	0.539	0.510	0.507	0.521	0.468	0.473	0.519	0.511	0.548	0.504
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{ww2v}}$	0.426	0.407	0.182	0.487	0.500	0.400	0.528	0.530	0.524	0.519	0.521	0.524	0.472	0.460	0.270	0.502	0.510	0.443
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{lda+w2v}}$	0.447	0.436	0.518	0.566	0.622	0.518	0.530	0.537	0.540	0.517	0.521	0.529	0.485	0.481	0.529	0.540	0.567	0.520
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{lda+ww2v}}$	0.437	0.640	0.493	0.432	0.371	0.475	0.527	0.527	0.545	0.524	0.528	0.530	0.477	0.578	0.518	0.474	0.436	0.497
占い師																		
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{lda}}$	0.075	0.072	0.194	0.074	0.071	0.097	0.066	0.088	0.135	0.069	0.060	0.084	0.071	0.079	0.159	0.072	0.065	0.089
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{w2v}}$	0.092	0.021	0.025	0.028	0.017	0.037	0.080	0.048	0.064	0.075	0.059	0.065	0.086	0.029	0.036	0.041	0.027	0.044
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{ww2v}}$	0.079	0.055	0.016	0.035	0.034	0.044	0.064	0.069	0.070	0.070	0.081	0.071	0.071	0.061	0.026	0.047	0.048	0.051
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{lda+w2v}}$	0.057	0.034	0.097	0.044	0.063	0.059	0.058	0.084	0.098	0.057	0.057	0.071	0.057	0.049	0.098	0.049	0.060	0.063
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{lda+ww2v}}$	0.097	0.027	0.141	0.077	0.094	0.087	0.085	0.061	0.102	0.067	0.075	0.078	0.091	0.038	0.118	0.072	0.083	0.080
霊媒師																		
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{lda}}$	0.084	0.070	0.143	0.090	0.093	0.096	0.083	0.097	0.145	0.081	0.086	0.098	0.084	0.081	0.144	0.085	0.090	0.097
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{w2v}}$	0.085	0.054	0.133	0.033	0.014	0.064	0.075	0.100	0.140	0.058	0.049	0.084	0.080	0.070	0.136	0.042	0.022	0.070
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{ww2v}}$	0.078	0.093	0.240	0.055	0.072	0.108	0.075	0.179	0.209	0.083	0.127	0.135	0.077	0.122	0.223	0.066	0.092	0.116
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{lda+w2v}}$	0.101	0.064	0.195	0.073	0.057	0.098	0.088	0.129	0.168	0.097	0.107	0.118	0.094	0.086	0.180	0.083	0.074	0.103
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{lda+ww2v}}$	0.060	0.044	0.226	0.089	0.106	0.105	0.065	0.166	0.185	0.086	0.097	0.120	0.063	0.070	0.203	0.087	0.102	0.105
狩人																		
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{lda}}$	0.085	0.060	0.079	0.070	0.083	0.075	0.073	0.074	0.077	0.061	0.068	0.071	0.079	0.066	0.078	0.066	0.075	0.073
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{w2v}}$	0.070	0.008	0.051	0.083	0.053	0.053	0.072	0.097	0.058	0.068	0.052	0.069	0.071	0.002	0.054	0.075	0.052	0.051
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{ww2v}}$	0.050	0.016	0.002	0.073	0.089	0.046	0.043	0.110	0.154	0.062	0.069	0.088	0.046	0.028	0.003	0.067	0.078	0.044
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{lda+w2v}}$	0.063	0.012	0.058	0.065	0.084	0.056	0.069	0.067	0.052	0.065	0.073	0.065	0.066	0.020	0.055	0.065	0.078	0.057
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{lda+ww2v}}$	0.057	0.004	0.032	0.065	0.075	0.047	0.058	0.069	0.055	0.063	0.064	0.062	0.057	0.008	0.041	0.064	0.069	0.048
狂人																		
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{lda}}$	0.213	0.196	0.213	0.205	0.236	0.213	0.058	0.074	0.070	0.065	0.065	0.066	0.089	0.107	0.144	0.099	0.102	0.108
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{w2v}}$	0.084	0.233	0.084	0.138	0.122	0.132	0.056	0.057	0.061	0.066	0.061	0.060	0.080	0.092	0.136	0.089	0.081	0.096
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{ww2v}}$	0.488	0.247	0.488	0.196	0.215	0.327	0.063	0.058	0.055	0.056	0.060	0.058	0.089	0.093	0.223	0.088	0.093	0.117
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{lda+w2v}}$	0.057	0.270	0.057	0.138	0.117	0.128	0.062	0.057	0.074	0.060	0.064	0.063	0.092	0.095	0.180	0.083	0.082	0.106
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{lda+ww2v}}$	0.215	0.092	0.215	0.212	0.283	0.203	0.055	0.064	0.064	0.063	0.066	0.062	0.079	0.076	0.203	0.097	0.107	0.112
人狼																		
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{lda}}$	0.195	0.231	0.116	0.151	0.144	0.167	0.210	0.221	0.225	0.232	0.226	0.223	0.203	0.226	0.153	0.183	0.176	0.188
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{w2v}}$	0.195	0.241	0.261	0.227	0.166	0.218	0.225	0.218	0.213	0.245	0.231	0.226	0.209	0.229	0.234	0.236	0.193	0.220
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{ww2v}}$	0.196	0.232	0.183	0.154	0.123	0.178	0.218	0.216	0.224	0.236	0.242	0.227	0.207	0.224	0.202	0.186	0.163	0.196
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{lda+w2v}}$	0.165	0.215	0.219	0.132	0.086	0.163	0.219	0.216	0.219	0.238	0.247	0.228	0.188	0.215	0.219	0.170	0.127	0.184
$\overrightarrow{\mathrm{U}}^{\max}_{\mathrm{lda+ww2v}}$	0.202	0.233	0.097	0.150	0.119	0.160	0.213	0.223	0.247	0.219	0.222	0.225	0.208	0.228	0.139	0.178	0.155	0.182

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

人狼知能大会第一回自然言語部門の開催

Natural Language Task in AI Werewolf Contest

狩野　芳伸[*1]
Yoshinobu Kano

稲葉　通将[*2]
Michimasa Inaba

[*1] 静岡大学
Shizuoka University

[*2] 広島市立大学
Hiroshima City University

We report the first Natural Language Task in the AI Werewolf Contest of the AI Werewolf project. In this task, participants are required to create an agent system that plays the conversation game “Mafia” in Japanese text. We show statistical and subjective evaluation results of automatic play within agents and with a human, discussing future possibility of this task.

1. はじめに

近年、対話システムの利用が注目を集めている。従来多く見られたタスク指向型対話システムに加え、いわゆる雑談的な対話を行う非タスク指向型対話システムも多くみられる。対話システムが必要とする要素はテキスト入出力に限ったとしても、語彙、構文から意味、論理まで、完成度を上げていくと最終的にほとんどあらゆる知的要素が必要となろう。

人狼ゲームは基本的に制約のない会話を通じてのみ行うゲームであり、対話システムに必要な要素を包含している。一方で人狼ゲームを題材にすることは、ゲームの勝敗という目的があるために状況を限定しつつ一歩一歩研究を進めうるという利点がある。本稿では、対話システムの発展に寄与する研究の切り口として、会話ゲーム「人狼」のプレイヤー自動化を試みる人狼知能大会における、自然言語を用いる部門の第一回大会開催とその結果について述べる。なお、全国大会に合わせて第二回のプレ大会開催を企画しており、結果を全国大会のオーガナイズドセッション「不完全情報ゲームと人狼知能」内で発表予定である。

2. 人狼ゲーム

2.1 人狼ゲームの設定

人狼ゲームは数名～十数人程度のプレイヤーで行うゲームである。各プレイヤーは村人陣営と人狼陣営に分かれてそれぞれの陣営の勝利を目指す。ゲーム開始前に所属陣営を決定するが、基本的に村人には他プレイヤーの所属陣営は公開されない。村人陣営の目的は人狼をすべて見つけ出し追放(ゲームから排除)することで、人狼陣営の目的は村人を食べ尽くす(ゲームから排除する)ことである。

人狼陣営のプレイヤーは排除されないよう、村人陣営の振りをすることになる。プレイヤーは基本的に会話のみを通じてお互いの正体を探るが、何の情報も無い状態では人狼側が有利になりすぎるため、村人側に有利な特殊能力を持ったいくつかの「役職」が主に村人側に用意されている。ゲームの設定により異なるが、一日一人だけ指定したプレイヤーが「人狼かどうか」を知ることができる(ただし本人以外にはそれが真かどうか、占ったかどうかも知らされない)「占い師」、人狼陣営だが自身は人狼が誰だかを知らず、能力も持たないため、場を混乱させることによって人狼陣営に貢献することの多い「裏切者」などがある。

連絡先:狩野　芳伸、静岡大学情報学部行動情報学科、静岡県浜松市中区城北 3-5-1、kano@inf.shizuoka.ac.jp

2.2 人狼ゲームの流れ

ゲームは「一日」を基準とするターンを繰り返す。一日の前半を「昼」と呼び、プレイヤーは決められた時間、自由に会話を行う。後半を「夜」と呼び、ゲームから排除するプレイヤーを投票によって決定する。村人陣営は人狼陣営のプレイヤーを排除しようとし、人狼陣営のプレイヤーは村人陣営のプレイヤーを排除しようとするだろうが、表面上はあくまで「人狼と思われる人」を排除するための投票になる。最大得票を得たプレイヤーはゲームから排除(「追放」)される。

次に、全プレイヤーが顔を伏せた状態で、司会者が様々な役職のプレイヤーに声をかけ、声をかけられたプレイヤーはジェスチャーなどで他のプレイヤーにわからないよう、特殊能力に従った行動をとる。 例えば、人狼はゲームから排除するプレイヤーを一人決定する(「襲撃」)。

ここまでが「一日」のターンで、これをどちらかの陣営が勝利条件を満たすまで繰り返す。プレイヤーの勝敗は所属陣営の勝敗できまるので、途中で排除されたかどうかはプレイヤーの勝敗に直接関係がない。村人陣営の勝利条件は「すべての人狼を排除する」こと、人狼陣営の勝利条件は「人狼以外のプレイヤーの数を人狼の数と同数またはそれ未満にする」ことである。

人狼ゲームは元々ロシアで遊ばれていたゲームでマフィアと呼ばれていた。それがアメリカで商品化され、日本でも「汝は人狼なりや」「タブラの狼」などいくつかのゲームセットが発売されている。現在では、インターネット越しに掲示板形式で人狼ゲームを長期にわたって行う BBS 人狼、短期間で行う短期人狼などがある。人狼をプレイする人口は現在増え続けているが、上の年代になるにつれて知名度は減少しており、若者世代に人気のゲームであると言えよう。

3. 人狼知能プロジェクトと人狼知能大会

3.1 人狼知能プロジェクト

人狼知能プロジェクト[1][2][3][4]では、人狼知能プロトコルと対戦用の人狼知能サーバの情報を公開することで、多く研究者や開発者がエージェントの作成に参加できる環境を整えてきた。

将棋やチェスなど盤面上にすべての情報が開示される完全情報ゲームとは異なり、人狼は不完全情報ゲームである。この特徴と、人狼が基本的に会話を通じてのみ行われるということが、プレイヤーの自動化という視点でとらえたときに特有の興味深い研究テーマを生み出している。

まず、状況判断がプレイヤーの言動に依存するため、おおくの局面で本質的に「正解」を知りえず、「推理」が必要である。推理する際にも、他プレイヤーの意図をモデル化するという高度な作業が必要となる。こうした推理やモデルの上に、人狼陣営はいやおうなく「嘘をついて騙す」ことが求められる一方、村人陣営はそえを「見破る」必要がある。これは見方を変えると、いかに他者を「説得」し「信頼を得る」かということでもある。

さらに、実際のゲームでは表情や音声、ジェスチャーなど非言語情報も大きな役割を果たす。すなわち、人狼プレイヤーの構築の研究は、人工知能を中心に、自然言語、対話、音声、心理学、エージェントなど多様な関連分野の研究とその統合が必要となる挑戦的な課題といえる。実際、人狼知能プロジェクトのオーガナイザーはそうした異なる分野から様々なアプローチで研究を進めている。

4. 人狼知能大会の自然言語部門

2017 年の大会より、従来のプロトコル部門に加え自然言語処理部門のタスクを開催した。プレ大会を GAT (Game AI Tournament) 2017 において、本大会を CEDEC (Computer Entertainment Developers Conference) 2017 において開催、結果の発表を行った。以下では本大会について述べる。

当面の現実的な目標としては、会話を通じたゲームが成立したといえるレベルを達成することである。既存の（雑談）対話システムそのままではシステム間の対話がほとんど成立しないであろう。実際の人狼ゲームでは雑談的な会話も頻繁に発生し、そこからある種の推理を行うこともあるが、自然言語部門ではまずはゲーム勝敗に直結する会話が中心となり、自然と使用する語彙も限定されある程度の意思疎通が可能ではないかと期待している。エージェント内でプロトコルを中間言語的に利用することも考えられる。

4.1 自然言語部門の設定

(1) 人狼ゲームの設定

対話に重点をおき分析や実装を容易にするためプレイヤー数が 5 の 5 人人狼とし、ゲーム当たりのターン数も少なくなっている。役職の内訳は占い師 1、人狼 1、裏切り者 1、村人 2 である。5 人人狼では日数が短く、役職の推測に利用できる情報が少ないのが特徴で、偶然の要素も大きい。

初日（0 日目）は特にゲーム情報を与えない。挨拶などを行うことを想定している。初日の夜（夜は会話以外のゲーム進行処理が行われる）は占いのみを行い、投票と襲撃はない。

1 日目以降は、20 ターン経過するか、全員が over という特別な応答を返すまで 1 日の昼が継続する。人狼知能サーバは同期式で通信を行っており、各エージェントから 1 発話ずつ収集してこれを 1 ターンと呼んでいる。エージェントから見ると 1 ターンは同時の発話であり、前ターンまでの発話情報しか参照できない。発話をしない skip という特別な応答も利用できる。

投票での得票一位が複数あったときは、単独一位が得られるまで投票を繰り返す。

(2) システムと対戦形式

枠組みとしては従来の人狼知能サーバを流用し、投票などゲーム特有のアクションについては従来通りとしつつ、プロトコルを用いていた「会話」に相当する部分はすべて自然言語（句読点・感嘆符・疑問符以外の記号を含まない日本語テキスト）のみとした。例外として特定のエージェントに対する発話を示せるよう、発話冒頭に「>>Agent[01] 発話本文...」という形のアンカー付与オプションを許した。アンカー自体は発話の一部とはみなさない。

```
1,talk,1,0,4,私は占い師だよ
1,talk,2,0,3,ぼくは占い師。Agent[02]の結果は黒だったよ。
1,talk,3,0,1,Skip
1,talk,4,0,2,俺は占い師だぜ
1,talk,5,1,5,Skip
1,talk,6,1,4,いや、そうは思わないな。
1,talk,7,1,1,僕は占い師だよ。
1,talk,8,1,3,Agent[02]はみんなを騙そうとしてるね。
1,talk,9,1,2,Agent[01]を占った結果人狼だったぜ
1,talk,10,2,5,Over
1,talk,11,2,2,Skip
1,talk,12,2,3,嘘は良くないよ、Agent[01]。
（凡例:日,アクション種別,発言 ID,ターン数,エージェント ID,
発話文字列）
```

図 1. 異種エージェント同士の相互対戦のログ抜粋例

アンカーに限らず、発話内でエージェントを指す際は「Agent[xx]」という形式で表わすこととした。

ネットワーク経由で対戦サーバに接続するリモート対戦を採用し、実装や計算資源は参加者が自由にできるものとした。また、発話リクエストから応答までの制限時間を 5 秒とした。

対戦方法は 3 通りを設定した。ひとつは、同一エージェントを 5 体用意して戦わせる自己対戦である。ふたつめは、5 種類の異なるエージェントを対戦させる相互対戦である。三つめは、4 種類の異なるエージェントと 1 名の人間を混在させて行う対人対戦である。機械同士の対戦は事前に自動的に行ってログを収集し、対人対戦は大会当日にリアルタイムで行った。図 1 に相互対戦のログ抜粋例を示す。



図 2. アバター表示によるプレイ画面の例

対戦表示用の UI として、宝塚大学東京メディア芸術学部渡邉研究室に表情や姿勢の変化するモーション付きアバターを作成いただき、大会当日にはこれを用いたデモンストレーションも行った（図 2）。

4.2 自然言語部門の評価メトリクス

(1) 勝敗率

人狼ゲームは属する陣営ごとに明確に勝敗が決定できる。エージェント間で十分に「意思疎通」がとれているのであれば、勝敗率は言語解析および生成の正確さとゲーム戦略の性能を総合した評価値となりうる。エージェントの実装は役職ごとに異なることが多いため、役職ごと、および全体で勝敗数をカウントし相互対戦による評価を行った。試合数はエージェントあたり 120 ゲームである。表 1 に本大会における勝敗数と勝敗率を示す。

チーム	村人	占い師	裏切者	人狼	総合
AITWolf	24/48 (0.50)	10/24 (0.42)	8/24 (0.33)	7/24 (0.29)	49/120 (0.41)
KELDIC	26/48 (0.54)	14/24 (0.58)	9/24 (0.38)	12/24 (0.50)	61/120 (0.51)
m_cre	14/24 (0.58)	18/24 (0.75)	16/24 (0.67)	16/24 (0.67)	83/120 (0.69)
forst	23/48 (0.48)	14/24 (0.58)	7/24 (0.29)	11/24 (0.46)	55/120 (0.46)
Kanolab	28/48 (0.58)	11/24 (0.46)	13/24 (0.54)	7/24 (0.29)	59/120 (0.49)

表 1. 各参加チームの相互対戦における役職ごとおよび全体の勝敗数と勝敗率

(2) 主観評価

勝敗率はわかりやすい評価尺度であるが、実際には人狼はチームプレイであること、対戦相手のレベルや振る舞いによって同じエージェントでも勝敗率の変動がありうることに注意が必要である。これらいずれの点も、そもそもきちんと「意思疎通」がとれているかが問題であり、そうでなければ勝敗率は対話とは関係のない部分で決定されている可能性もある。そのため、対話システムの評価としては勝敗率はまだ参考程度にみなすべき値であると考えられる。

一般に対話システムの評価は「対話が成立しているようにみえる」という表層的なものになりがちで、結果ある種の逃げに走るほうが良い評価を得られることも多い。人狼知能においては、会話に制約がないと同時にゲームを成立させ勝利に導くという目標があるため、表層的な発話に終始しては内容の一貫したふるまいにならず不自然に映るだろう。そのため適切な項目を設けた主観評価によって、より本質的な要素に高得点をつける評価が可能ではないかと考える。対話システムの評価にとどまらず、人狼ゲーム自体も勝ち負けだけでなく「面白いプレイ」であったかが重要であり、勝敗以外の評価軸をどう設定するかが研究テーマの一つである。

本大会では、下記 A～E の 5 つの主観評価項目を設定し、自己対戦および相互対戦ログを対象にそれぞれ 5 段階評価を行った。

A 発話表現は自然か

B 文脈を踏まえた対話は自然か

C 発話内容は一貫しており矛盾がないか（一貫性に関与しない発話は一貫していないとカウント）

D ゲーム行動（投票、襲撃、占いなど）は対話内容を踏まえているか（全行動のなかでの割合）

E 発話表現は豊かか。エージェントごとに一貫して豊かなキャラクター性が出ているか。

参加チーム以外のオーガナイザー5 名、外部から招へいした方 2 名からなる計 7 名の評価委員により主観評価を行った。表 2 に評価軸ごとの平均値を示す。

チーム	A	B	C	D	E
AITWolf*	2.14	1.85	2.14	2.00	1.00
Forst	3.28	3.00	**3.14**	3.14	2.00
Kanolab*	3.00	2.85	3.00	2.85	2.71
KELDIC	2.28	1.85	2.00	1.85	2.57
m_cre**	**3.42**	**3.14**	2.71	**3.85**	**4.00**

表 2. 主観評価の評価軸ごとの平均値（*は個別評価受賞）

さらに、各評価委員ごとにそれぞれの視点で最も良いと判断したチームを選定してもらい、各賞とした。当日は、外部評価委員 1 名が実際に対戦し、その選定によりリアルタイム対戦での評価も行った。

5. おわりに

本稿では、会話ゲーム人狼を日本語のやり取りで自動プレイする初めての試みである人狼知能大会自然言語部門の開催とその結果を紹介した。第一回ということもあり、特に対話システムとしてみると必ずしも十分な言語処理が行えていない面もあるが、まずは人狼をプレイすることはできたといえるのではないだろうか。今回の評価からは、作成者の人狼ゲームへの理解度が、システム動作の評価に大きく影響していたように思われる。評価軸やそのスコア基準については、これからも追加や改善の余地があろう。

今後はさまざまな発展が考えられる。リアルタイム対戦におけるアバターの影響は大きく、こうした実環境とのインタラクションは重要な課題である。直接的な発展としては、音声入出力の導入が考えらえるが、その分の性能低下を考えると当面はテキストのほうが分析が容易であろう。現在、同期式での対戦を行っているが、これを非同期にすればより自然な対話環境となり、異なる側面が見えてくる可能性がある。こうした発展を取り入れつつ、毎年定期的な開催を行い対話システムやエージェントの研究発展に寄与していきたい。

謝辞

本大会の開催には多数の皆様に多大な協力をいただいた。以下でお名前を挙げさせていただく。アバターデザインをご提供くださった宝塚大学東京メディア芸術学部渡邉研究室の渡邉哲意、石川雄仁、森下優香の各氏。自然言語部門の人狼知能サーバと UI 実装・運用に協力くださった静岡大学情報学部狩野研究室の箕輪峻、柴淳、三原直樹、小川ちひろ、滝波秋穂、真木裕子の各氏。評価、議論、大会運営にご参加いただいた井原渉（澪標アナリティクス）、高橋一成（株式会社人狼）、西森魅萌（人狼アイドル）の各氏。CEDEC 運営委員会の三宅洋一郎（スクウェア・エニックス）、今給黎隆（東京工芸大学）の両氏。大会運営と主観評価を担当いただいた人狼知能プロジェクトオーガナイザーの鳥海不二夫（東京大学）、大澤博隆（筑波大学）、片上大輔（東京工芸大学）、篠田孝祐（電気通信大学）、大槻恭士（山形大学）の各氏。ここに深謝申し上げる。

参考文献

[1] 片上大輔, 鳥海不二夫, 大澤博隆, 稲葉通将, 篠田孝祐, 松原仁: 人狼知能プロジェクト, 人工知能, Vol.30, No.1, pp .65-73 (2015)

[2] 鳥海不二夫, 片上大輔, 大澤博隆, 稲葉通将, 篠田孝祐, 狩野芳伸. 人狼知能 だます・見破る・説得する人工知能. 森北出版. (2016)

[3] “人狼知能プロジェクト.” [Online]. http://aiwolf.org/.

[4] 狩野芳伸、大槻恭士、園田亜斗夢、中田洋平、箕輪 峻、鳥海不二夫. 人狼知能で学ぶ AI プログラミング 欺瞞・推理・会話で不完全情報ゲームを戦う人工知能の作り方. マイナビ出版. (2017)

4:20 PM - 5:00 PM (Tue. Jun 5, 2018 3:20 PM - 5:00 PM Room H)

[1H2-OS-13b-a] Special program

©The Japanese Society for Artificial Intelligence

[1J1] [General Session] 9. NLP / IR

座長:平岡 拓也（日本電気株式会社）

Tue. Jun 5, 2018 1:20 PM - 3:00 PM Room J (2F Royal Garden B)

[1J1-01] A Study on Evaluation Method of Wikipedia's Article Using Network Feature Quantity in Definition Statement Extension for Word Sense Disamibiguation

○Wataru Murata[1], Ei-Ichi Osawa[2] （1. Future University Hakodate Graduate School, 2. Future University Hakodate）

1:20 PM - 1:40 PM

[1J1-02] Generating Descriptions for Videos based on the Interaction between a Human and Objects considering their Positional Relationship

○Rino Urushihara[1], Ichiro Kobayashi[1] （1. Ochanomizu University）

1:40 PM - 2:00 PM

[1J1-03] Automatic generation of questions from product manual sentences

○Sato Sato[1], Itsui Hiroyasu[2], Okumura Manabu[3] （1. School of Engineering, Tokyo Institute of Technology, 2. Mitsubishi Electric Corporation, 3. Institute of Innovative Research, Tokyo Institute of Technology）

2:00 PM - 2:20 PM

[1J1-04] Development of an Access Method to Linked Open Data through Converting Natural Language into SPARQL Queries

○Yuri Murayama[1], Ichiro Kobayashi[1], Takeshi Morita[2], Yukiko Nakano[3], Takahira Yamaguchi[2] （1. Ochanomizu University, 2. Keno University, 3. Seiko University）

2:20 PM - 2:40 PM

[1J1-05] Comparison of Reviews on Picture Books and Developmental Psychology Literature focusing on Infants' Developmental Reactions to Picture Books

○Miho Kasamatsu[1], Hiroshi Uehara[1,2], Takehito Utsuro[1], Yu Saito[3] （1. University of Tsukuba, 2. Akita Pref. Univ., 3. Seitoku Univ.）

2:40 PM - 3:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

語義曖昧性解消のための定義文拡張における ネットワーク特徴量を利用したWikipediaの記事評価手法の検討

A Study on Evaluation Method of Wikipedia's Article Using Network Feature Quantity in Definition Statement Extension for Word Sense Disamibiguation

村田 亘 *1　　大沢 英一 *2
Wataru Murata　　Ei-Ichi Osawa

*1公立はこだて未来大学大学院 システム情報科学研究科
Graduate School of Systems Information Science, Future University Hakodate

*2公立はこだて未来大学 システム情報科学部 複雑系知能学科
Department of Complex and Intelligent Systems, School of Systems Information Science, Future University Hakodate

Word Sense Disambiguation is one of the basic tasks of Natural Language Processing. This is the task which distinguishes multi-sense word in a sentence. Wikipedia was regarded as a large scale-network that articles are nodes and links are edges study using the link structure of Wikipedia. Therefore the present study extended define statement of word sense by selecting articles which have strong connectivity with other word sense.

Experiment of Words Sense Disambiguation failed in selecting articles and there are word sense whose correct answer rate was low. Therefore the correct answer rate is considered to rise evaluating usefulness of articles selected quantitatively. The present study focused on network feature quantity and analysed the network structure. It was found from the result of the observation that especially value of Modularity Q affected the correct answer rate.

1. はじめに

近年，インターネットやスマートフォンの普及に伴い，多くの人々がSNSやブログなどを用いて情報を発信することができる．このことから，膨大な量の言語データがインターネット上に存在し，これらを分析することで，情報検索，情報抽出，テキストマイニング，文書要約，翻訳などの応用技術の研究が行われている．そういった研究は，自然言語処理の研究分野に属しており，「言葉がわかる」計算機システムの構築を目指している [新納 16]．

自然言語処理の基本タスクの1つに，語義曖昧性解消 (WSD: Word Sense Disambiguation) がある．これは，文中の多義語の語義を識別するタスクであり，特に翻訳技術の性能向上には必要不可欠である．また，日本語の場合は文中で漢字に変換されていない平仮名の単語を正しい漢字に変換する「かな漢字変換」にも応用できる．

WSDは一般に教師あり機械学習手法を用いた研究が多くなされており，現在の教師あり機械学習の枠組みで処理すれば，90%程度の正解率に達すると言われている [新納 16]．しかし，訓練データの作成コストが高く，対象単語が多くても数百程度に限定されていしまうという問題がある [新納 16]．現実のアプリケーションではすべての単語を対象にする必要があるため．教師あり機械学習手法で解決することは難しい．そこで，すべての単語に語義を付与するWSDはall-words WSDとして，主に教師なし機械学習を用いて研究がされており，現在は60~70%の正解率である [新納 16]．教師なし機械学習の手法には，辞書の定義文から語義の分散表現を求め，評価データの文脈の分散表現との比較を行う手法 [Chen 14] がある．

一方で，知識ベースを利用したWSDの研究もなされており，古くからある知識ベースの手法にLeskアルゴリズム [Lesk 86] がある．これは，辞書の各語義の定義文に含まれる単語と，対象の文の単語との重複が一番多い語義に決定する手法である．しかし，Leskアルゴリズムには，重複する単語が存在しない場合に，語義を決定できないという問題がある．

そこで村田らはWikipediaを大規模ネットワークと捉え，ネットワーク特徴量や共起指標などを利用することで語義と関係の強い記事の選定を行い，定義文の拡張を行った [村田 17]．WSDの実験では，拡張を行うことで正解率が約10%向上した．しかし，村田らの手法では記事が正しく選定されないことで，語義の拡張が正しく行われなかった例がみられた．

もし語義の拡張に有用な記事を定量的に評価できれば，正解率の向上が期待できる．また，WSDだけでなくWWW(World Wide Web) の有用なページの選定などに応用できると考えている．

そこで，本研究では語義の定義文拡張のための有用な記事の識別方法についてネットワーク特徴量を利用して検討する．

連絡先: 村田 亘，公立はこだて未来大学大学院 システム情報科学研究科，北海道函館市中野町 116-2，0138-34-6448，g2117046@fun.ac.jp

2. 前提知識

本章では，本論文の内容で用いる特に重要な技術や知識について，概要を述べる．

2.1 クラスター係数

クラスター係数とは，あるノードの隣接ノードどうしが隣接ノード，つまり三角形の割合を示す指標である．ノード v_i に隣接しているノードの数 (次数) を k_i とすると，v_i のクラスター係数 C_i は以下の式で表される [増田 10]．

$$C_i = \frac{v_i\text{を含む三角形の数}}{k_i(k_i-1)/2} \tag{1}$$

2.2 コミュニティ抽出

図1のように，同じ集団内ではエッジが密で異なる集団間にはエッジがあまりないネットワークはよく見られる [増田 10]．点線内が1つの集団に対応し，これをコミュニティと呼ぶ．

コミュニティ抽出のための指標にはモジュラリティQがよく利用され，Qは値が高いほど良い分割といえる．モジュラリティQは以下の式で表される．

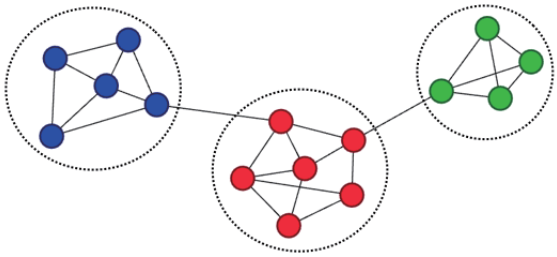


図 1: コミュニティの例

$$Q = \sum_i (e_{ii} - a_i^2) \tag{2}$$

e_{ii} はネットワーク全体におけるコミュニティ内のエッジの割合，a_i はネットワーク全体におけるコミュニティi から他のコミュニティへのエッジの割合である．したがって，コミュニティ内のノード間のエッジが多く，コミュニティ外のノード間のエッジが少ない分割ほど Q は高くなる．

Q を利用したコミュニティ抽出法には，Newman 法 [Newman 04] がある．しかし，Newman 法は大規模ネットワークに適用させた場合に計算量が膨大になるため，計算量を抑えたコミュニティ抽出法である CNM 法 [Clauset 04] が提案されている．

2.3 Jaccard 係数

Jaccard 係数は，2 つの集合間の類似性を表す指標である．X と Y の Jaccard 係数は以下の式で表される．

$$Jaccard(X,Y) = \frac{|X \cap Y|}{|X \cup Y|} \tag{3}$$

本研究では，ノード v_i とノード v_j に隣接しているノードをそれぞれの集合とし，$Jaccard(v_i, v_j)$ を算出する．つまり，v_i と v_j が互いに共通のノードと隣接しているほど Jaccard 係数は高くなる．

3. ハイパーリンク構造の Jaccard 係数を利用した定義文拡張による WSD 手法

本章では，[村田 17] の研究の概要を述べる．

3.1 提案手法の概要

提案手法の手順の概要を以下に示す．ここで，本研究でのネットワークは，「Wikipedia の記事をノード，他の記事へのリンクをエッジとする無向ネットワーク」とする．

(i) ソース記事 s に対して被リンク先に距離 2 の無向ネットワークを構築

(ii) Jaccard 係数とクラスター係数，CNM 法を用いた記事の選定

(iii) 選定された記事 (Selected Articles) から，共起ネットワーク (Co-occurrence Network) の構築

(iv) キーワード抽出 (Keyword Extraction)

(v) 語義曖昧性解消 (Word Sense Disambiguation)

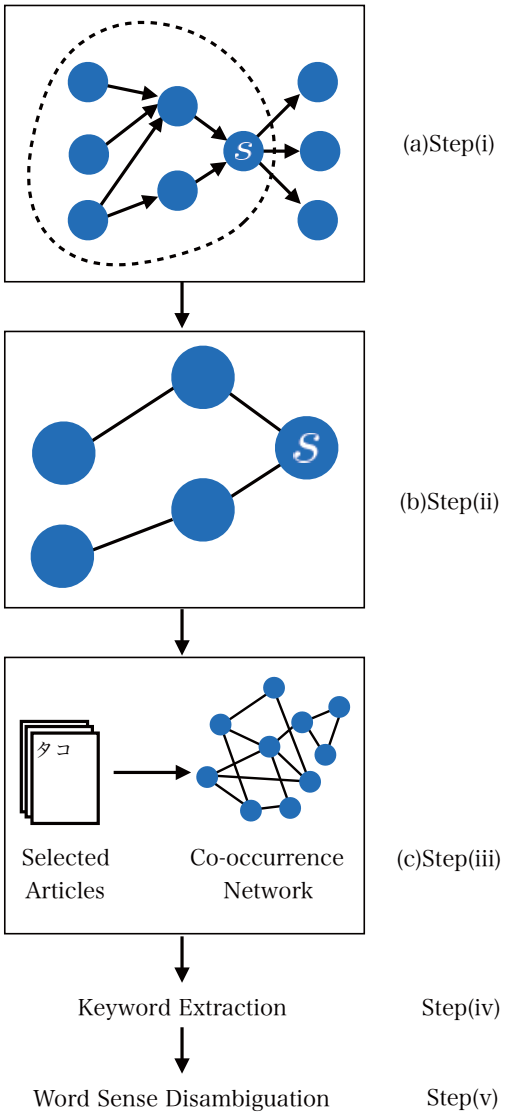


図 2: 提案手法の手順 (出典：[村田 17])

手順 (i)，(ii) は [千田 10]，手順 (iii)，(iv) は [松尾 02] の提案手法を参考にしている．

4. 章以降の説明のため，手順 (i)，(ii) の概要を述べる．

3.1.1 手順 (i)：ネットワークの構築

ソース記事 s(語義) から被リンク先に対して距離 2 の無向ネットワークを構築する．被リンク先とは，ソース記事へリンクを張っている記事のことである．ただし，被リンク先が存在しない場合はソース記事 s のみを用いる．

3.1.2 手順 (ii)：Jaccard 係数とクラスター係数を用いた記事の選定

手順 (i) で構築されたネットワークの全てのエッジに対して Jaccard 係数を算出し，閾値を 0.01 に設定する．次に，Jaccard 係数が閾値未満であればエッジを除去しソース記事 s のクラスター係数を算出する．ただし，エッジの本数が 0 本となったノードは除去する．さらに閾値を 0.01 上げ，エッジの除去，ソース記事 s のクラスター係数の算出を繰り返す．そして，ソース記事 s のクラスター係数が最後に極大をとる Jaccard 係数を最終的な閾値に決定し，ネットワークを再構築する．最後の極

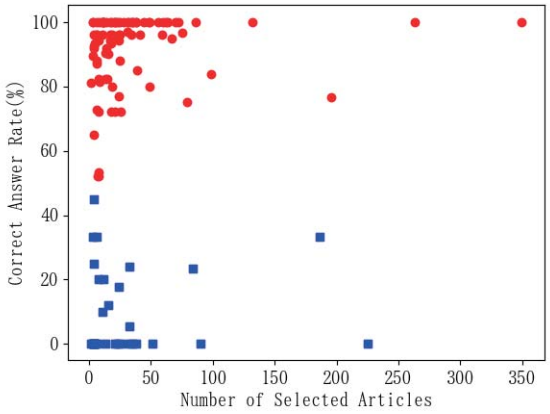


図 3: 選定された記事数と正解率

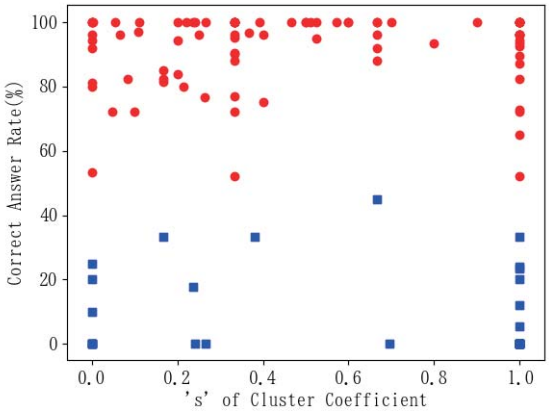


図 4: ソース記事 s のクラスター係数と正解率

大にする理由は，Jaccard 係数が高いため類似性が高い記事が残り，クラスター係数が高いためネットワークが密であるからである．

次に，再構築されたネットワークに対して CNM 法を適用し，ソース記事 s を含むコミュニティに含む記事を選定された記事集合とする．

3.2 実験・評価

実験に用いた評価データは，多義語が 50 個でそれぞれの多義語に対して 50 個ずつ用意した．それぞれの多義語の語義数には偏りがあるため，語義の総数は 119 個であった．つまり，2500 個の評価データを用いて，語義曖昧性解消の実験を行い，正解率を算出した．

$$\text{正解率} = \frac{|\,\text{正解データ} \cap \text{提案手法の結果データ}\,|}{|\,\text{正解データ}\,|} \qquad (4)$$

結果は，拡張を行わない場合の正解率は 62.3%，拡張を行った場合が 73%であり，正解率が約 10% 向上した．しかし，記事の選定が失敗しているために，定義文の拡張が正しく行われず正解率が低い語義もみられた．

そこで，本研究では選定された記事が有用かどうかを識別するために，記事の選定の際のネットワーク構造を解析する．

4. 選定された記事の評価

本章では，ネットワーク特徴量を用いて選定された記事が WSD に有用かどうかを検討する．ここで，正解率が 50%以上の語義の選定された記事集合を「有用」とする．有用な記事集合は 88 個，有用でない記事集合は 31 個あった．

4.1 選定された記事数

図 3 は選定された記事数と正解率のグラフである．赤の丸い点になっているのは正解率が 50%以上，青の四角い点は 50%未満の正解率の語義である．

図 3 から，選定された記事数は 1 ～ 50 個が最も多くなっているが，その範囲においても正解率が 0%の語義から 100%に近いものが多く，記事数を用いた有用な記事の識別は難しい．

4.2 クラスター係数

図 4 は [村田 17] の提案手法の手順 (ii) の閾値を決定し，ネットワークを再構築した際のソース記事 s のクラスター係数と正解率のグラフである．

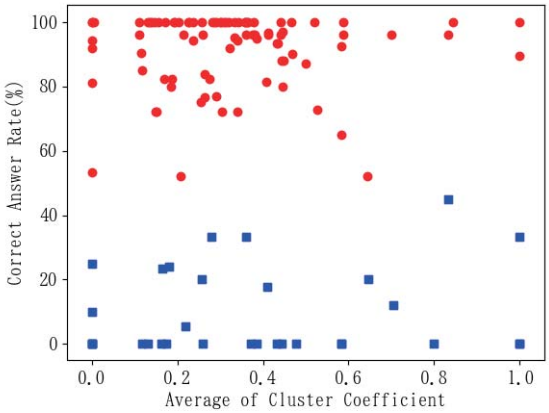


図 5: 平均クラスター係数と正解率

ソース記事 s のクラスター係数が高ければネットワークが密であるので，正解率に影響すると考えたが，有用な記事集合のなかでもクラスター係数が低いものが多かった．また，クラスター係数が高いのにもかかわらず，正解率が低い記事集合もみられた．

図 5 はネットワークを再構築した際の平均クラスター係数と正解率のグラフである．グラフから平均クラスター係数は 0.1 ～ 0.6 の値に集中しており，正解率との関係はあまりない．

4.3 モジュラリティ Q

図 6 はコミュニティ抽出をする際のモジュラリティ Q の値と正解率のグラフである．グラフの分布は図 3 に似ているが，図 6 の方が分散が大きくなっており，$Q = 0.7$ 以上の有用な記事集合は約 9 割存在する．

ここで，Q に閾値を設定する．閾値以上の Q の記事集合を有用な記事集合と識別し，閾値未満の記事集合を有用でない記事集合と識別する．

例として $Q = 0.7$ を閾値とし正しく有用な記事集合かどうかの識別を行う．図 6 の横破線は正解率が 50%，縦破線は $Q = 0.7$ である．この場合，Q が 0.7 以上の有用な記事集合

表 1: モジュラリティQ に閾値を設定した場合の Precision・Recall・F 値

	有用な記事集合 (赤の丸い点)			有用でない記事集合 (青の四角い点)		
Threshold	Precision	Recall	F	Precision	Recall	F
0.1	0.745	**0.965**	**0.841**	0.4	0.064	0.111
0.2	0.75	0.954	0.839	0.428	0.096	0.157
0.3	0.75	0.954	0.839	0.428	0.096	0.157
0.4	0.754	0.943	0.838	0.444	0.129	0.2
0.5	0.754	0.943	0.838	0.444	0.129	0.2
0.6	0.771	0.92	0.839	0.5	0.225	0.311
0.7	0.795	0.886	0.838	**0.523**	0.354	0.423
0.8	**0.844**	0.738	0.787	0.452	0.612	**0.52**
0.9	0.838	0.295	0.436	0.295	**0.838**	0.436

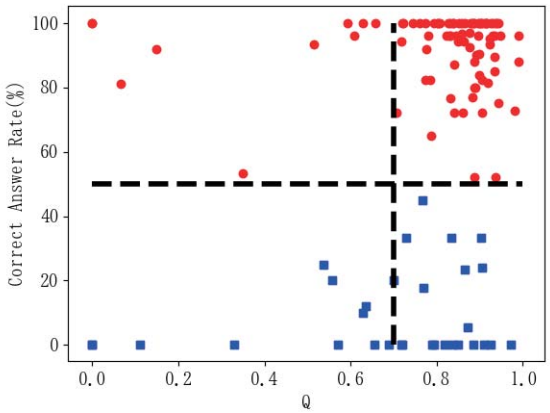


図 6: モジュラリティQ と正解率

(右上) は正しく識別され，0.7 未満 (左上) は誤って識別される．また，0.7 以上の有用でない記事集合 (右下) は誤って識別され，0.7 未満 (左下) は正しく識別される．

表 1 は，Q に閾値を設定し Precision，Recall，F 値を算出したものである．有用な記事集合の F 値は $Q = 0.1$ のとき最大だが，0.1 ～ 0.7 で大きく値は変わらない．これは，有用な記事集合の正解率が $Q = 0.7$ 以上に有用な記事集合が密集しているため Recall の変化があまりないためである．

このため，選定された記事集合の有用性を識別するためには $Q = 0.8$ が最も良い閾値であることがわかる．しかし，そのときの有用でない記事集合の Recall は約 0.6 であることから，4 割が識別できていない．

今後は，他のネットワーク特徴量などを利用する必要がある．

5. おわりに

本論文では．記事の選定が失敗し WSD の正解率が低くなってしまう場合があるという [村田 17] の問題に対して，ネットワーク特徴量を用いることで選定された記事の有用性の識別方法の検討を行った．検討した中ではモジュラリティQ を用いた場合が最も多く識別ができたが，識別に失敗しているものも多かった．

今後は中心性などのネットワーク指標や，[村田 17] の提案手法の手順 (i) から (ii) にかけてネットワークがどのように変化しているのかを解析することで，より良い識別手法が得られると考えている．

また，WWW などのハイパーリンク構造を持つネットワークに対して本手法を適用させ，より良い有用な記事の抽出方法を模索したい．

参考文献

[Chen 14] Chen, X., Liu, Z., and Sun, M.: A Unified Model for Word Sense Representation and Disambiguation, in *In Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, pp. 1025–1035 (2014)

[Clauset 04] Clauset, A., Newman, M. E. J., and Moore, C.: Finding community structure in very large networks, *Physical Review E*, Vol. 70, No. 066111 (2004)

[Lesk 86] Lesk, M.: Automatic sense disambiguation using machine readable dictionaries: how to tell a pine cone from an ice cream cone, in *the 5th annual international conference on Systems documentation*, pp. 24–26 (1986)

[Newman 04] Newman, M. E. J.: Fast algorithm for detecting community structure in networks, *Physical Review E*, Vol. 69, No. 066133 (2004)

[松尾 02] 松尾 豊, 大澤 幸生, 石塚 満 : Small World 構造に基づく文書からのキーワード抽出, 情報処理学会誌, Vol. 43, No. 6, pp. 1825–1833 (2002)

[新納 16] 新納 浩幸 : 自然言語処理の現状と展望 語義曖昧性解消, 情報処理学会誌, Vol. 57, No. 1, pp. 20–21 (2016)

[千田 10] 千田 俊輔, 大沢 英一 : リンク構造解析による Wikipedia のナビゲーション情報の抽出, 合同エージェントワークショップ&シンポジウム JAWS2010 (2010)

[増田 10] 増田 直紀, 今野 紀雄 : 複雑ネットワーク 基礎から応用まで, 近代科学社 (2010)

[村田 17] 村田 亘, 大沢 英一 : ハイパーメディアの Jaccard 係数に着目した定義文拡張における語義曖昧性解消, 日本ソフトウェア科学会第 34 回大会講演論文集 (2017)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

人の動作，物体検出およびそれらの位置情報を考慮した動画像からの文生成

Generating Descriptions for Videos based on the Interaction between a Human and Objects considering their Positional Relationship

漆原 理乃 *1　小林 一郎 *1
Rino Urushihara　Ichiro Kobayashi

*1お茶の水女子大学
Ochanomizu University

Image and video captioning with deep learning has been actively studied. On the other hand, few studies have focused on generating descriptions by correctly capturing the contents of images and videos. So, our study aims to generate natural language descriptions for videos based on the results of the identification of human activity and object detection for a movie. We propose a method to generate descriptions by combining four representative deep learning techniques: human pose estimation, time-series data analysis, object detection, and sequence-to-sequence. In addition, in generating descriptions, we apply positional information of the detected objects and a human in a movie, which works as natural attention on which objects should be described in a sentence. Through experiments, we have confirmed that our method could precisely describe the contents of movies, especially the interaction between a human and objects.

1. はじめに

近年，監視カメラによる不審者の挙動の把握や高齢者の見守り，スポーツの実況中継など，人の動作を言葉によって報告する技術の必要性が高まっている．深層学習を用いた画像の言語化においては Encoder-Decoder Network に基づく研究 [Donahue 15, Kiros 15] が多く報告されており，Encoder として画像特徴量抽出に効果的な GoogleLeNet [Loffe 15] を用いた [Vinyals 15] が特に高性能な文生成手法を確立した．画像中の物体を検出し，得られた単語から確率的に説明文を生成する手法 [Fang 15] も報告されている．また，動画像における言語化手法としても、Encoder-Decoder Network に基づく研究 [Pasunuru 17] が盛んで，特に動画像処理に関する様々なタスクにおける動画像特徴量抽出に効果的な Convolutional 3D [Tran 15] を用いて説明文生成を行う手法 [Dong 16] なども報告されている．ただ、これらは深層学習を用いるため新規な自然文を生成することに成功しているが，画像や動画像特徴量から Decoder を介して文章を生成する手法が多く，人間が実際に画像や動画像を見て認識するような事象，特に人の動作について正しく捉えて言語化する手法はほとんどない．

そのため本研究では，深層学習を用いて，動画像中の事象を正しく捉えた動画像の説明文生成に取り組む．図 1 に本研究の概要図を示す．具体的には，動画像のフレームごとに人の姿勢情報を抽出し時系列情報として，動作を表す単語を選択する処理と，フレームごとに物体を検出する処理を合わせ，それぞれの処理において得られた結果から人の動作を捉えた動画像説明文生成を行う．

2. 人の動作認識に基づく文生成

2.1 動作認識

本研究では，Cao らによる深層学習を用いた人の姿勢推定手法 [Cao 17] を用い，動画像の各フレームごとに鼻や目，肘などの 18 個の人の部位のピクセル座標を検出する．そこで得られたフレームごとの 36 次元 (=人の部位数 18× フレームのピクセル座標数 2) の情報に対して，Encoder-Decoder Temporal Convolutional Networks (ED-TCN) [Lea 16] を用いて，動画像のフレームごとのセンサー情報や特徴量を入力とし，プーリングとアップサンプリングを用いて広範囲の時系列情報を効果的に捉え，動画像中の全てのフレームに対して動作を表す適切な単語を選択する．

2.2 物体検出

物体検出には Single Shot MultiBox Detector (SSD) [Liu 16] を用いる．SSD は，画像中の物体を検出するシステムである．画像を入力とし，画像中に含まれる物体の種類とその物体のピクセル座標 {x 軸の最大値，x 軸の最小値，y 軸の最大値，y 軸の最小値 }，確信度を出力する．画像の特徴量抽出に効果的な深層学習のモデルである Convolutional Neural Network (CNN) の一種，VGG16 のネットワーク構造をベースとし，深層学習を用いた他の手法 Faster R-CNN [Ren 16] や YOLO [Redmon 16] よりも高精度かつ高速度である [Liu 16].

2.3 物体の位置情報を用いた文生成

本研究では，Sutskever ら [Sutskever 14] による RNN の一種，Long Short-Term Memory (LSTM) を用いて，あるシーケンスを別のシーケンスに変換するという言語モデルを改良し，動画像中の物体の位置情報を用いた文生成手法を提案する．図 2 に提案手法のモデルを示す．動画像の各フレームごとに ED-TCN によって予測された動作を表す単語 (図 2 では verb) と，SSD によって検出された物体の単語 (図 2 では w1, w2) と検出された物体それぞれの位置情報となるピクセル座標 {x 軸の最大値，x 軸の最小値，y 軸の最大値，y 軸の最小値 } を入力とし，すでに学習されたモデルから物体のピクセル座標や語順情報に基づき，各語が選ばれる確率を算出し，逐次的に次の単語の予測を繰り返し文を生成する手法を提案する．

3. 実験

3.1 使用データ

料理の動画像である TACoS Cooking Dataset [Regneri 13] とそのフレームごとに対応する説明文である TACoS Multi-

連絡先: 漆原理乃，お茶の水女子大学理学部情報科学科小林研究室，〒 112-8610 東京都文京区大塚 2-1-1，g1420509@is.ocha.ac.jp

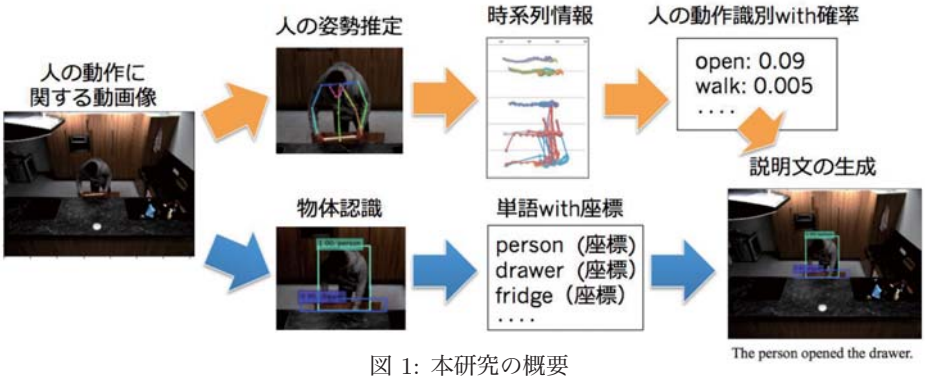


図 1: 本研究の概要

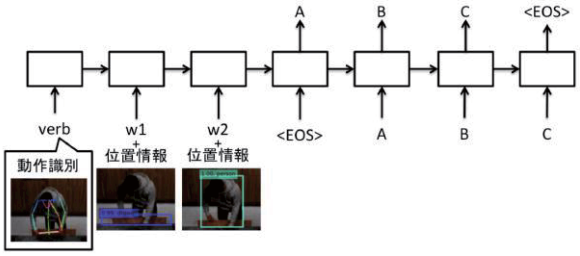


図 2: 物体の位置情報を用いた文生成モデル

Level Corpus [Senina 14][*1] を使用した．説明文は提案手法に合わせ，時制を過去形に一致させ，位置情報を追加し，単語を抽象化するなど，改変したものを使用した．

3.2 人の姿勢推定に基づく動作認識実験

本研究では，まず動画像の各フレームにおいて姿勢推定手法 [Cao 17] により人の姿勢を推定し，得られた時系列データを入力として，ED-TCN を用いて人の動作を表す適切な単語を選択する．

3.2.1 実験設定

システムの実装に際しては，姿勢推定手法 [Cao 17] のコード [*2] を深層学習フレームワークである TensorFlow を用いて実験を行った．ハイパーパラメータの数値設定やネットワークの重みは Microsoft COCO[*3] で学習済みのものを使用した．

ED-TCN に関しては，深層学習フレームワーク Keras で実装されているコード [*4] を TensorFlow のバックエンドのもと使用した．実験に使用した動画像は，10fps で 40 秒から 22 分程度 (フレーム数は 363 から 13,648) の 121 本で，訓練用に 109 本，検証用に 6 本，評価用に 6 本使用した結果を提示する．また，訓練用データで使用された 58 個の動作を表す単語を識別に使用する．ここで，TACoS の動画像説明文中に動作を表す単語がないフレームもいくつかあり，その場合は None として実験した．ED-TCN の学習に関するハイパーパラメータの数値設定については [Lea 16] における実験同様，レイヤー数は Encoder と Decoder それぞれ 2 層使用し，フィルタサイズは Encoder 側では第 1 層目は 64 と第 2 層目は 96 に設定し，Decoder 側の最終層は 64，最終層の 1 つ前の層は 96 とする．学習アルゴリズムは確率的勾配降下法，誤差関数は交差エントロピー，全てのレイヤーの畳み込み層においてドロップアウトを使用した．畳み込む手法や畳み込むフレームサイズ、epoch 数を変更させ実験を行った．ここで、畳み込む手法とは時系列方向においてはフレームサイズを d とした場合に時刻 $t-\frac{d}{2}$ から時刻 $t+\frac{d}{2}$ までのフレーム情報を畳み込む手法 ([Lea 16] においては acausal と呼ばれる) と時刻 $t-d$ から時刻 t までのフレーム情報を畳み込む手法 ([Lea 16] においては causal と呼ばれる) の 2 種類があり，それぞれ実験をした．

3.2.2 実験結果

TACoS のあるフレーム画像に対して [Cao 17] を行った結果を図 3 に示す．ED-TCN において畳み込む手法とフレームサイズ d を変化させ実験を行った epoch 数ごとの動作識別結果を図 4 に示す．評価手法としては，各動画像のフレームごとの正解率 (正解したフレーム数/全体のフレーム数) のマクロ平均と，時系列情報のセグメンテーションを評価する手法として [Lea 16] において使用されていた，編集距離を 0 から 100 に正規化した編集スコア (数値が高い方が良い結果となる) をそれぞれ求め評価を行った．また，causal モデルでフレームサイズ d を 40 とした場合の 1000 epochs 時の上位 n 件を正解とした場合の結果を図 5 に示し，200 epochs 時，500 epochs 時の 58 単語のうちの一部単語において，それぞれの適合率，再現率，F 値を求め比較した結果を表 1 に示す．表 1 中の動画像数は訓練用データと検証用データに含まれる動画像の中で，その単語が出現する動画像数である．



図 3: TACoS のあるフレームにおける姿勢推定結果

3.2.3 考察

図 4 より，epoch 数を増やすことで，正解率・編集スコアともに高くなっていくこと，また 1000 epochs の場合，フレームサイズ d は 40 で causal モデルの場合が最も精度が高くなることもわかった．図 5 より，上位 5 位以上を正解とした場合は正解率が 77%以上となる．表 1 より，epoch 数を増やすことで訓練用の動画像数が少ない単語 (例えば，squeeze や peel, take apart など) でも F 値が高くなることがわかる．take out や wash は再現率は高く適合率は低いため，異なる動作の場合

∗1 https://github.com/qiuwei/videosum/tree/master/corpus/TACoS
∗2 https://github.com/ZheC/Realtime_Multi-Person_Pose_Estimation
∗3 http://mscoco.org/
∗4 https://github.com/colincsl/TemporalConvolutionalNetworks

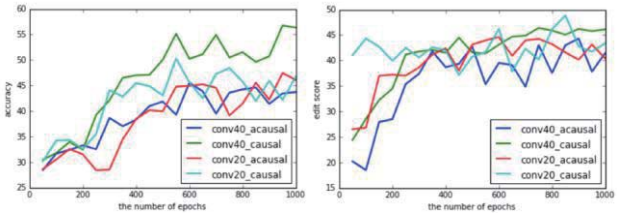


図 4: Accuracy(左) と edit-score(右)

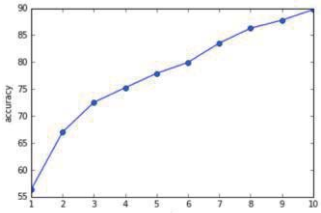


図 5: 上位 10 までの正解率

でもその 2 つを多く出してしまっており，cut は peel や slice などの似ている動作が多いため epoch 数を増やしても F 値は上がらなかったと考えられる．動作を表す単語選択においては似ている動作を識別できるような枠組みや少ない訓練データ数でも識別できるような枠組みが必要と考えられる．

3.3 物体検出実験

物体検出手法 SSD において動画像の各フレームにおいて物体の種類とその位置情報の検出を行った．

3.3.1 実験設定

物体検出手法 SSD では深層学習のフレームワーク Keras によって実装されているコード [*5] を用いた．SSD で使用されている VGG16 のネットワーク構造のうち，画像特徴量を抽出する層である，conv1_1 から pool3 までの層においては，大規模な画像認識コンペティション VOC2007 の 5,011 枚の画像のみで学習した重みを使用した．その層以降 (つまり conv4_1 以降) の学習は TACoS の動画像からランダムに抽出した 251 枚のフレーム画像も交え 5,262 枚の画像で学習した．検出する物体の種類は VOC2007 における 20 種類と，TACoS において説明文で頻繁に使用される代表的な 13 種類の単語を厳選し，合計 33 種類の物体を画像から検出するように学習した．

3.3.2 実験結果

SSD を実験した結果は図 6 に，3.4.2 項で生成した文と合わせて明記する．画像中には，検出された物体をバウンディングボックスで囲み，その上部左に検出した物体の種類の確信度を 0 から 1 の範囲に数値化したものを，上部右に検出した物体の種類を明記した．

3.4 文生成実験

物体検出手法 SSD において得られた情報と，動作認識実験において得られた動作を表す単語を用いて，文生成を行った．

3.4.1 実験設定

文生成においては，SSD において検出された物体の確信度が 0.6 以上の物体の単語と位置情報を入力として使用した．使用した動画像は TACoS の 6 本で 5 本を訓練用，1 本を評価用に使用した．表 2 に使用した動画像の概要を示す．複数のフレームで 1 つの文が当てられているため，同一の文でもフレームが異なれば，SSD で検出した物体の位置情報が異なる．そのため 5 本の動画像における 112 文と 5,715 枚の画像で学習を行った．

表 1: 単語ごとの比較

単語	200 epochs { 適合率, 再現率, F 値 }	500 epochs { 適合率, 再現率, F 値 }	動画像数
take out	0.45, 0.76, 0.57	0.49, 0.68, 0.55	115
wash	0.14, 0.36, 0.20	0.14, 0.35, 0.20	99
cut	0.55, 0.34, 0.42	0.22, 0.36, 0.27	95
peel	0.06, 0.49, 0.11	0.31, 0.34, 0.32	45
take apart	0.0, 0.0, 0.0	0.17, 0.14, 0.15	37
squeeze	0.0, 0.0, 0.0	0.58, 0.55, 0.56	8
tap	0.0, 0.0, 0.0	0.0, 0.0, 0.0	4

表 2: 使用した動画像の概要

動画像 ID	種類	文数	フレーム数
s13-d21	訓練	13	702
s13-d25	訓練	13	716
s13-d28	訓練	30	1389
s13-d40	評価	16	901
s13-d52	訓練	16	713
s13-d54	訓練	40	2195

システムの実装に関しては，言語モデル [Sutskever 14] を深層学習フレームワーク Keras で実装したコード [*6] を用いた．入力は SSD で検出できる 33 種類の単語と訓練用の動画像の説明文で使用されている 30 単語を合わせ 63 次元のベクトル表現で，SSD において検出した物体の単語は 1 でそれ以外を 0 としたものと，検出した物体の位置情報 {x 軸の最大値，x 軸の最小値，y 軸の最大値，y 軸の最小値 } の 4 次元を入力次元に追加し，入力は 67 次元で出力は 63 次元とした．学習アルゴリズムは確率的勾配降下法，誤差関数は平均二乗誤差を用いて実験した．

3.4.2 実験結果

評価用の動画像において SSD を実験した結果と生成した文を図 6 に示す．また文生成における定量的な結果として，epochs ごとの評価用動画像の全フレームの BLEU スコアのマクロ平均を表 3 に示す．

表 3: 文生成における BLEU スコアのマクロ平均

epoch 数	BLEU スコア
50 epochs	0.70
100 epochs	0.71

3.4.3 考察

表 3 からはある程度高精度で文が生成されていることがわかる．図 6 の具体的な生成文を見てみると，(1) では人は fridge の近くにおり，(3) では cupboard の近くにいるため，それらの単語が文中に出現したと考えられる．また，SSD の結果では現れていない単語 ((1)ingredient，(3)plate など) も文中に出現し，訓練用データから適切に補完できていることも確認できる．(5)(6) は評価用の動画像において近いフレーム同士であり，冷蔵庫の隣で食材のパッケージを取っている動画像である．動作識別時の正解ラベルは remove-package としているが訓練データ数が少なかったためにラベルが識別できず，適切に説明文を生成することができなかったと考えられる．

4. おわりに

本研究では，動画像のフレームごとに人の姿勢情報を抽出し時系列データとして，ED-TCN を用いた動作を表す単語を選

∗5 https://github.com/rykov8/ssd_keras

∗6 https://github.com/farizrahman4u/seq2seq

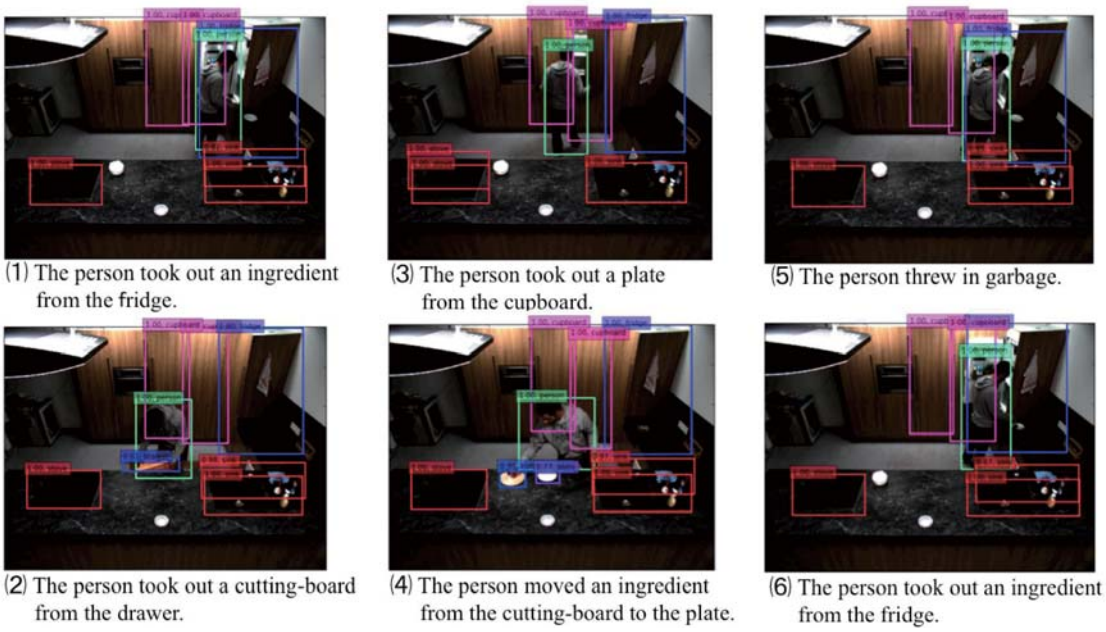


図 6: SSD 結果と生成文の例

択する処理と，SSD を用いたフレームごとに物体検出を行う処理を合わせ，人の動作を捉えた説明文生成手法を構築した．文生成実験においては人と物体との位置関係を捉えた文が生成されていること，物体検出で検出できない単語も訓練用データから補完できることを確認した．

今後の課題としては，動作認識において cut や peel などの動作が近い単語や訓練データ数が少ない単語でも識別できるような枠組みを考えていきたい．また，画像・動画特徴量から文生成する既存手法との比較より提案手法の有効性を確認し，BLEU スコアが向上するよう改良を進めてきたい．

参考文献

[Donahue 15] Donahue, J., Hendricks, L.A., Guadarrama, S., Rohrbach, M., Venugopalan, S., Saenko, K., and Darrell, T.: Long-term Recurrent Convolutional Networks for Visual Recognition and Description, In CVPR ' 15 (2015).

[Kiros 15] R. Kiros, R. Salakhutdinov, R. S. Zemel, "Unifying visual-semantic embeddings with multimodal neural language models", In NIPS Deep Learning Workshop, 2015.

[Loffe 15] Ioffe, S. and Szegedy, C.: Batch normalization: Accelerating deep network training by reducing internal covariate shift, In arXiv preprint arXiv:1502.03167 (2015).

[Vinyals 15] O. Vinyals, A. Toshev, S. Bengio, and D. Erhan, "Show and tell: A neural image caption generator", In CVPR, 2015.

[Fang 15] H. Fang, S. Gupta, F. Iandola, R. K. Srivastava, L. Deng, P. Dollar, J. Gao, X. He, M. Mitchell, J. C. Platt, C. L. Zitnick, and G. Zweig."From captions to visual concepts and back", In CVPR, 2015.

[Pasunuru 17] R. Pasunuru, and M. Bansal, "Multi-Task Video Captioning with Video and Entailment Generation", In ACL, 2017

[Tran 15] D. Tran, L. Bourdev, R. Fergus, L. Torresani, and M. Paluri, "Learning Spatiotemporal Features with 3D Convolutional Networks", in ICCV, 2015

[Dong 16] J. Dong, X. Li, W. Lan, Y. Huo, C. G. M. Snoek, "Early Embedding and Late Reranking for Video Captioning", In ACMMM, 2016

[Cao 17] Z. Cao, T. Simon, S. Wei, and Y. Sheikh."Realtime Multi-Person 2D Pose Estimation using Part Affinity Fields", In CVPR, 2017.

[Lea 16] C. Lea, M. D. Flynn, R. Vidal, A. Reiter, and G. D. Hager."Temporal Convolutional Networks for Action Segmentation and Detection", arXiv preprint arXiv:1611.05267, 2016.

[Liu 16] W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C. Fu, and A. C. Berg."SSD: Single Shot MultiBox Detector", arXiv preprint arXiv:1512.02325, 2016.

[Ren 16] S. Ren, K. He, R. Girshick, and J. Sun. 2016. Faster r-cnn: Towards real-time object detection with region proposal networks. arXiv preprint arXiv:1506.01497.

[Redmon 16] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi. 2016. You only look once: Unified, real-time object detection. arXiv preprint arXiv:1506.02640.

[Sutskever 14] I.Sutskever, O. Vinyals, and Q. V. Le. "Sequence to sequence learning with neural networks", In Advances in NIPS, 2014.

[Regneri 13] M. Regneri, M. Rohrbach, D. Wetzel, S. Thater, B. Schiele, and M. Pinkal, "Grounding action descriptions in videos," Transactions of the Association for Computational Linguistics (TACL), vol. 1, pp. 25-36, 2013.

[Senina 14] A. Senina, M. Rohrbach, W. Qiu, A. Friedrich, S. Amin, M. Andriluka, M. Pinkal, and B. Schiele. " Coherent multi-sentence video description with variable level of detail", arXiv preprint arXiv:1403.6173, 2014.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

製品マニュアル文からの質問自動生成

Automatic generation of questions from product manual sentences

佐藤 紗都[*1] 伍井 啓恭[*2] 奥村 学[*3]
Sato Sato Hiroyasu Itsui Manabu Okumura

[*1] 東京工業大学工学院 School of Engineering Tokyo Institute of Technology
[*2] 三菱電機株式会社 Mitsubishi Electric Corporation
[*3] 東京工業大学科学技術創成研究院 Institute of Innovative Research Tokyo Institute of Technology

In this research, as the first step to develop a system that automatically generates related question answer pairs from sentences in a product manual, we present a method to automatically generate question sentences from manual sentences. As the result of experiments with a data set of about 1400 sentences, we obtained BLEU score of 62.11 by comparing generated sentences with manually prepared question sentences.

1. はじめに

電化製品の高度化の 1 つの方向性に，製品に対するユーザの質問に音声などで電化製品自身が応答することが挙げられる．例えば，炊飯器に向かって「白米でお粥を作るとき、どのくらい時間がかかりますか？」と聞いたときに，炊飯器が「約 41～47 分かかります」と答えることができれば有用と考えられる．しかし，このような質問応答システムの構築には製品に関する質問応答対が必要であり，これを人手で作成することには大きなコストがかかる．一方で，製品に必ず付属している製品マニュアルは製品の使用方法などが網羅されているため，これを用いて自動で質問生成することができればそのコストを削減することが可能である．そこで，本研究では製品の使用方法などが網羅されている製品マニュアルを用いて，関連する質問応答対を獲得する第一歩として，マニュアル文から関連する質問文を自動生成する手法を示す．

具体例を図 1 に示す．例 1 に示すように入力のマニュアル文「炊飯中の「チリチリ」等の音はIH特有の通電音によるもので、故障ではありません」に対し質問文，「炊飯中に変な音がするのは故障ですか？」と出力する．また，例 2 のようなマニュアル独特の入力に対しても対応できるようにする．

質問を自動生成する試みは古くから行われており，規則に基づく手法，テンプレートを用いる手法，ニューラルネットワークを用いる手法の 3 つに大きく分類することができる．

規則に基づく手法の1つとして，平叙文を質問文に変換する汎用規則を用いて質問文候補を複数生成し，分類器を用いてランキングする手法[Heilman 2009]が提案されているが，英文の質問生成特有のルールが多く，日本語に直ちに適応することは難しい．

テンプレートを用いる手法として，質問応答サイトに対する検索履歴ログを用いて，検索クエリを入力として，自動的にテンプレートを生成し，質問を自動生成する手法[Zhao 2011]が提案されており，本研究にもっとも類似するが，大量の検索履歴が利用可能であることを前提としたものであり，大量に入手できない場合には不向きである．

ニューラルネットワークを用いる手法の1つとして，教師付き学習と強化学習を組み合わせてリカレントニューラルネットワークモデルを学習させる手法[Yuan 2017]が挙げられるが，この手法は質問応答データが大量に入手できない場合には不向きである．

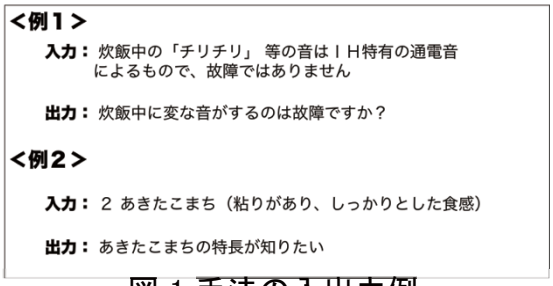


図 1 手法の入出力例

一方で打者成績とイニング速報からテンプレートを生成し，それを用いて，打者成績からイニング速報を生成する手法[村上 2016]が提案されている．この手法ではデータ数が少ない場合でも対応可能であるため，本研究ではこのテンプレート生成手法を用いて質問生成を試みる．

以下その具体的な手法を説明し，それに対する評価実験の結果と考察を述べる．

2. 提案手法

2.1 システム概要

図 2 に質問生成システムの概要を示す．提案手法は大きく学習フェーズと質問文生成フェーズの 2 つに分けられる．

学習フェーズでは，人手で作成されたマニュアル文と質問文の対を訓練データとして，マニュアル文と質問文の自動対応付けを行い，対応した単語個所をタグに抽象化した後，クラスタリングを行い，マニュアル文-質問文の対の代表テンプレートリストを生成する(テンプレート生成)．

質問生成フェーズでは，入力されたマニュアル文に対して，自動対応付けにより，生成した代表テンプレートリストから候補テンプレートを抽出し，タグを単語で置換することで質問文を生成する(質問文生成)．

次節からテンプレート生成と質問文生成について詳しく説明する．

連絡先：佐藤紗都，東京工業大学工学院，横浜市緑区長津田町 4259 R2-7，satosato@lr.pi.titech.ac.jp

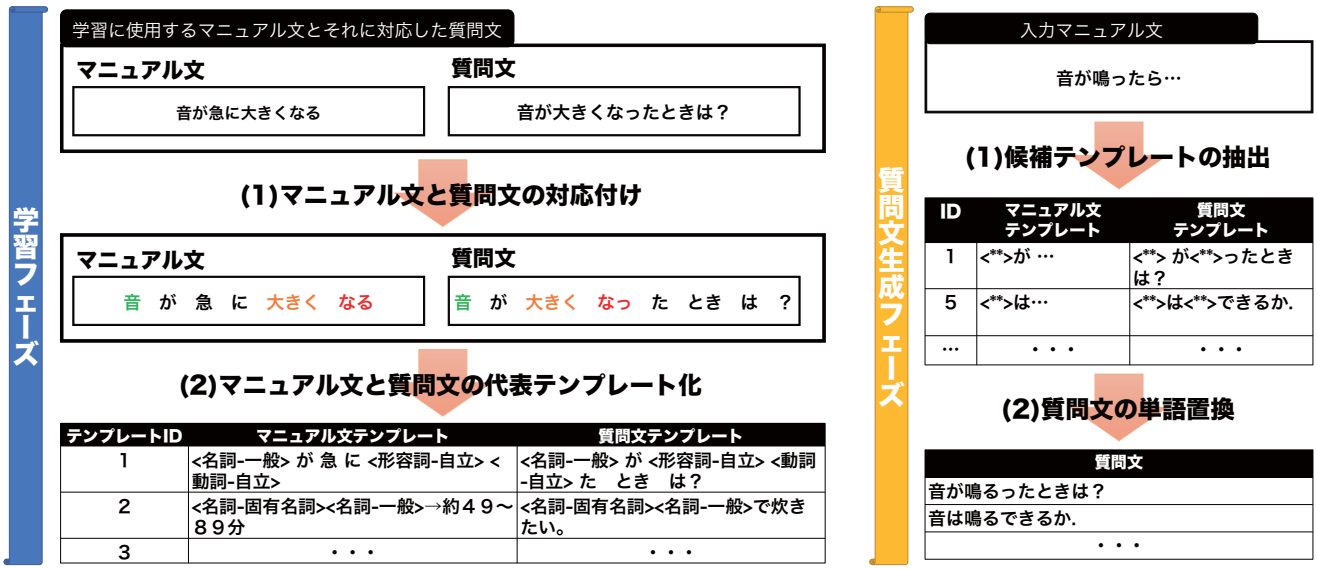


図 2 質問文生成システム概要

2.2 テンプレート生成

テンプレート生成では大きく分けて，(1) マニュアル文と質問文の対応付け，(2) マニュアル文と質問文の代表テンプレート化という 2 つの処理を行う．

(1) マニュアル文と質問文の対応付け

MeCab(http://mecab.sourceforge.jp/)を用いてマニュアル文と質問文をそれぞれ形態素解析する．次に，その結果に対し，Jing ら[Jing 1999]の隠れマルコフモデルに基づいたアライメント手法を適用し，マニュアル文と質問文の原形単語間の対応付けを行う．

(2) マニュアル文と質問文の代表テンプレート化

(1)の結果を用い，まずマニュアル文と質問文の汎化を行う．具体的には，(1)で対応付いた単語のうち，自立語であるものは変数化して良いと考え，マニュアル文と質問文のその単語個所を「<品詞-品詞細目 1>」という品詞タグに置き換えることで汎化を行う．例えば，単語が一般名詞であった場合は「<名詞-一般>」，形容詞自立であった場合は「<形容詞-自立>」と置き換えるため，図1では「音が急に大きくなる」というマニュアル文が「 <名詞-一般> が 急 に <形容詞-自立> <動詞-自立>」という風に汎化される．ここで対応づいた自立語の単語をタグに置き換えた文をテンプレート文と呼ぶ．

次に，マニュアルテンプレート文-質問テンプレート文の対をクラスタリングする．具体的には，質問文に含まれる内容語及びタグの TF-IDF 値で構成されるベクトルを特徴量として k-means 法によるクラスタリングを行い，生成されたクラスタごとに固有のテンプレート ID を付与する．

最後に，生成されたクラスタの中心に最も近いテンプレート対をそれぞれのクラスタの代表テンプレート対として，代表テンプレートリストを生成する．

2.3 質問文生成

質問文生成では大きく分けて，(1) 候補テンプレートの抽出，(2) 質問文中のタグの単語置換という 2 つの処理を行う．説明のために，あるクラスタ k の代表マニュアルテンプレートを rep_k，入力されたマニュアル文を m とする．

(1) 候補テンプレートの抽出

2.2 節(1)と同じアライメント手法を用いて，入力マニュアル文と代表マニュアルテンプレートの対応付けを行い，一定以上の割合対応付けが取れたものを候補テンプレートとする．図 3 に入力マニュアル文と代表マニュアルテンプレートの対応づけの流れを示す．

まず，m を MeCab で形態素解析し，rep_k のタグになっている部分と同じ位置の m の単語個所を品詞タグに置き換える．この置き換えを行なった m を m'とする．さらに置き換えた m の単語の品詞をインデックス，品詞ごとの m の単語リスト(単語の出現順にソート)を値とした品詞単語辞書を保持しておく．

次に，2.2 節(1)と同じアライメント手法を用いて，rep_k と m'の単語間の対応付けを行う．また，rep_k と m'の単語間の対応付けがされた割合(対応割合)を求める．対応割合Rは rep_k の単語数をl_r，m'の単語数を$l_{m'}$，対応が取れた単語数をl_aとすると次の式で表すことができる：

$$R = l_a / max(l_r, l_{m'}).$$

以上の操作を各代表テンプレートについて行い，パラメタとして与えられた対応割合下限R_{limit}以上の代表マニュアルテンプ

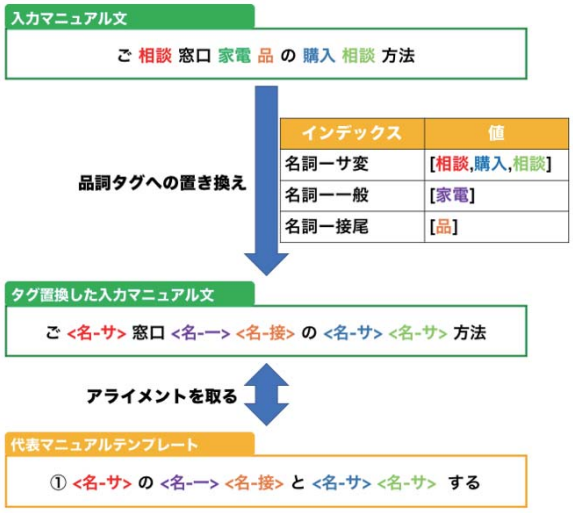


図 3 入力文と代表テンプレートの 対応づけ

レートと代表質問テンプレートの対を候補テンプレート対として出力する.

(2) 質問文中のタグの単語置換

図 4 に示すように品詞単語辞書を用いて, 出力された候補テンプレート対の代表質問テンプレートの品詞タグを単語に置換する.

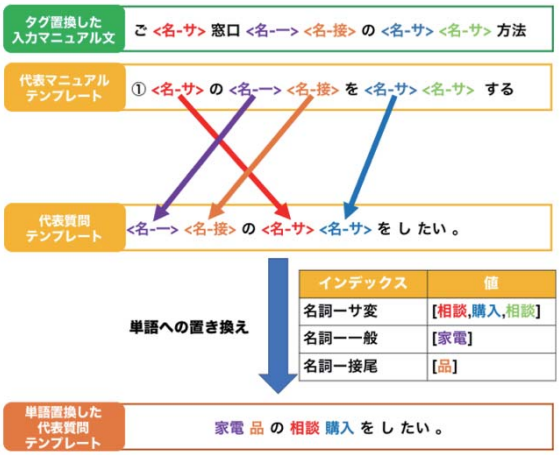


図 4 質問文の単語置換

具体的には代表質問テンプレートの先頭から 1 単語ずつ見ていき, もし品詞タグであった場合, 品詞単語辞書のそのインデックスを持つ単語リストの先頭の単語に置換し, その単語を単語リストから除外する処理を文末まで繰り返す.

3. 実験

実験には公開されている冷蔵庫と炊飯器のマニュアルの各文および質問文を人手で対応づけした 1358 文対を利用した.

3.1 テンプレート生成

まず, 代表テンプレートリストを生成するため, テンプレート生成実験を行なった. MeCab で形態素解析を行う際に, 新語を含むテキストの形態素解析用辞書として, mecab-ipadic-NEologd (https://github.com/neologd/mecab-ipadic-neologd) を用いた.

変化させたパラメタはクラスタ数・テンプレート変数化割合・クラスタリング特徴量である. クラスタ数は 10 および 50 から 300 まで 50 刻みの値で変化させた. テンプレート変数化割合とは質問文の汎化を行なう際に質問文中の単語数のうち品詞タグに変わった割合である. このテンプレート変数化割合が高ければ高いほど, 汎化していると言える. テンプレート変数化割合の閾値とその閾値以上の質問文数を表 1 に示す. また, 1358 文のテンプレート変数化割合の平均は 29%で, 1 単語も変数化しなかった文は 409 文であった. テンプレート変数化割合の閾値は 5~15% の間で変化させた.

クラスタリング特徴量は Unigram, Bigram, Trigram, Unigram + Bigram, Bigram + Trigram, Unigram + Bigram + Trigram, それぞれの TF-IDF を取った特徴量をそれぞれ試した.

評価はシルエット係数[Rousseeuw 1987]を用いた. シルエット係数とは各サンプルについて算出され, k-means などによってクラスタリングされた各サンプルがその割り当てられたクラスタ内にどの程度収まっているかを示す値(1 が最高値, -1 が最低値)である.

表 1 テンプレート変数化割合と質問文数

テンプレート変数化割合の閾値[%]	質問文数[文]
1	949
5	949
10	895
15	811
20	680
25	543

3 つのパラメタを変化させた結果, 全サンプルに対するシルエット係数の平均が大きくなった場合の上位 5 位を表 2 に示す.

表 2 クラスタリング結果

テンプレート変数化割合閾値[%]	クラスタリング特徴量	クラスタ数	平均シルエット係数
15	Unigram + TF-IDF	300	0.23
15	Unigram + TF-IDF	250	0.22
10	Unigram + TF-IDF	300	0.21
15	Unigram + TF-IDF	200	0.2
10	Unigram + TF-IDF	250	0.2

表 2 からテンプレート変数化割合閾値 15%, クラスタリング特徴量 Unigram + TF-IDF, クラスタ数 300 の場合がもっとも平均シルエット係数が高かったため, このクラスタで代表テンプレートリストの生成を行った. またこのリストを用いた場合, 代表文とアライメントが取れる単語数およびその品詞が一致し, 質問文生成可能であると考えられる質問数は 375 文であった. 以下にテンプレート例を 2 つ示す.

(マニュアルテンプレート例 1)
マニュアルテンプレート:<名詞-一般>(<名詞-固有名詞>) 約 8 4 ～ 88分
質問テンプレート: <名詞-一般>で<名詞-固有名詞>を作るとき、どのくらい時間がかかる？
(マニュアルテンプレート例 2)
マニュアルテンプレート: <名詞-一般> の <名詞-一般>
質問テンプレート:<名詞-一般> の <名詞-一般> について

また, クラスタに属するサンプルのシルエット係数をクラスタごとに平均したクラスタシルエット係数平均の分布は図 5 のようになった. このように全体の 96%のクラスタシルエット係数平均が 0 か正の値であった. 以下, このクラスタシルエット係数平均の下限を指定したクラスタを用いて質問生成を行う.

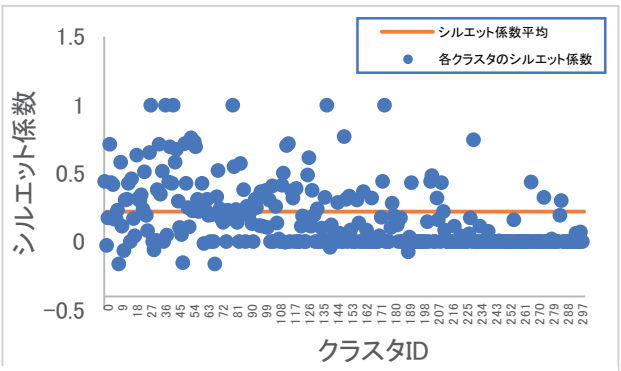


図 5 クラスタシルエット係数平均の分布

3.2 質問文生成

前節で得たテンプレートリストを用いて，質問文生成実験を行なった．人手で作成された正解質問文と生成された質問文の差異を機械翻訳の評価として用いられる BLEU[Papineni 2002]で評価した．また，生成可能である文のうち質問文を生成できた文の割合も評価として用いた．対応割合下限R_{limit}を 60%から 95%まで 5%刻みで変化させ，クラスタシルエット係数平均下限S_{limit}を-0.2(クラスタシルエット係数平均の最低値)から 0.2 まで 0.1 刻みで変化させた結果の BLEU 上位 5 位を表 3 に示す．

表 3 質問文生成結果

対応割合下限[%]	クラスタシルエット係数平均下限	BLEU	平均生成質問数[文]	生成できた割合[%]
70	−0.1	62.11	1.75	93.07
75	−0.1	62.11	1.76	92.53
80	−0.1	62.03	1.77	90.93
75	−0.2	62.02	1.75	93.33
70	−0.2	62.01	1.75	93.87

表 3 で BLEU と質問文を生成できた割合が最も高い対応割合下限 70%，クラスタシルエット係数平均下限-0.1 の場合について生成例を 2 つ示す．

（生成例 1）
入力マニュアル文:「うま早」「お急ぎ」はできません
正解質問文:寿司用のご飯を「お急ぎ」で炊きたい 。
生成質問文 1:寿司用のご飯を「お急ぎ」で炊きたい 。
生成質問文 2:中華粥を「お急ぎ」で炊きたい 。
[ほか 9 文，同様の炊飯器でできる調理質問が出力された]
（生成例 2）
入力マニュアル文:①音が急に大きくなる。音色が変わる→お使い始め、暑いとき、ドアの開け閉めが多いなどのときに高速運転に切り替わり、強い力で冷やします
正解質問文:音が大きくなった
生成質問文:音が大きくなった

生成例から，正解とは異なるが自然な質問文が得られていることおよび正解文と同様の質問文が得られていることがわかる．

また，生成結果が人手作成と同一でない生成文について，被験者による 5 段階の評価尺度(MOS 値)による主観評価を実施した．表 4 に実験設定，図 6 にその結果を示す．

表 4 実験設定

項目	詳細
被験者	12 人(男性 7 人，女性 5 人)
人手作成文	ランダム抽出した(生成不可文を除く)50 文中，人手生成文と異なる結果であった 26 文
自動生成質問文	上記に対応する自動生成質問文 38 文（N ベストを含む）
評価尺度(MOS 値)	5:非常に良い，4:良い，3:どちらでもない，2:悪い，1:非常に悪い，の 5 段階評価

生成文のうち 48%が人手作成文と同じ文となったが，図 6 からもわかるように残りの 52%の生成文の約 6 割(生成文全体の 30.1%)が MOS 値 4 以上となった．同一文を除く生成文の MOS 値平均は 3.50 で人手作成文は 4.25 であった．これらから，生成文全体のうち 78.1%が人手作成文と同一か主観評価 4 以上であることを確認できた．

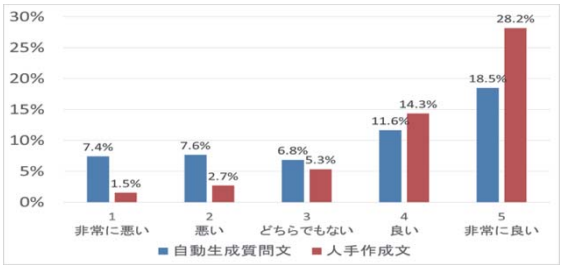


図 6 同一文を除く文の MOS 値比較

4. おわりに

本研究ではマニュアル文から関連する質問文を自動生成する手法を示した．実験の結果，人手作成文を正解として，BLEU スコア 62.11 が得られるとともに，生成文全体のうち 78.1%が人手作成文と同一か主観評価 4 以上であることが確認できた．

今後の課題は大きく分けて 2 点考えられる．第一にクラスタリングの精度の向上による代表テンプレートリストの改善と穴埋めアルゴリズムの改良を行い，よりよい質問文を増やすことである．第二に解答文生成システムも同様に構築し，製品マニュアルに書かれている記述から，関連する質問応答対を自動生成するシステムを構築する予定である．

参考文献

[Heilman 2009] Michael Heilman et al.: Question Generation via Overgenerating Transformations and Ranking , *CARNEGIE-MELLON UNIV PITTSBURGH PA LANGUAGE TECHNOLOGIES INST*, 2009.

[Zhao 2011] Shiqi Zhao et al.: Automatically generating questions from queries for community based question answering , *Proceedings of the 5th International Joint Conference on Natural Language Processing* , pp.929-937, 2011.

[Yuan 2017] Xingdi Yuan et al.: Machine Comprehension by Text-to-Text Neural Question Generation, *Proceedings of the 2nd Workshop on Representation Learning for NLP* , Association for Computational Linguistics , pp.15-25, 2017.

[村上 2016] 村上 聡一朗, 他.: 打者成績からのイニング速報の自動生成, *言語処理学会 第 22 回年次大会 発表論文集*, pp.338-341, 2016.

[Jing 1999] Hongyan Jing et al.: The decomposition of human-written summary sentences, *Proceedings of the 22nd annual international ACM SIGIR conference on Research and development in information retrieval*, pp.129-136, 1999.

[Rousseeuw 1987] Peter J.Rousseeuw: Silhouettes: A graphical aid to the interpretation and validation of cluster analysis, *Journal of Computational and Applied Mathematics 20* , pp.53-65, 1987.

[Papineni 2002] Papineni et al.: BLEU: A Method for Automatic Evaluation of Machine Translation, *Proceedings of the 40th Annual Meeting on Association for Computational Linguistics*, pp.311-318, 2002.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

自然言語のSPARQLクエリ変換に基づく構造化知識へのアクセス手法の開発

Development of an Access Method to Linked Open Data through Converting Natural Language into SPARQL Queries

村山 友理 *1 Yuri Murayama　小林 一郎 *1 Ichiro Kobayashi　森田 武史 *2 Takeshi Morita　中野 有紀子 *3 Yukiko Nakano　山口 高平 *2 Takahira Yamaguchi

*1お茶の水女子大学 Ochanomizu University　*2慶應義塾大学 Keio University　*3成蹊大学 Seikei University

In recent years, vast amount of knowledge in various fields is open to the public on the Web. This knowledge will be helpful for understanding the meaning of natural language if it is used in a natural language processing system. With this background, we propose a method to emphasize on making a link between the information extracted from natural language input and the knowledge. Besides, as an experiment to evaluate our proposed method, we are planning to introduce our method to service interaction at a robot cafe.

1. はじめに

現在，Linked Open Data (LOD) として様々な分野の膨大な知識がデータとして Web 上に公開されている．これらの大量の知識を自然言語処理システムの中に組み込むことができれば，自然言語理解における背景知識として利用可能になるなど，従来のシステムを超えた優れたシステムが実現されると考えられ，それらのデータを自然言語と結びつけるための様々な取り組みが進められている [Wang 07, Lei 14, 鈴木 15, Shekarpour 17, 高山 17]．基本的な問題として，自然言語の表現から LOD のように形式的に記述されている知識にアクセスするために，自然言語文からデータレポジトリにアクセスするクエリ言語に変換できるようにすることを対象に研究が行われている．

本研究では，先行研究のアプローチを踏まえて，自然言語文から抽出した情報に知識のリレーションを紐づけることに重点を置いた手法の提案を行う．また，提案手法を評価する具体的な実験として，ロボットが喫茶店でお客さんから注文をとる場面を想定して，そこで発生する質問に回答するための知識を取得するためにユーザの質問文から SPARQL クエリを自動生成することを考える．

2. 提案手法

本研究で提案する手法の概要を図 1 に示す．

本研究の提案手法における，自然言語質問文から SPARQL クエリを自動生成する手続きについて以下に示す．

1. 自然言語質問文の構文解析からのトリプル候補の抽出
   京都大学黒橋河原研究室で開発された日本語構文・格・照応解析システム KNP[*1] を用いて，自然言語質問文を解析し，語彙の依存関係および述語項構造を抽出する．述語項構造の解析結果の内，述語に対して項を 2 つ持つものから候補の RDF トリプル（以下，トリプルと呼ぶ）として（述語，項 1，項 2）を抽出する．トリプルがとる各単語について WordNet を用いてその類義語を調べる．これは，Wang ら [Wang 07] の手法で用いているように，自然言語質問文中の表層表現や類義語がデータレポジトリ中の RDF トリプルを記述されている語彙になっている可能性があり，そのような知識に対して柔軟なアクセスができるように配慮するためである．

2. 述語から質問タイプを判別
   候補のトリプルの述語に基づき，質問タイプを判別する．本研究で設定した述語の種類ごとの質問タイプの分類を表 1 に示す（表 1 に示す質問タイプについては 3. 章に詳述する）．この段階では，項 1，項 2 はまだ未確定なのでそれぞれ`?x0`,`?x1` としておく．例えば，述語が “含む” であれば基本型と判定されることから，テンプレートとして {`?x0 ????  ?x1.`} が与えられる．

3. 項の属性を判定
   候補のトリプルの項に注目して，その属性がクラス，インスタンス，リテラルのいずれであるかを判定する．クラスとインスタンスの判定は，オントロジーに沿って事前に作成した辞書を用いて行い，単語が辞書に存在しない場合はリテラルと判断する．クラスと判定された場合はトリプルパターン {`?x rdf:type :`クラス名 } を追加する．インスタンスだった場合は ’`?x`’ を ’`:`インスタンス名 ’ に変換する．リテラルの場合は変数のままにしておく．

4. 語彙表現からの回答対象候補の特定
   質問文中の語彙表現によって質問の答えになる回答対象候補を特定する．候補を特定する語彙表現として，“どんな”，“はありますか”，“は何ですか” を採用する．質問文中に “どんな” が現れた場合はその直後に来る単語を，“はありますか” と “は何ですか” の場合は直前にくる単語を回答対象候補とし，それに対応する変数を `SELECT DISTINCT` 後の変数リストに加える．

5. 知識への問合せによるリレーション候補の決定
   上記の処理によって作成した SPARQL クエリの`????`の部分を`?rel` に，`SELECT DISTINCT` 後の変数を一旦`?rel` にしてリレーションの候補を知識に問い合わせることにより決定する．

6. SPARQL クエリの完成
   リレーションの候補の検索結果において，各リレーション

連絡先: 村山友理，お茶の水女子大学理学部情報科学科小林研究室，〒 112-8610 東京都文京区大塚 2-1-1，g1420534@is.ocha.ac.jp

*1 http://nlp.ist.i.kyoto-u.ac.jp/index.php?KNP

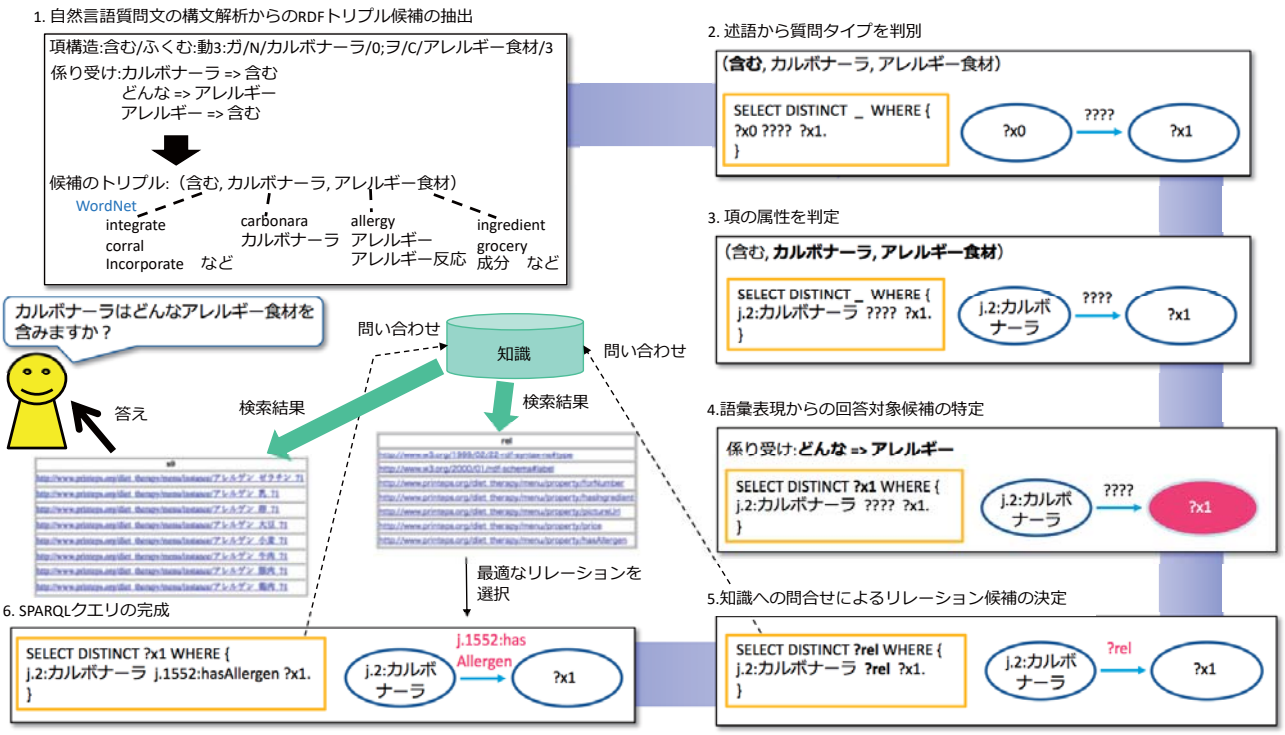


図 1: 提案手法の概要

候補と，ステップ 1 で WordNet を使って調べておいたトリプルの各単語の類義語すべての文字列のバイグラムを取り（例えば，{ha,as,sA,Al,ll,le,er,rg,ge,en} と {al,ll,le,er,rg,gy}），Jaccard 係数によって類似度を求め，定めた閾値を超えた候補を最適なリレーションと決定する．閾値以上の候補が複数存在する場合は，Zipf の法則に従いより希少な方を最適なリレーションとして選択する．以上の手続きにより入力された自然言語質問文の内容を反映した SPARQL クエリを完成させる．

3. 質問タイプ

“含む”，“使う” などの述語は基本型としてテンプレートで {?x0 ???? ?x1.} を与える．“低い” のような「程度」を問い合わせる述語は Degree 型とし，テンプレートで {?x0 ???? ?x1. ?x1 j.1552:amount ?amount.} を与える．本研究では，知識のドメインを料理のメニューに限定しているため，程度に対する問い合わせは「量」への問い合わせであるとする．ORDER BY ASC(?amount) LIMIT 3 により，量によって答えを昇順に並べ上位 3 つを返すように設定している．候補のトリプル中に “何種類 “という単語が含まれる場合，Count 型とし，テンプレート {?x0 rdf:type :クラス名.} と項目の数を数える COUNT 関数を与える．“どんなパスタがありますか？“の場合は，KNP を用いて三つ組の情報を得られないため，提案手法のステップ 2，3，5 を除いて SPARQL クエリを生成する．ある単語が “どんな” と “がありますか” の 2 つのキーワードに挟まれた場合，該当する項目をすべて回答する List 型に分類されるとする．“～含まれますか？“のような受け身型の場合，まずは “～含みますか？“のような能動態のときと同じように項 1，項 2 をそれぞれ?x0,?x1 として SPARQL クエリに変形してゆき，ステップ 5 でリレーションの候補を知識に問い合わせ答えが返ってこなかったら，リレーションの矢印の向きを反対にする，つまり {?x0 ?rel ?x1.} の部分を {?x1 ?rel ?x0.} に修正して再度リレーションの候補を知識に問い合わせる．

4. 実験

喫茶店におけるメニューに関して，本研究で設定した 5 つの質問タイプに基づく自然言語質問文を受けた際の提案手法の有効性を検証する．

4.1 実験設定

図 2 に本研究で利用するメニューオントロジーの一部を示す．

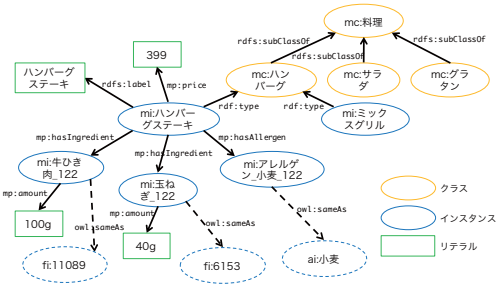


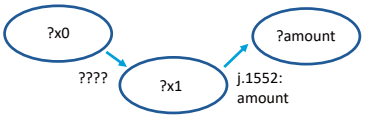
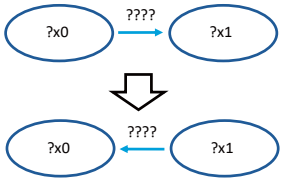
図 2: メニューオントロジーの一部

Virtuoso (version 07.20.3214)，SPARQL 1.1 を使用した．

4.2 実験結果と考察

提案手法の実装を行い，表 1 の例文に挙げた「カルボナーラはどんなアレルギー食材を含みますか？」「トマトを使ったパスタはありますか？」「塩分の低いパスタは何ですか？」「ハ

表 1: 質問タイプの分類

型	述語	例文と候補のトリプル	SPARQLクエリのテンプレート	RDFグラフのテンプレート
基本型	含む 使う	カルボナーラはどんなアレルギー食材を含みますか？ （含む, カルボナーラ, アレルギー食材） トマトを使ったパスタはありますか？ （使う, パスタ, トマト）	SELECT DISTINCT _ WHERE { ?x0 ???? ?x1. }	
Degree型	低い 高い	塩分の低い/高いパスタは何ですか？ （低い/高い, パスタ, 塩分）	SELECT DISTINCT _ WHERE { ?x0 ???? ?x1. ?x1 j.1552:amount ?amount. } ORDER BY ASC/DSEC(?amount) LIMIT 3	
Count型	----	ハンバーグは何種類ありますか？ （有る, ハンバーグ, 何種類）	SELECT DISTINCT (COUNT(?x0) as ?count) WHERE { ?x0 rdf:type :クラス名. }	
List型	----	どんなパスタがありますか？ （有る, パスタ, ----） ※三つ組なし	SELECT DISTINCT ?x0 WHERE { ?x0 rdf:type :クラス名. }	
受け身型	----	どんなアレルギー食材がカルボナーラには含まれますか？ （含む,アレルギー食材,カルボナーラ）	SELECT DISTINCT _ WHERE { ?x0 ???? ?x1. } ⇩ SELECT DISTINCT _ WHERE { ?x1 ???? ?x0. }	

ンバーグは何種類ありますか？」「どんなハンバーグがありますか？」「どんなアレルギー食材がカルボナーラには含まれますか？」の 6 文に対して実験を行った．また,「塩分が低くて，トマトを使ったパスタはありますか？」のように Degree 型と基本型を組み合わせた，述語を 2 つ含む文に対しても実験を行った．この具体的な処理の流れを図 3 に示す．

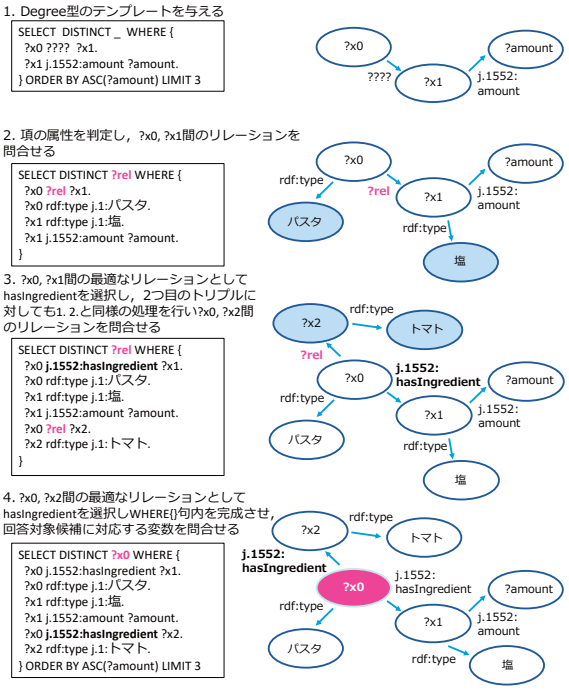


図 3: 例「塩分が低くて，トマトを使ったパスタはありますか？」の処理の流れ

まず，KNP を用いて（低い，パスタ，塩分）,（使う，パスタ，トマト）の 2 つの候補のトリプルを抽出する．1 つ目のトリプル（低い，パスタ，塩分）に対し，提案手法のステップ 2 により Degree 型のテンプレートを与える．ステップ 3 により項の属性の判定をし，`?x0,?x1` 間のリレーションを知識に問い合わせ最適なものとして `hasIngredient` を選択する．次に，2 つ目のトリプル（使う，パスタ，トマト）に対しても同様の処理を行いクエリの `WHERE {}` 句内を完成させる．最後に，ステップ 4 により特定した回答対象候補に対応する変数を `SELECT DISTINCT` 後の変数リストに加え，求める SPARQL クエリを生成する．

表 2 に示すように，各質問タイプにおいてそれぞれ適切な SPARQL クエリを生成し，知識から正確な回答を得ることができた．

5. おわりに

KNP による述語項構造・係り受け解析と，データ主導による RDF トリプルの変形を用いた，自然言語から SPARQL クエリへ変換する手法を提案した．エンティティを知識側の語彙と対応付け，エンティティ間のリレーションを知識から獲得することによって，SPARQL クエリが完成されれば答えは保証される．また，基本型，Degree 型，Count 型，List 型，受け身型の 5 つの質問タイプを設定した．提案手法の実装を行い，設定した質問タイプの自然言語質問文及び，より一般化した，それらを組み合わせた質問文に対してそれぞれ適切な SPARQL クエリを生成することができた．

今後の課題として，否定や接続詞を扱えるように質問タイプを拡張すること，DBpedia などの知識にも対応することと，エンティティ間のリレーションを決める際に，Knowledge Embedding の手法を用いて SPARQL クエリを生成することに取り組んでいきたい．

表 2: 各質問タイプにおける知識抽出結果

型	自然言語質問文	生成された SPARQL クエリ	知識から得られた回答
基本型	カルボナーラはどんなアレルギー食材を含みますか？	SELECT DISTINCT ?x1 WHERE { j.2:カルボナーラ j.1552:hasAllergen ?x1. }	アレルゲン_ゼラチン_71，アレルゲン_小麦_71 アレルゲン_乳_71，アレルゲン_牛肉_71 アレルゲン_卵_71，アレルゲン_豚肉_71 アレルゲン_大豆_71，アレルゲン_鶏肉_71
	トマトを使ったパスタはありますか？	SELECT DISTINCT ?x0 WHERE { ?x0 j.1552:hasIngredient ?x1. ?x0 rdf:type j.1:パスタ. ?x1 rdf:type j.1:トマト. }	トマトクリームスパゲッティ ミートソースボロニア風 半熟卵のミートソースボロニア風
Degree 型	塩分の低いパスタは何ですか？	SELECT DISTINCT ?x0 WHERE { ?x0 j.1552:hasIngredient ?x1. ?x0 rdf:type j.1:パスタ. ?x1 rdf:type j.1:塩. ?x1 j.1552:amount ?amount. } ORDER BY ASC(?amount) LIMIT 3	パルマ風スパゲッティ ミートソースボロニア風 半熟卵のミートソースボロニア風
Count 型	ハンバーグは何種類ありますか？	SELECT DISTINCT (COUNT(?x0) as ?count) WHERE { ?x0 rdf:type j.1:ハンバーグ. }	6
List 型	どんなハンバーグがありますか？	SELECT DISTINCT ?x0 WHERE { ?x0 rdf:type j.1:ハンバーグ. }	イタリアンハンバーグ ハンバーグステーキ ミックスグリル 焼肉とハンバーグの盛合せ 煮込みハンバーグ 野菜ソースのハンバーグ
受け身型	どんなアレルギー食材がカルボナーラには含まれますか？	SELECT DISTINCT ?x0 WHERE { j.2:カルボナーラ j.1552:hasAllergen ?x0. }	アレルゲン_ゼラチン_71，アレルゲン_小麦_71 アレルゲン_乳_71，アレルゲン_牛肉_71 アレルゲン_卵_71，アレルゲン_豚肉_71 アレルゲン_大豆_71，アレルゲン_鶏肉_71
Degree 型 ＋ 基本型	塩分が低くて，トマトを使ったパスタはありますか？	SELECT DISTINCT ?x0 WHERE { ?x0 j.1552:hasIngredient ?x1. ?x0 rdf:type j.1:パスタ. ?x1 rdf:type j.1:塩. ?x1 j.1552:amount ?amount. ?x0 j.1552:hasIngredient ?x2. ?x2 rdf:type j.1:トマト. } ORDER BY ASC(?amount) LIMIT 3	ミートソースボロニア風 半熟卵のミートソースボロニア風 トマトクリームスパゲッティ

謝辞

本研究は，科学技術振興機構 (JST) 戦略的創造研究推進事業 (CREST)「実践知能アプリケーション構築フレームワーク PRINTEPS の開発と社会実践」(JPMJCR14E3) の支援によって実施した．

参考文献

[Wang 07] Chong WangMiao XiongQi ZhouYong Yu, PANTO: A Portable Natural Language Interface to Ontologies, European Semantic Web Conference ESWC 2007: The Semantic Web: Research and Applications pp.473-487, 2007.

[Lei 14] Zou, Lei and Huang, Ruizhe and Wang, Haixun and Yu, Jeffrey Xu and He, Wenqiang and Zhao, Dongyan, Natural Language Question Answering over RDF: A Graph Data Driven Approach, Proceedings of the 2014 ACM SIGMOD International Conference on Management of Data, pp.313–324, Snowbird, Utah, USA, 2014.

[鈴木 15] 鈴木遼司, 三輪誠, 佐々木裕： 交通オントロジーを対象とした質問文の SPARQL クエリ変換, 第 21 回言語処理学会年次大会, P2-13, pp.171-174, 京都, 2015.

[Shekarpour 17] Saeedeh Shekarpour, Edgard Marx, Soren Auer, Amit Sheth, RQUERY: Rewriting Natural Language Queries on Knowledge Graphs to Alleviate the Vocabulary Mismatch Problem, the Thirty-First AAAI Conference on Artificial Intelligence (AAAI-17), San Francisco, CA, February 4-9, 2017.

[高山 17] 高山隼矢, 三輪誠, 佐々木裕： 交通オントロジーに基づく質問応答データセットの構築, 第 23 回言語処理学会年次大会, P14-3, 2017.

[Bordes 11] Antoine Bordes, Jason Weston, Ronan Collobert, Yoshua Bengio, Learning Structured Embeddings of Knowledge Bases, the Twenty-Fifth AAAI Conference on Artificial Intelligence, pp. 301-306, San Francisco, California, August 07 - 11, 2011.

[Mittal 17] Sudip Mittal, Anupam Joshi, Tim Finin, Thinking, Fast and Slow: Combining Vector Spaces and Knowledge Graphs, arXiv:1708.03310v2 [cs.AI],21 Aug 2017.

[大貫 17] 大貫陽平, 貫井駿, 村田剛志, 稲木誓哉, 邱シュウレ, 渡部雅夫, 岡本洋：DNN による RDF 上の単語間の関係の予測, 人工知能学会 セマンティックウェブとオントロジー研究会,SIG-SWO-041-02, 福岡,2017.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

絵本に対する子どもの認知発達的反応に着目した絵本レビュー・発達心理学文献の比較

Comparison of Reviews on Picture Books and Developmental Psychology Literature focusing on Infants' Developmental Reactions to Picture Books

笠松 美歩[*1] 上原 宏[*1*2] 宇津呂 武仁[*1] 齋藤 有[*3]
Miho Kasamatsu Hiroshi Uehara Takehito Utsuro Yu Saito

[*1]筑波大学大学院システム情報工学研究科 [*2]秋田県立大学システム科学技術学部
Grad. Sch. Sys. & Inf. Eng, Univ. of Tsukuba Fclty. Sys. Sci. & Tech., Akita Pref. Univ.

[*3]聖徳大学 児童学部
Fclty. Child Studies, Seitoku Univ.

In order to examine how the stimuli of picture books induces a variety of reactions in infants, we take an approach of applying a text mining technique to a large amount of the reviews on picture books written by their parents or the childcare personnel. This paper especially studies the relation between the contents of picture books and an infant's developmental reactions. We further classify subcategories of an infant's developmental reactions as well as picture books according to the contents of picture books, and compare them with examples of infants' developmental reactions reported in the developmental psychology literature. We conclude that the proposed approach of applying a text mining technique to the reviews on picture books is quite effective.

1. はじめに

本論文では，従来の発達心理学研究における方式のように，養育者や保育者が子どもに絵本の読み聞かせを行う様子を収録し，その内容を 1 つ 1 つ分析する方式とは異なり，絵本のレビューが書き込まれるサイトを情報源として，絵本に対する子どもの認知発達的反応が描写された絵本レビューを収集してこれを分析対象とする方式を提案する．本論文で情報源とする絵本レビューサイトにおいては，実際に絵本の読み聞かせを行った養育者や保育者が，絵本の読み聞かせを行なった際の様子や絵本への感想，絵本に対する子どもの反応の有無やその反応の様子など，多岐多様な情報を記載している．本論文では，特に，それらの絵本レビューの中から，実際に絵本に対する子どもの認知発達的反応の様子が大規模に収集可能であることを示す．さらに，本論文では，0~6 歳の子どもが絵本に対して認知発達的反応をする場合の中心的な反応の事例として，「じっと見る・じっと聞く」，「指さす」，「真似をする」，「ごっこをする」，「物語に入り込む・感情移入する」の 5 種類の反応に着目し，絵本レビューよりそれらの反応事例を網羅的に収集する．また，それとともに，それらの子どもの反応が特に多く観測される絵本タイトルもあわせて網羅的に収集する．本論文において以上を行なった結果，子どもの反応が特に多く観測される絵本タイトルとして全 44 冊を選定することができた．さらに，上述の 5 種類の反応別にこれらの全 44 冊の絵本を特徴付けたところ，絵本と反応の組合せにして合計 64 組の組合せを認定することができた．また，これらの組合せ全体で観測された子どもの反応の推定総数は，約 770 例となった．さらに，上述の 5 種類の子どもの反応に対して，子どもの反応の詳細および絵本の特徴に基づく下位分類を行うことによって，子どもの反応および絵本の類型化を行なった．その結果，5 種類の反応全体において合計 13 種類の下位分類を設定することができた．

また，本論文では，既存の発達心理学文献を対象として絵本に対する子どもの認知発達的事例を収集し，絵本レビューを情報源とする絵本事例収集結果，および，子どもの認知発達的反応の収集・類型化の結果と，既存の発達心理学文献における知見との間で比較分析を行った．その結果，本論文の提案方式によって絵本レビューから収集した子どもの認知発達的反応事例によって，従来の発達心理学文献における知見を裏付けることができた．さらに，発達心理学文献での報告事例の規模・種類とも上回る子どもの認知発達的事例を収集・類型化することができた．以上の結果によって，本論文の提案方式が有効であることを示すことができた．

連絡先: 笠松 美歩，筑波大学大学院システム情報工学研究科，〒 305-8573 茨城県つくば市天王台 1-1-1, 029-853-5427

2. 絵本レビューサイト「絵本ナビ」

本論文では，絵本情報サイト「絵本ナビ」[*1] に読者が書き込んだレビュー (以降，レビュー) を分析の対象とする．絵本ナビは，絵本および児童書約 70,200 タイトルに関する出版社，著者，あらすじなどの基本情報の他，大量のレビュー (2018 年 3 月現在で約 36 万 2 千レビュー) が書き込まれる国内最大級の絵本および児童書に特化した情報サイトである．多くのレビューにおいて，絵本の読み手 (以降，レビュアー) の感想や行動を描写した記述と，聞き手である子どもの反応を描写した記述が混在している．文献 [上原 15] では，絵本ナビ中のレビューを人手分析し，絵本に対する子どもの反応の描写が含まれる割合について報告している．

3. 分析対象とする子どもの年齢および絵本

本論文では，絵本レビューにおいて分析対象とする子どもの年齢を 0~6 歳とする．また，本論文で分析対象とする絵本を選定する際には，絵本ナビにおけるレビュー数ランキングの上位 100 作品を候補とする．そして，この 100 作品中の絵本の各々を b，1. 節で述べた 5 種類の反応表現の各々を e，0~6 歳の子どもの年齢の整数値の各々を a として，年齢 a の子どもを対象とした絵本 b についての全レビューのうちで，反応表現 e が出現したレビュー数を $f(b, a, e)$ で表す．次に，それらの $f(b, a, e)$ 件のレビューに対して人手によって，「当該反応表現 e の描写対

[*1] http://www.ehonnavi.net

象が実際に子どもの反応か否か」の判定を行い，$f(b,a,e)$ 件のうち実際に子どもの反応が描写されていたレビューの件数を $f_c(b,a,e)$ によって表す (ただし，$f(b,a,e) > 10$ の場合には，10 件を無作為抽出して子どもの反応の有無の人手判定を行うことによって $f_c(b,a,e)$ の推定値を算出する)．そして，全年齢 (0~6 歳) および全表現における子どもの反応の観測数の総和が 8 以上 (次式)

$$\sum_{a,e} f_c(b,a,e) \quad \geq \quad 8$$

となる絵本 44 冊を分析対象とする．

4. 子どもの認知発達的反応を用いた絵本の分類および発達心理学文献の調査

次に，各絵本 b に対して，その絵本の特徴を示す子どもの反応表現ごとに絵本を分類し，これを絵本および子どもの反応の大分類とする．ここで，全 5 種類の反応表現「じっと」,「指さし」,「真似」,「ごっこ」,「入り込んで+感情移入」のうちの「じっと」については，反応の特徴を精査して，

- 対象年齢が 0~1 歳が中心となり,「(意味は理解していないかもしれないが) 絵をじっと見る・音をじっと聞く」という反応，および，
- 2 歳以上が中心となり,「感情移入してお話をじっと聞く」という反応，

に二分する．特に後者については,「入り込んで＋感情移入」という反応を伴う場合も多く，相互に重複する事例が多く観測されるため，両者を融合したものを 1 つの大分類とし，合計で以下の 5 分類とする．

(a) 「じっと」(0~1 歳中心)((意味は理解していないかもしれないが) 絵をじっと見る・音をじっと聞く)
(b) 「指さし」
(c) 「真似」
(d) 「ごっこ」
(e) 「じっと (2 歳以上中心)」＋「入り込んで+感情移入」(感情移入してお話をじっと聞く)

次に，以下に示す 3 段階を経て，絵本の分類を行った．

段階 1 絵本に対する反応の 13 下位分類 (表 1 および表 2) を作成し，分析対象絵本 44 冊における 50 絵本・年齢・反応組を 13 下位分類に分類．

段階 2 「その他」以外の 13 下位分類中の 50 絵本・年齢・反応組の頻度条件を導出．

段階 3 分析対象絵本 44 冊に対し，50 絵本・年齢・反応組が満たす頻度条件を再適用し，14 絵本・年齢・反応組を選定．

さらに，13 下位分類の各「下位分類」ごとに発達的心理学文献の調査を行ない，その詳細な調査・比較結果を表 1・表 2「各反応の実例が出現する発達心理学論文，書籍」他の欄に示す．

この結果から分かるように，いくつかの下位分類を除いて，多くの下位分類において，発達心理学文献において，それぞれの下位分類に該当する子どもの反応事例が報告されている．しかし，各下位分類ごとに，発達心理学文献全体での子どもの反応の報告事例数は約数件から 1 件程度であり，絵本の種類数も約数種類から 1 種類程度である．一方，本論文において，絵本レビューから子どもの反応が抽出された絵本の種類数は，各下位分類ごとに絵本の種類数が数種類程度あり，しかも，子どもの反応が観測された絵本レビュー数の総数は，表 1 および表 2 で対象とした子どもの反応全体で 770 例以上 (この収集元は，子どもの反応表現の観測総数 (推定値)1,389 例であり，このうち，表 1 および表 2 の大分類に該当する事例数が 770 例以上である) である．また，下位分類「その他」を除くと，各下位分類ごとに，約 20 例程度から多いもので 100 例以上，平均して 50 例以上である．また，子どもの反応の下位分類別に，子どもの反応が収集できた絵本レビュー数は，絵本間で平均して 12 例以上であり，以上の結果から，発達心理学文献における報告数よりもはるかに多くの事例を観測できていることが分かる．本論文の方式によって，絵本レビューから子どもの認知発達的反応を収集することによって，従来の発達心理学文献での知見を裏付けるとともに，発達心理学文献での報告事例の規模・種類とも上回る事例を収集することができた．よって，本論文の提案方式が有効であることを示すことができた．

5. おわりに

本論文では，絵本レビューから収集した子どもの認知発達的反応事例によって，従来の発達心理学文献における知見を裏付けるとともに，発達心理学文献での報告事例の規模・種類とも上回る子どもの認知発達的事例を収集・類型化できた．

参考文献

[秋田 98] 秋田喜代美：読書の発達心理学 子どもの発達と読書環境, 国土社 (1998).

[古市 14] 古市久子：こどもの動きを引き出すオノマトペ絵本, 東邦学誌, Vol. 43, No. 2, pp. 87–104 (2014).

[近藤 12] 近藤文里, 辻元千佳子：絵本の選択が ADHD 児の読み聞かせに及ぼす効果 (5) — 絵本におけるオノマトペの作用 —, 滋賀大学教育学部紀要 教育科学, No. 62, pp. 15–29 (2012).

[仲本 04] 仲本美央：現在の赤ちゃん絵本と周辺研究の動向, 育英短期大学研究紀要, No. 21, pp. 33–44 (2004).

[齋藤 12] 齋藤有：子どもの主体性を促す「共有型」養育態度の関わり: 安定した対話パタンへの着目, お茶の水女子大学グローバル COE プログラム「格差センシティブな人間発達科学の創成」, pp. 73–81 (2012).

[齋藤 13a] 齋藤有, 内田伸子：母親の養育態度と絵本の読み聞かせ場面における母子相互作用の関係に関する長期縦断的検討, 読書科学, Vol. 55, 1・2, pp. 56–67 (2013).

[齋藤 13b] 齋藤有, 内田伸子：幼児期の絵本の読み聞かせに母親の養育態度が与える影響: 「共有型」と「強制型」の横断的比較, 発達心理学研究, Vol. 24, No. 2, pp. 150–159 (2013).

[佐々木 93] 佐々木宏子：絵本と子どものこころ, JULA 出版局 (1993).

[佐々木 06] 佐々木宏子：絵本は赤ちゃんから 母子の読み合いがひらく世界, 新曜社 (2006).

[佐藤 07] 佐藤公治, 西山希：絵本の集団読み聞かせにおける楽しさの共有過程の微視発生的分析, 北海道大学大学院教育学研究紀要, No. 100, pp. 29–49 (2007).

[関根 12] 関根佐也佳：乳児期における絵本読み場面の母子相互行為の変化: 縦断的観察による分析, 人間文化創成科学論叢, Vol. 15, pp. 221–229 (2012).

[関根 14] 関根佐也佳：乳幼児期の絵本場面における母親の演出行動と質問行動の役割: 情緒的な相互行為促進に影響を及ぼす行動様式の検討, お茶の水女子大学子ども学研究紀要, No. 2, pp. 55–64 (2014).

[菅井 11] 菅井洋子：乳児期の読書環境構成に関する発達研究–絵本場面における実物への指さしを中心として, 発達研究, Vol. 25, pp. 69–78 (2011).

[外山 89] 外山紀子：絵本場面における母親の発話, 教育心理学研究, Vol. 37, No. 2, pp. 151–157 (1989).

[角田 03] 角田巌：子どもと絵本における相互主観性の成り立ち, 人間科学研究, No. 25, pp. 53–62 (2003).

[上原 15] 上原宏, 馬場瑞穂, 宇津呂武仁：発達心理学の観点から見た絵本レビュー中の子供の反応の分析, 言語処理学会第 21 回年次大会論文集, pp. 832–835 (2015).

表 1: 絵本レビュー中の子どもの認知発達的反応に基づく絵本の分類および発達心理学文献との比較 (1)

絵本の特徴を示す子どもの反応	反応の詳細および絵本の特徴に基づく下位分類		子どもの年齢	提案手法によって分類された絵本冊数 / 絵本タイトル	各反応の実例が報告された発達心理学論文・書籍 / 絵本冊数 / 絵本タイトル / 子どもの年齢
じっと (0~1 歳が中心) (意味は理解していないかもしれないが) 絵をじっと見る・音をじっと聞く	オノマトペとシンプルな絵が特徴の絵本において，特にその特徴に対して反応する		0~1 歳	5 冊 / がたんごとんがたんごとん / ごぶごぶ ごぼごぼ / じゃあじゃあびりびり / ぴょーん / もこ もこもこ	佐々木 [佐々木 06] / 1 冊 / 桃太郎 / 0 歳
	顔の描画が特徴的な絵本において，特にその特徴に対して反応する		0~1 歳	4 冊 / いいおかお / いないいないばあ / おつきさまこんばんは / おひさまあはは	仲本 [仲本 04] / 1 冊 / かお かお どんなかお / 年齢不詳
	カラフルな色彩など絵が特徴の絵本において，じっと見るなどの反応をする		0~1 歳	5 冊 / きゅっきゅっきゅっ / はらぺこあおむし / わたしのワンピース / あおくんときいろちゃん / おててがでたよ	該当する論文，書籍なし
	その他		1 歳	1 冊 / しょうぼうじどうしゃじぷた	該当する論文，書籍なし
指さし	紛らわしい絵柄の中に絵本の中の登場物を描いた絵本において，挿絵の中から目的の対象物を探す		1~2 歳	3 冊 / うずらちゃんのかくれんぼ / きんぎょがにげた / たべたの だあれ	関根 [関根 14] / 1 冊 / きんぎょがにげた / 1 歳
	具体的な物体が描かれた絵本が対象	具体物を描いた挿絵を指さす	1~2 歳	6 冊 / がたんごとんがたんごとん / おやすみなさいおつきさま / しろくまちゃんのほっとけーき / ぞうくんのさんぽ / たまごのあかちゃん/ はらぺこあおむし	外山 [外山 89] / 1 冊 / 絵本不明 / 1 歳から 2 歳のいずれかの年齢
		絵本外の実世界において，挿絵の中の具体物と対応する実物を指さす	1~2 歳	1 冊 / だるまさんの	菅井 [菅井 11] / 4 冊 / あーんあん / ここです / きんぎょがにげた / ノンタンの絵本 / 1~2 歳
	挿絵の中で多数の登場物が小さく細かく描かれた絵本において，関心のある部分を指さす		2~3 歳	2 冊 / 14 ひきのあさごはん / からすのパンやさん	秋田 [秋田 98] / 1 冊 / からすのパンやさん/ 3 歳
	その他		1~3 歳	3 冊 / きゅっきゅっきゅっ / こんとあき / よるくま	齋藤・内田 [齋藤 13a] / 3 冊 / おふろだおふろだ / こいぬがうまれるよ / はじめてのおつかい / 2 歳，5 歳
					齋藤・内田 [齋藤 13b] / 1 冊/ きつねのおきゃくさま / 3 歳，5 歳
					佐々木 [佐々木 06] / 1 冊 / ちへいせんのみえるところ / 1 歳
					関根 [関根 12] / 1 冊 / ノンタンスプーンたんたんたん / 1 歳

表 2: 絵本レビュー中の子どもの認知発達的反応に基づく絵本の分類および発達心理学文献との比較 (2)

絵本の特徴を示す子どもの反応	反応の詳細および絵本の特徴に基づく下位分類		子どもの年齢	提案手法によって分類された絵本冊数 / 絵本タイトル	各反応の実例が報告された発達心理学論文・書籍 / 絵本冊数 / 絵本タイトル / 子どもの年齢
真似	特徴的な言葉を用いた絵本において，その中の言葉を真似する	真似する対象の言葉=オノマトペ	1~2 歳	2 冊 / じゃあじゃあびりびり / もこ もこもこ	古市 [古市 14] / 1 冊 /もこ もこもこ / 2 歳
					近藤・辻元 [近藤 12] / 1 冊 / きたきたうずまき / 5 ~ 6 歳 (注: ADHJ 児)
		真似する対象の言葉=絵本中のセリフ	1~4 歳	1 冊 / はじめてのおつかい	秋田 [秋田 98] / 1 冊 / ノンタンのたんじょうび / 2 歳
					齋藤 [齋藤 12] / 1 冊 / きつねのおきゃくさま / 5 歳
					佐藤・西山 [佐藤 07] / 1 冊 / おおきなかぶ / 5~6 歳
	食べ物や，それを食べる場面が出現する絵本において，食べる真似をする		1~3 歳	6 冊 / いいおかお / はらぺこあおむし / いちご / くだもの / ぐりとぐら / なにをたべてきたの？	関根 [関根 12] / 1 冊 / ノンタンスプーンたんたんたん / 1 歳
					角田 [角田 03] / 1 冊 / すいかのたね / 年齢不詳
	特徴的なキャラクターが登場する絵本において，キャラクターの動作の真似をする		1~4 歳	7 冊 / おててがでたよ / だるまさんの / だるまさんが / だるまさんと / どんどこ ももんちゃん / ぴょーん / しろくまちゃんのほっとけーき	佐々木 [佐々木 06] / 1 冊 / でんぐりでんぐり / 年齢不詳
					佐々木 [佐々木 93] / 1 冊 / いただきまあす / 年齢不詳
	その他		1~3 歳	4 冊 / おつきさまこんばんは / たまごのあかちゃん / てぶくろ/ねないこだれだ	該当する論文，書籍なし
ごっこ	物語性の強い絵本において，物語の再現をする		2~4 歳	3 冊 / おおきなかぶ / てぶくろ / 三びきのやぎのがらがらどん	佐々木 [佐々木 06] / 4 冊 / めっきらもっきらどおんどん / はじめてのおつかい / おおきなかぶ / こすずめのぼうけん / 2 歳，4 歳，年齢不詳
	その他		2~4 歳	4 冊 / あさえとちいさいもうと / えんそくバス / くれよんのくろくん / がたんごとんがたんごとん	該当する論文，書籍なし
「じっと (2 歳以上が中心)」+「入り込んで+感情移入」(感情移入してお話をじっと聞く)	主人公が不安な気持ちになる場面がある絵本において，主人公の不安な気持ちに反応する		2~6 歳	5 冊 / よるくま / こんとあき / はじめてのおつかい / あさえとちいさいいもうと / おしいれのぼうけん	該当する論文，書籍なし
	その他		2~6 歳	2 冊 / くれよんのくろくん / おへそのあな	秋田 [秋田 98] / 2 冊 / ひとりぼっちのライオン / はじめてのおつかい / 2~4 歳
					齋藤・内田 [齋藤 13b] / 1 冊 / きつねのおきゃくさま / 3 歳
					佐々木 [佐々木 06] / 6 冊 / ぺんぎんたんけんたい / はじめてのおつかい / こぐまちゃんいたいいたい / だるまちゃんとだいこくちゃん / とんことり / ふたりはいつも / 2~4 歳，年齢不詳
					佐々木 [佐々木 93] / 1 冊 / どろんこハリー / 3 歳

[1J2] [General Session] 9. NLP / IR

座長:木村 泰知（小樽商科大学）

Tue. Jun 5, 2018 3:20 PM - 5:00 PM Room J (2F Royal Garden B)

[1J2-01] A Linear-Time Kernelized Co-occurrence Norm for Sparse Linguistic Expressions

○Sho Yokoi[1,2], Sosuke Kobayashi[3], Kenji Fukumizu[4], Kentaro Inui[1,2] （1. Tohoku Univ., 2. Riken AIP, 3. Preferred Networks, 4. ISM）

3:20 PM - 3:40 PM

[1J2-02] Experimental Analysis of Effect of Reducing Search Space for Relevance Feedback Based on SVM

○Yuto Imamura[1], Takahiro Nishigaki[1], Takashi Onoda[1] （1. Aoyama Gakuin University）

3:40 PM - 4:00 PM

[1J2-03] Neural Ranking with Pretraining for Curation of Important Sentences in Business Operations

○Yuta Koreeda[1], Kenzo Kurotsuchi[1], Toshihiko Yanase[1], Kohsuke Yanai[1], Hisao Mase[1], Misa Sato[1] （1. Hitachi, Ltd.）

4:00 PM - 4:20 PM

[1J2-04] The effect of optimization by RIBES in statistical machine translation

○Naotaka Kawata[1], Hideki Isozaki[2], Genichiro Kikui[2] （1. Okayama Prefectural University Graduate School of Computer Science and Systems Engineering , 2. Okayama Prefectural University Faculty of Computer Science and Systems Engineering Department of Systems Engineering）

4:20 PM - 4:40 PM

[1J2-05] An Idea of Patent Document Classifier Support System Using Rough Set Theory

○masaki kurematsu[1] （1. Iwate Prefectural University）

4:40 PM - 5:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

カーネル法に基づく疎な言語表現のための高速計算可能な共起尺度

A Linear-Time Kernelized Co-occurrence Norm for Sparse Linguistic Expressions

横井 祥 *1*2 Sho Yokoi
小林 颯介 *3 Sosuke Kobayashi
福水 健次 *4 Kenji Fukumizu
乾 健太郎 *1*2 Kentaro Inui

*1東北大学 Tohoku University
*2理研 AIP センター RIKEN Center for AIP
*3Preferred Networks Preferred Networks
*4統計数理研究所 The Institute of Statistical Mathematics

Estimating pointwise mutual information (PMI), a well-known co-occurrence measure between linguistic expressions, leads to a trade-off between learning time and the robustness to data sparsity. We propose a new kernel-based co-occurrence measure, named pointwise HSIC (PHSIC). PHSIC, intuitively, is a "smoothed PMI" by kernels, so it is robust to data sparsity; furthermore, its estimator is reduced to an efficient linear-time matrix calculation. In our experiments, we apply PHSIC to a dialogue response selection task using sparse language data. Experimental results show that the learning speed is about 100 times faster than that of a recurrent neural network-based PMI estimator; moreover, when the size of the data is small, its predictive performance hardly deteriorates compared to PMI.

1. はじめに

ふたつの言語表現の間の共起の強さのモデル化は自然言語処理における基本的タスクである．たとえばコロケーション獲得 [Manning 99] では，はじめにコーパスから bigram（連続して出現する単語ペア）が集められ，とくに強く共起する bigram（たとえば "New York"）を見つけることが目的となる．あるいは対話の応答文選択 [Lowe 15] では，はじめに〈発話文，応答文〉ペアの集合が与えられ，あたらしい発話文 x に対して最も適当な応答文 y—発話文 x ともっとも強く共起する応答文 y—を候補集合から選択することが目的となる．いずれの場合も，はじめに言語表現のペアの集合 $\mathcal{D} = \{(x_i, y_i)\}_{i=1}^n$ が与えられ，新しいペア (x, y) の共起の強さを計算・推定することになる．

言語表現のペアの共起の強さはしばしば**自己相互情報量（PMI）** [Church 89] でモデル化される．すなわち，与えられたペアの集合を適当な同時分布 $\mathbf{P}_{XY}$ からのサンプル

$$\mathcal{D} = \{(x_i, y_i)\}_{i=1}^n \underset{\text{i.i.d.}}{\sim} \mathbf{P}_{XY} \tag{1}$$

だと考えて，ペア (x, y) の共起の強さを次で測る：

$$\mathrm{PMI}(x, y; X, Y) = \log \frac{\mathbf{P}_{XY}(x, y)}{\mathbf{P}_X(x)\mathbf{P}_Y(y)}. \tag{2}$$

PMI を与えられたデータ $\mathcal{D}$ から推定する方法をふたつ述べる．ひとつめは頻度による推定である：

$$\widehat{\mathrm{PMI}}_{\mathrm{MLE}}(x, y; \mathcal{D}) = \log \frac{n \cdot c(x, y)}{\sum_{y'} c(x, y') \sum_{x'} c(x', y)}. \tag{3}$$

ここで $c(x, y)$ はペア (x, y) の $\mathcal{D}$ 内の頻度を表す．式 (3) の推定は計算が容易であり，コロケーション獲得 *1 など，特に単語同士の共起を測る際にしばしば用いられるが [Church 89]，各 x や y が疎である場合（たとえば句や文である場合）は適用できない．ふたつめの PMI 推定法は再帰ニューラルネット（RNN）を用いるものである．Li ら [Li 16] は対話の応答文生成（各 x や y が文であり非常に疎な場合）に共起尺度として PMI を適用するため *2，$\mathbf{P}(y)$ を RNN 言語モデル [Mikolov 10]，$\mathbf{P}(y|x)$ を条件付き RNN 言語モデル [Sutskever 14] でモデル化し，PMI を推定した：

$$\widehat{\mathrm{PMI}}_{\mathrm{RNN}}(x, y; \mathcal{D}) = \log \frac{\widehat{\mathbf{P}}_{\mathrm{CondRNN}}(y|x)}{\widehat{\mathbf{P}}_{\mathrm{RNN}}(y)}. \tag{4}$$

式 (4) の推定は各 x や y が疎な場合も適用できるが，学習コストは大きい．以上のように，頻度による PMI の推定 (3) と RNN による PMI の推定 (4) には疎性への頑健性と計算コストというトレードオフがある．我々が知る限り，疎な言語表現に適用できかつ高速に計算可能な共起の尺度は存在しない．

本稿では，カーネル法に基づく新しい共起尺度 **Pointwise HSIC（PHSIC）**を提案する．PHSIC は直感的には "カーネルでスムージングした PMI" であり，疎性に頑健かつ高速な推定が可能という特徴を持つ．まず 2. 節で提案尺度の形式的な定義を与える．PMI が「相互情報量への貢献度」であることに対応させ，PHSIC は「HSIC（カーネル法に基づく依存性尺度）への貢献度」として定義する．3. 節で PHSIC が疎性に頑健であることの直感的な説明を与える．PMI は新しいペアとすでに観測されたペアを完全一致で照合するが，PHSIC はこの照合をカーネル関数で平滑化した量と見ることができる．4. 節で，PHSIC の行列計算に帰着させた効率的な推定法を示す．5. 節で対話の応答文選択の実験をおこなう．PHSIC は RNN による PMI の推定に比べて，学習は約 100 倍高速であり，かつデータ数が少ないとき（データがさらに疎な場合）に予測精度の劣化が小さいことを示す．

問題設定・記号

X, Y をそれぞれ $\mathcal{X}, \mathcal{Y}$ に値をとる確率変数とする．本稿で扱うタスクは，入力として言語表現のペアの集合 $\mathcal{D} = \{(x_i, y_i)\}_{i=1}^n \underset{\text{i.i.d.}}{\sim} \mathbf{P}_{XY}$ を受け取り，与えられたペア $(x, y) \in \mathcal{X} \times \mathcal{Y}$ の "共起の強さ" を測るものである．提案手法はカーネル法に基づくため，カーネル法に関連する記号をいくつか用意する (表 1)．

連絡先: yokoi@ecei.tohoku.ac.jp

*1 コロケーション獲得において単純に頻度 $c(x, y) \propto \widehat{\mathbf{P}}(x, y)$ の大きな bigram を探すと，"of the" など高頻度な機能語のペアが上位に上がってきてしまい，連語を探す目的に合わない [Manning 99].

*2 対話の応答文生成において単純に条件付き確率 $\widehat{\mathbf{P}}(y|x)$ の高い y を探すと，"I don't know." など，発話文 x の内容に関わらず用いることのできるありきたり回答が上位に上がってきてしまう [Li 16].

表 1: 本稿で用いる記号.

$k : \mathcal{X} \times \mathcal{X} \to \mathbb{R}$	$\mathcal{X}$ 上の正定値カーネル（直感的には類似度関数）
$\ell : \mathcal{Y} \times \mathcal{Y} \to \mathbb{R}$	$\mathcal{Y}$ 上の正定値カーネル
$\phi(x) := k(x, \cdot)$	k が定める特徴空間における $x \in \mathcal{X}$ の特徴ベクトル
$\psi(y) := \ell(y, \cdot)$	ℓ が定める特徴空間における $y \in \mathcal{Y}$ の特徴ベクトル
$\widetilde{k}$: $\mathcal{X} \times \mathcal{X} \to \mathbb{R}$	確率分布 X で中心化したカーネル k（$\widetilde{\ell}$ も同様）
$\widetilde{k}(x, x') := k(x, x') - \mathbf{E}_{x'}[(x, x')] - \mathbf{E}_{x}[(x, x')] + \mathbf{E}_{x,x'}[(x, x')]$	
$= (\phi(x) - \mathbf{E}_x[\phi(x)])^\top (\phi(x') - \mathbf{E}_x[\phi(x)])$	

表 2: 提案尺度 Pointwise HSIC（PHSIC）の位置づけ（2. 節）.

確率変数間の依存性の尺度 X と Y の依存の度合い （$\mathbf{P}_{XY}$ と $\mathbf{P}_X\mathbf{P}_Y$ の異なりの度合い）	サンプル間の共起の尺度 ペア (x, y) の 「X と Y の依存の度合い」への貢献度
相互情報量（MI） $\mathrm{MI}(X, Y) = \mathrm{KL}[\mathbf{P}_{XY} \| \mathbf{P}_X\mathbf{P}_Y]$	自己相互情報量（PMI） $\mathrm{PMI}(x, y; X, Y)$
$= \mathop{\mathbf{E}}_{(x,y)}\left[\log \dfrac{\mathbf{P}_{XY}(x,y)}{\mathbf{P}_X(x)\mathbf{P}_Y(y)}\right]$	$= \log \dfrac{\mathbf{P}_{X,Y}(x,y)}{\mathbf{P}_X(x)\mathbf{P}_Y(y)}$
HSIC $\mathrm{HSIC}(X, Y; k, \ell) = \mathrm{MMD}^2[\mathbf{P}_{XY}, \mathbf{P}_X\mathbf{P}_Y]$	Pointwise HSIC（PHSIC） $\mathrm{PHSIC}(x, y; X, Y, k, \ell)$
$= \mathop{\mathbf{E}}_{(x,y)}\left[\mathop{\mathbf{E}}_{(x',y')}[\widetilde{k}(x,x')\widetilde{\ell}(y,y')]\right]$	$= \mathop{\mathbf{E}}_{(x',y')}[\widetilde{k}(x,x')\widetilde{\ell}(y,y')]$
$= \mathop{\mathbf{E}}_{(x,y)}\left[(\phi(x)-m_X)^\top C_{XY}(\psi(y)-m_Y)\right]$	$= (\phi(x)-m_X)^\top C_{XY}(\psi(y)-m_Y)$

2. Pointwise HSIC

この節でカーネル法に基づく新しい共起尺度である Pointwise HSIC（PHSIC）の形式的な定義を与える．はじめに PMI が「ペアの相互情報量への貢献度」と捉えられることを述べ，次にこれに対応させ，提案尺度 PHSIC を「ペアの HSIC（カーネル法に基づく依存性尺度）への貢献度」として定義する (表 2)．すなわち PHSIC は一言で言えば “カーネル化した PMI” である．

2.1 相互情報量と自己相互情報量

まず**確率変数の依存性**の測りかたについて述べる．確率変数 X と Y が独立であるとは，同時分布 $\mathbf{P}_{XY}$ と周辺分布の積 $\mathbf{P}_X\mathbf{P}_Y$ が等しいことであった．したがって，ふたつの確率変数 X と Y がどの程度依存しているかは，なんらかの観点で「$\mathbf{P}_{XY}$ と $\mathbf{P}_X\mathbf{P}_Y$ がどの程度異なるか」を測ればよい．

確率変数 X と Y の**相互情報量** [Cover 06] は [*3] ：

$$\mathrm{MI}(X, Y) := \mathrm{KL}[\mathbf{P}_{XY} \| \mathbf{P}_X\mathbf{P}_Y]. \tag{5}$$

ここで $\mathrm{KL}[\cdot\|\cdot]$ は確率分布間の KL ダイバージェンスを表す．すなわち相互情報量は $\mathbf{P}_{XY}$ と $\mathbf{P}_X\mathbf{P}_Y$ の違いを KL ダイバージェンスの観点で測った確率変数の依存性尺度である．

ところで相互情報量は，同時分布 $\mathbf{P}_{XY}$ による期待値の形，つまりペア $(x, y) \in \mathcal{X} \times \mathcal{Y}$ 全体での総和の形でも表現することができる：

$$\mathrm{MI}(X, Y) = \mathop{\mathbf{E}}_{(x,y)}\left[\log \frac{\mathbf{P}_{XY}(x,y)}{\mathbf{P}_X(x)\mathbf{P}_Y(y)}\right]. \tag{6}$$

網掛け部がまさに**自己相互情報量（PMI）**

$$\mathrm{PMI}(x, y; X, Y) = \log \frac{\mathbf{P}_{XY}(x,y)}{\mathbf{P}_X(x)\mathbf{P}_Y(y)} \tag{7}$$

であることに注意すると，$\mathrm{PMI}(x, y)$ は「ペア (x, y) の，相互情報量 $\mathrm{MI}(X, Y)$ への貢献度」と見ることができる．

2.2 HSIC と PHSIC

カーネル法に基づく依存性尺度である HSIC を紹介し，つぎに HSIC への貢献度として提案尺度である PHSIC を定める．

Hilbert–Schmidt independence criterion（HSIC）はカーネル法に基づく確率変数間の依存性尺度である [Gretton 05]：

$$\mathrm{HSIC}(X, Y; k, \ell) = \mathrm{MMD}^2_{k,\ell}[\mathbf{P}_{XY}, \mathbf{P}_X\mathbf{P}_Y]. \tag{8}$$

ここで $\mathrm{MMD}[\cdot,\cdot]$ は maximum mean discrepancy（MMD）[Gretton 12] と呼ばれる量で，カーネルが定める特徴空間上での分布間の距離を定める．すなわち HSIC は $\mathbf{P}_{XY}$ と $\mathbf{P}_X\mathbf{P}_Y$ の違いを MMD の観点で測った確率変数の依存性尺度である．

ところで HSIC も相互情報量と同様に同時分布 $\mathbf{P}_{XY}$ による期待値の形で表現することができる：

$$\mathrm{HSIC}(X, Y; k, \ell) = \mathop{\mathbf{E}}_{(x,y)}\left[\mathop{\mathbf{E}}_{(x',y')}[\widetilde{k}(x,x')\widetilde{\ell}(y,y')]\right] \tag{9}$$

$$= \mathop{\mathbf{E}}_{(x,y)}\left[(\phi(x) - m_X)^\top C_{XY}(\psi(y) - m_Y)\right] \tag{10}$$

$$m_X := \mathop{\mathbf{E}}_{x}[\phi(x)], \quad m_Y := \mathop{\mathbf{E}}_{y}[\psi(y)] \tag{11}$$

$$C_{XY} := \mathop{\mathbf{E}}_{(x,y)}\left[(\phi(x) - m_X)(\psi(y) - m_Y)^\top\right]. \tag{12}$$

式 (9) は HSIC のデータ空間での表現であり，式 (10) は特徴空間での表現である [*4]．相互情報量と PMI の関係と同様に，**Pointwise HSIC（PHSIC）**を式 (9)(10) の網掛け部により定義する：

$$\mathrm{PHSIC}(x, y; X, Y, k, \ell) := \mathop{\mathbf{E}}_{(x',y')}[\widetilde{k}(x,x')\widetilde{\ell}(y,y')] \tag{13}$$

$$= (\phi(x) - m_X)^\top C_{XY}(\psi(y) - m_Y). \tag{14}$$

すなわち $\mathrm{PHSIC}(x, y)$ は「ペア (x, y) の，$\mathrm{HSIC}(X, Y)$ への貢献度」である．

3. 「平滑化した PMI」としての PHSIC

PHSIC がデータの疎性に頑健な理由として，PHSIC は「PMI をカーネルで平滑化した量」だと捉えられることを述べる．まず，PMI の推定量 (3) は次のように書き換えられる：

$$\widehat{\mathrm{PMI}}_{\mathrm{MLE}}(x, y) = \log \frac{n \cdot \sum_{i=1}^n \mathbb{I}[x = x_i \wedge y = y_i]}{\sum_{i=1}^n \mathbb{I}[x = x_i] \sum_{i=1}^n \mathbb{I}[y = y_i]}. \tag{15}$$

ここで $\mathbb{I}[\mathrm{cond}]$ は指示関数を表し，条件 cond が満たされるときは 1 を，そうでないときは 0 を返す．式 (15) によれば，PMI の推定量は「与えられた (x, y) を観測済みの $(x_i, y_i) \in \mathcal{D}$ たちと順に照合し，(x, y) と (x_i, y_i) が完全に一致すれば加点，x 側もしくは y 側のどちらか一方のみが一致する場合は減点」を繰り返した量である (表 3，上側)．

一方，PHSIC(13) の推定量は次の通り：

$$\widehat{\mathrm{PHSIC}}_{\mathrm{kernel}}(x, y) = \frac{1}{n}\sum_{i=1}^n \widehat{\widetilde{k}}(x, x_i)\widehat{\widetilde{\ell}}(y, y_i). \tag{16}$$

関数 $\widehat{\widetilde{k}}(\cdot,\cdot)$，$\widehat{\widetilde{\ell}}(\cdot,\cdot)$ はデータで中心化した類似度関数である [*5]．(16) によれば，PHSIC の推定量は「与えられた (x, y) を観測

*3 相互情報量は，一般に $I(X;Y)$ と表記されるが，本稿では後述する $\mathrm{HSIC}(X, Y)$ との表記の一貫性のため $\mathrm{MI}(X, Y)$ で表わす．

*4 一般にカーネル法では，特徴空間における内積 $\phi(x)^\top\phi(x')$ をデータ空間におけるカーネル $k(x, x')$ で計算できることを用いて，データ空間側で統計処理をおこなう．

*5 $\widehat{\widetilde{k}}(x, x') := k(x, x') - \frac{1}{n}\sum_{j=1}^n k(x, x_j) - \frac{1}{n}\sum_{i=1}^n k(x_i, x') + \frac{1}{n^2}\sum_{i=1}^n\sum_{j=1}^n k(x_i, x_j)$，$\widehat{\widetilde{\ell}}(\cdot,\cdot)$ も同様．

表 3: PMI と PHSIC の「与えられた (x, y) と観測済みの $(x_i, y_i) \in \mathcal{D}$ たちとの照合の仕方」という観点での比較.

	加点	減点
PMI	(x, y) $\| \quad \|$ $\mathcal{D} = \{\ldots, (x_i, y_i), \ldots\}$	$(x, y) \quad (x, y)$ $\| \quad \nparallel$ $\{\ldots, (x_i, y_i), \ldots, (x_i, y_i), \ldots\}$
PHSIC	$(x, y) \quad (x, y)$ $\wr \quad \wr \quad \wr\wr$ $\{\ldots, (x_i, y_i), \ldots, (x_i, y_i), \ldots\}$	$(x, y) \quad (x, y)$ $\wr \quad \wr \quad \wr\wr$ $\{\ldots, (x_i, y_i), \ldots, (x_i, y_i), \ldots\}$

済みの $(x_i, y_i) \in \mathcal{D}$ たちと順に照合し，x 側と y 側がともに平均より似ている場合（$\widehat{\widehat{k}}(x, x_i) > 0$ かつ $\widehat{\widehat{\ell}}(y, y_i) > 0$ の場合）に加点 *6，x 側と y 側のどちらか一方が似ていてもう一方が似ていない場合は減点」を繰り返した量である (表 3，下側).

以上のように，PMI と PHSIC の推定量を「与えられた (x, y) と観測済みの $(x_i, y_i) \in \mathcal{D}$ たちとの照合の仕方」という観点で比較すると，PMI は完全一致で照合する一方，PHSIC はこれをカーネル（類似度関数）を用いて平滑化していることが分かる．PHSIC が（ナイーブな推定であってもなお）データの疎性に頑健であることがこの点からも期待できる.

3.1 既存の類似度関数の活用

また自然言語処理には正定値カーネルの形の類似度関数が潤沢に存在する．PHSIC はこれらの資産をそのまま活用できる.

- **単語ベクトル**の和 [Mikolov 13] や**文の分散表現** [Kiros 15] など，分布仮説に基づく文や句の分散表現が多数提案されており，学習済みのモデルも種々配布されている．さらに，これら同士の**コサイン**が簡便で高精度な類似尺度として利用できる.
- SVM 時代に考案された**構造カーネル** [Collins 02] が多数存在する.
- 正定値カーネルの和や積も正定値カーネルであるため，これらの類似度関数を自在に**組合せ**ることができる.

4. PHSIC の推定法と計算量

特徴空間での推定（線形カーネル・コサインの場合）：一般に，カーネル $k(\cdot, \cdot)$ が定める特徴ベクトル $\phi(\cdot)$ は未知ないし超高次元であり特徴空間での推定は難しい（これをデータ空間で代替するのがカーネル法の特徴のひとつであった）．ところが，昨今の自然言語処理で利用される句や文の類似度は，コサインでよく計算できるケースがある (3.1 節)．コサインとともに用いられる文 x のベクトル表現を $\boldsymbol{x} \in \mathbb{R}^d$ とすれば，これは特徴空間での表現 $\phi(x) = \boldsymbol{x}/\|\boldsymbol{x}\|_2$ が陽に与えられていることに等しい（$k(x, x') = \phi(x)^\top \phi(x') = \cos(\boldsymbol{x}, \boldsymbol{x}')$）．線形カーネルの場合も自明に同様の表現が手に入る．このような場合，PHSIC を特徴空間側で推定することが可能である.

PHSIC の特徴空間での表現 (14) の推定量は次の通り：

$$\widehat{\mathrm{PHSIC}}_{\mathrm{feat}}(x, y) = (\phi(x) - \overline{\phi(x)})^\top \widehat{C}_{XY} (\psi(y) - \overline{\psi(y)}) \quad (17)$$

$$\widehat{C}_{XY} := \tfrac{1}{n} \textstyle\sum_{i=1}^n \phi(x_i)\psi(y_i)^\top - \overline{\phi(x)}\,\overline{\psi(y)}^\top. \quad (18)$$

ただし $\overline{\phi(x)} = \frac{1}{n}\sum_{i=1}^n \phi(x_i)$ は特徴空間での標本平均，$\overline{\psi(y)}$ も同様．式 (17)(18) の計算は行列計算に帰着されており，しかも計算量も小さい．学習時はベクトル $\overline{\phi(x)}, \overline{\psi(y)} \in \mathbb{R}^d$ および行列 $\widehat{C}_{XY} \in \mathbb{R}^{d \times d}$ の計算が必要であり，時間計算量は $\mathcal{O}(nd^2)$，空間計算量は $\mathcal{O}(nd)$（ともにデータ数に対して線形）．予測時は $\phi(x), \psi(y) \in \mathbb{R}^d$ の構成および式 (17) の計算に $\mathcal{O}(d^2)$ の時間計算量を要する.

データ空間での推定（非線形カーネルの場合）：木カーネル [Collins 02] 等の非線形カーネルを用いる場合は PHSIC をデータ空間で推定する必要がある．データ空間でも，グラム行列の分解を介する簡単な工夫で式 (17) と同等の計算量での PHSIC の推定が可能である（紙面の都合で導出は省略する）.

$$\widehat{\mathrm{PHSIC}}_{\mathrm{ICD}}(x, y) = (\boldsymbol{a} - \overline{\boldsymbol{a}})^\top \widehat{C}_{\mathrm{ICD}} (\boldsymbol{b} - \overline{\boldsymbol{b}}) \quad (19)$$

$$\widehat{C}_{\mathrm{ICD}} := \tfrac{1}{n}(HA)^\top B. \quad (20)$$

ただし行列 $A = (\boldsymbol{a}_1, \ldots, \boldsymbol{a}_n)^\top \in \mathbb{R}^{n \times d}$ は不完全コレスキー分解により計算した $AA^\top \approx K$*7 なる行列であり，B も同様（$BB^\top \approx L$）．ベクトル $\overline{\boldsymbol{a}} \in \mathbb{R}^d$ は $\{\boldsymbol{a}_i\}_{i=1}^n$ の平均 $\frac{1}{n}A^\top \mathbf{1}$，$\overline{\boldsymbol{b}}$ も同様．また，新しい $x \in \mathcal{X}$ に対応するベクトル $\boldsymbol{a} \in \mathbb{R}^d$ は，不完全コレスキー分解のアルゴリズムを「途中から行う」ことで計算できる．分解中に採用された支配的な x_i たちを順に $x^{(1)}, \ldots, x^{(d)}$ とすると，$\boldsymbol{a}$ の第 j 成分 $\boldsymbol{a}(j)$ は以下で計算できる（$\boldsymbol{b}$ も同様）：$\boldsymbol{a}(j) = [k(x, x^{(j)}) - \sum_{m=1}^{j-1} \boldsymbol{a}(m) A_{jm}] \,/\, A_{jj}$.

5. 実験

PHSIC が疎なデータに適用でき (3. 節) しかも計算量が小さい (4. 節) ことを，疎な言語データ（文対）を用いる対話の応答文選択タスクを通して大規模実データで検証する．実験の結果，提案尺度は RNN を用いた PMI の推定に比べ 100 倍程度高速に学習でき，また訓練データ数が少ない場合（データがより疎な場合）も予測精度の劣化が少ないことがわかった.

タスク：対話の応答文選択タスクをおこなう．訓練データとして〈発話文，応答文〉のペアの集合 $\mathcal{D} = \{(x_i, y_i)\}_{i=1}^n$ が与えられ，評価データの発話文 x 毎に応答文 y を選択肢から選ぶ.

データ：ツイッターにおける対話ペアを用いる.

- 検証・評価には，関連度（共起の度合い）が高い対話を人手で抽出したデータセットを用いる [Sordoni 15]*8.
- 訓練セットもやはり [Sordoni 15] と同様の方法で収集した．ただし，検証・評価セット（2012 年のツイート）とのデータの重複を避けるため，収集対象の年次を 2017 年に変更した．訓練セットの大きさ n の違いが学習時間・予測精度へ与える影響を確かめるため，収集したデータから乱択した $\{10^2, 10^3, 10^4, 10^5\}$ ペアを訓練セットとして実験をおこなう.
- 最後に，[Li 16] と同様に，〈文脈，発話，応答〉の三つ組を〈文脈＋発話，応答〉のペアに変換する．なお評価セットは各発話文 x に対してコーパス全体から乱択で選択された負例の応答 y' が 9 件ずつ割り当てられている（10 択問題となる）.

5.1 提案尺度：PHSIC

PHSIC は任意の正定値カーネルを用いることができる．今回は，もっとも簡単な類似尺度のひとつである，文を構成する単語ベクトルの和同士のコサイン (3.1 節)

$$k(x, x') = \cos(\textstyle\sum \mathrm{wordvecs}(x), \sum \mathrm{wordvecs}(x')) \quad (21)$$

を用いる．$\ell(\cdot, \cdot)$ も同様．単語ベクトルは，文字 n-gram を活用した単語ベクトル学習アルゴリズムである `fastText`

*6 x 側と y 側がともに平均より似ていない場合，すなわち $\widehat{\widehat{k}}(x, x_i) < 0$ かつ $\widehat{\widehat{\ell}}(y, y_i) < 0$ の場合も PHSIC の推定値が増加する.

*7 行列 $K \in \mathbb{R}^{n \times n}$ は $K_{ij} := k(x_i, x_j)$ なるグラム行列，$L_{ij} := \ell(y_i, y_j)$ も同様.

*8 https://www.microsoft.com/en-us/download/details.aspx?id=52375

モデル				訓練セットサイズ n			
				10^2	10^3	10^4	10^5
RNN	300	fastText	Total	11.7	20.6	99.2	634.3
			$\widehat{\mathbf{P}}(y)$	4.8	8.0	23.6	294.6
			$\widehat{\mathbf{P}}(y\|x)$	6.9	12.6	75.6	339.7
	1200	random	Total	31.3	65.5	161.5	1743.2
			$\widehat{\mathbf{P}}(y)$	8.6	21.7	57.4	675.6
			$\widehat{\mathbf{P}}(y\|x)$	22.7	43.8	104.1	1067.6
	1200	fastText	Total	33.8	49.0	162.0	1751.3
			$\widehat{\mathbf{P}}(y)$	10.8	16.3	57.2	671.0
			$\widehat{\mathbf{P}}(y\|x)$	23.0	32.7	104.8	1080.3
PHSIC	fastText		Total	**0.02**	**0.2**	**1.4**	**14.5**
			feat map	0.0	0.1	1.3	14.0
			mat calc	0.0	0.0	0.1	0.5

表 4: 各モデルの学習時間，単位は秒．各行はモデル，各列は訓練データサイズ n，太字は列毎の最短学習時間．RNN の各モデルに付記されているのは次元数および単語埋め込みの初期化法．PHSIC の計算時間は，内数として特徴関数の計算時間 (feat map) と行列計算時間 (mat calc) を付記した．

[Bojanowski 17] によりウェブクロールデータ *9 から学習済みの公開資源 *10 を利用する．ベクトルは 300 次元，語彙サイズは 200 万．

5.2 ベースライン尺度：RNN 言語モデル

訓練データで RNN 言語モデル [Mikolov 10] および条件付き RNN 言語モデル [Sutskever 14] を，1 層 LSTM[Hochreiter 97]，フレームワークは `Chainer`[Tokui 15] を用いて学習し，(1) 応答文の尤度 $\widehat{\mathbf{P}}(y)$，(2) 応答文の条件付き確率 $\widehat{\mathbf{P}}(y|x)$，および (3)PMI ($\log\left[\widehat{\mathbf{P}}(y|x)/\widehat{\mathbf{P}}(y)\right]$) をベースライン尺度として用いる．隠れ層の次元，および単語埋め込み層の初期化については，以下の設定の組合せで学習する：

- 隠れ層の次元：300，1200，
- 初期化：$[-0.1, 0.1]$ の一様ランダム，`fastText` (5.1 節).

ほか設定は以下の通り：

- 語彙：頻度 2 以上の語を利用，
- ドロップアウト率：0.1（300 次元），0.3（1200 次元），
- バッチサイズ：16（$n = 10^2$），64（$n = 10^3, 10^4, 10^5$），
- 最大エポック：30*11 .

5.3 予測精度の評価

PHSIC やベースライン尺度は，各ペア (x, y) に対してなんらかの共起スコア score(x, y) を与える．共起スコアの良さを，(1)`MRR`（平均逆順位），(2)`AUC-ROC`，(1)`Recall@2` でそれぞれ評価する．

5.4 実験結果：学習時間

学習時間に関する実験結果は表 4 の通り *12．訓練セットの大きさ n が 10^5 のとき，PHSIC は RNN に基づく PMI の約 40–120 倍高速に学習が完了した．

5.5 実験結果：予測精度

予測精度に関する実験結果は表 5 の通り．10^5 万件の学習データをすべて使ったとき，PHSIC は既存尺度と大凡同等の予測精度を示し，さらに，訓練セットのサイズを小さくしたとき（より疎なとき），既存尺度の予測精度は大幅に劣化するのに対し，PHSIC の予測精度の劣化スピードははるかに緩慢であった．

モデル			訓練セットサイズ n			
			10^2	10^3	10^4	10^5
Chance Level			.50; .29; .20	.50; .29; .20	.50; .29; .20	.50; .29; .20
$\widehat{\mathbf{P}}(y)$	1200	fastText	.51; .30; .23	.50; .29; .21	.50; .30; .21	.50; .30; .21
$\widehat{\mathbf{P}}(y\|x)$	1200	fastText	.51; .30; .22	.50; .29; .21	.50; .30; .21	.52; .31; .23
PMI	300	random	.50; .29; .18	.51; .30; .21	.51; .30; .22	.58; .35; .29
		fastText	.50; .29; .18	.51; .29; .20	.56; .34; .25	**.66**; **.41**; **.36**
	1200	random	.50; .29; .20	.50; .29; .20	.51; .30; .19	.57; .35; .29
		fastText	.50; .29; .19	.51; .30; .20	.52; .32; .23	**.65**; **.42**; **.36**
PHSIC	fastText		**.57**; **.35**; **.29**	**.61**; **.38**; **.33**	**.62**; **.40**; **.34**	.62; **.40**; **.34**

表 5: 各モデルの予測精度（`MRR`，`ROC-AUC`，`Recall@2`）．

謝辞 東京大学の胡緯華氏からの有益な助言に感謝する．本研究の一部は文部科学省科研費 15H01702 の支援を受けた．

参考文献

[Bojanowski 17] Bojanowski, P., Grave, E., Joulin, A., and Mikolov, T.: Enriching Word Vectors with Subword Information, *TACL*, Vol. 5, pp. 135–146 (2017)

[Church 89] Church, K. W. and Hanks, P.: Word Association Norms, Mutual Information, and Lexicography, in *ACL*, pp. 76–83 (1989)

[Collins 02] Collins, M. and Duffy, N.: Convolution Kernels for Natural Language, in *NIPS*, pp. 625–632 (2002)

[Cover 06] Cover, T. M. and Thomas, J. A.: *Elements of Information Theory*, John Wiley & Sons (2006)

[Gretton 05] Gretton, A., Bousquet, O., Smola, A., and Schölkopf, B.: Measuring Statistical Dependence with Hilbert-Schmidt Norms, in *ALT*, pp. 63–77 (2005)

[Gretton 12] Gretton, A., Borgwardt, K. M., Rasch, M. J., Schölkopf, B., and Smola, A.: A Kernel Two-Sample Test, *JMLR*, Vol. 13, No. Mar, pp. 723–773 (2012)

[Hochreiter 97] Hochreiter, S. and Schmidhuber, J.: Long Short-Term Memory, *Neural Computation*, Vol. 9, No. 8, pp. 1735–1780 (1997)

[Kiros 15] Kiros, R., Zhu, Y., Salakhutdinov, R. R., Zemel, R., Urtasun, R., Torralba, A., and Fidler, S.: Skip-Thought Vectors, in *NIPS*, pp. 3294–3302 (2015)

[Li 16] Li, J., Galley, M., Brockett, C., Gao, J., and Dolan, B.: A Diversity-Promoting Objective Function for Neural Conversation Models, in *NAACL-HLT*, pp. 110–119 (2016)

[Lowe 15] Lowe, R., Pow, N., Serban, I., and Pineau, J.: The Ubuntu Dialogue Corpus: A Large Dataset for Research in Unstructured Multi-Turn Dialogue Systems, in *SIGDIAL*, pp. 285–294 (2015)

[Manning 99] Manning, C. D. and Schütze, H.: *Foundations of Statistical Natural Language Processing*, MIT press (1999)

[Mikolov 10] Mikolov, T., Karafiat, M., Burget, L., Cernocky, J., and Khudanpur, S.: Recurrent neural network based language model, in *Interspeech*, pp. 1045–1048 (2010)

[Mikolov 13] Mikolov, T., Chen, K., Corrado, G., and Dean, J.: Distributed Representations of Words and Phrases and their Compositionality, in *NIPS*, pp. 3111–3119 (2013)

[Sordoni 15] Sordoni, A., Galley, M., Auli, M., Brockett, C., Ji, Y., Mitchell, M., Nie, J.-Y., Gao, J., and Dolan, B.: A Neural Network Approach to Context-Sensitive Generation of Conversational Responses, in *NAACL-HLT*, pp. 196–205 (2015)

[Sutskever 14] Sutskever, I., Vinyals, O., and Le, Q. V.: Sequence to Sequence Learning with Neural Networks, in *NIPS*, pp. 3104–3112 (2014)

[Tokui 15] Tokui, S., Oono, K., Hido, S., and Clayton, J.: Chainer: a Next-Generation Open Source Framework for Deep Learning, in *LearningSys* (2015)

*9 `http://commoncrawl.org/`

*10 `https://fasttext.cc/docs/en/english-vectors.html`

*11 最大エポック終了時まで，0.5 エポック（$n = 5 \times 10^5$）または 1 エポック（ほか）毎に検証セットパープレキシティを計測し，検証セットパープレキシティが最良のモデルでの予測精度，および（最大エポックまでに要した時間ではなく）当該モデルを獲得するまでの学習時間を報告する．

*12 計算機環境は，CPU : Xeon E5-1650-v3 (3.5GHz, 6 Cores), GPU : GTX 1080 (8GB).

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

SVMに基づく適合フィードバックにおける探索空間縮小効果の実験的分析

Experimental Analysis of Effect of Reducing Search Space for Relevance Feedback Based on SVM

今村優斗　西垣貴央　小野田崇
Yuto Imamura　Takahiro Nishigaki　Takashi Onoda

青山学院大学 理工学部　経営システム工学科
Department of Industrial and Systems Engineering, College of Science and Engineering, Aoyama Gakuin University

SVM (Support Vector Machines) based relevance feedback has proposed. Vector space model is often used for document retrieval. At that time, the search space may become very large because the document vectors have too many attributes which included in the documents on the database. It is presumed that search performance decreases due to the presence of meaningless attributes. However, it is not clear the effect of the size of the search space for the search performance. Therefore, we compared among eight search spaces and conducted an experiment. The search space based on attributes included in the presentation documents improved search performance.

1. はじめに

企業において、自社の特許明細書に類似する他社の特許明細書の検索を行う場面や、研究者が論文を検索する際には、ユーザは文書検索により、より多くの適合文書 (ユーザが求めている文書) を獲得する必要がある。しかし、ユーザが検索クエリ (検索キーワード) を入力し、それに対して検索システムが検索結果を提示するという 1 回だけの検索により、多くの適合文書を獲得することは容易ではない。そのため、より多くの適合文書を獲得したい検索タスクでは、検索結果をユーザが評価し、その評価をもとに再検索を行う、対話的文書検索を行うことが現実的である [1]。この対話的文書検索の 1 つに、検索結果である文書をユーザに提示し、ユーザが適合文書・非適合文書の判定を行い、その判定結果をもとに再検索を繰り返す適合フィードバックがある。適合フィードバックを対話的分類学習としてとらえ、分類学習アルゴリズムの 1 つであるサポートベクターマシン：SVM(Support Vector Machines) を適用する方法が提案されている [2, 1]。

2. 関連研究

2.1 SVM に基づく適合フィードバック

参考文献 [1, 2] に基づき、SVM に基づく適合フィードバックの概要を説明する。

図 1 に SVM に基づく適合フィードバックの概念図を示す。$\boldsymbol{x}$ はデータベース上の文書ベクトルである。図中の○と●はそれぞれ判定済みの適合文書と非適合文書である。ここで◎は未判定文書である。ことのき学習データより得られる SVM の判別超平面 (識別関数) は次の式により表すことができる。

$$f(\boldsymbol{x}) = \boldsymbol{w}^{\mathrm{T}}\boldsymbol{x} + b \tag{1}$$

ここで $\boldsymbol{w}$ は判別超平面の法線ベクトル (線形識別器の重みベクトル)、非負値である b はバイアス項と呼ばれる定数であり、$\boldsymbol{x}$ は文書ベクトルを示している。

判別超平面と文書ベクトル $\boldsymbol{x}$ の距離は、

$$\frac{\boldsymbol{w}^{\mathrm{T}}\boldsymbol{x} + b}{||\boldsymbol{w}||} \tag{2}$$

連絡先: 今村優斗，青山学院大学 理工学部
経営システム工学科, a5714015@aoyama.jp

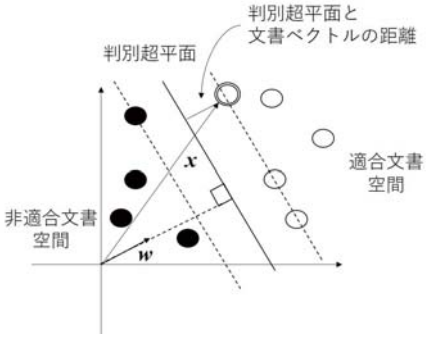


図 1: SVM に基づく適合フィードバックの概念図

となる。SVM に基づく適合フィードバックでは、この判別超平面からの距離を適合度とする。各未判定文書における適合度を計算し、適合文書側にある未判定文書のうち、適合度の大きいものから順に提示をする。

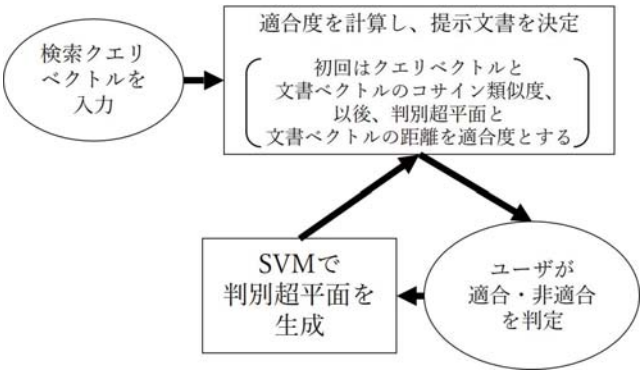


図 2: SVM に基づく適合フィードバックの流れ

図 2 に、SVM に基づく適合フィードバックの流れを示す。初回のフィードバックでは適合度として、文書ベクトルと検索クエリベクトルとのコサイン類似度を使用する。

2.2 SVM に基づく適合フィードバックの課題

文書ベクトルは文書データベース内の文書に含まれる語彙の数だけの属性を持つ。このため、大規模データベースにおける文書の空間ベクトル表現では、数万〜数十万と、膨大な属性をもつベクトルとなってしまい、探索空間が非常に大きくなってしまう。各文書に含まれている属性の数は、データベースに含まれている全文書中で使われている属性の数よりもとても少なく、文書ベクトルは要素に 0 をもったスパースなベクトルとなる。文書全体をこのようなベクトルで表現すると、膨大な記憶容量が必要になると同時に、適合度の計算を行う際の探索空間が大きくなることにより、計算コストも高くなってしまう。また、文書中に含まれる無意味な属性の存在が検索に影響を与え、検索性能を下げてしまうという現象が起こることがある [3]。

これまでの SVM に基づく適合フィードバックの研究では、従来の適合フィードバックの手法との比較実験や、文書ベクトル表現の違いについての考察、文書データベース中の適合文書の割合を変化させた実験などは行われてきているが、これらの研究では SVM に基づく適合フィードバックにおける探索空間縮小効果は考慮されていない [1]。

そこで本論文では、探索空間縮小を縮小することにより、検索性能を改善することができるのかどうかを検証する必要があると考え、複数の探索空間縮小手順を用意し、実験的に分析した。

3. 探索空間縮小手順

本研究では、ランダムに属性を選択する手順 4 つと提示文書の属性のみを用いる手順 3 つ、これに通常の SVM に基づく適合フィードバックを加えた 8 つの手順で実験を行った。

3.1 ランダムな属性選択

ランダムに属性を選択する手順として以下の 4 つの手順を用意した。

- 事前にランダムに 10000 の属性を選択し、その空間に基づき適合フィードバックを行う手順 SVM(random 10000)
- 事前にランダムに 5000 の属性を選択し、その空間に基づき適合フィードバックを行う手順 SVM(random 5000)
- 事前にランダムに 1000 の属性を選択し、その空間に基づき適合フィードバックを行う手順 SVM(random 1000)
- 各フィードバックでランダムに属性を選択し、探索空間を広げていく手順 SVM(random increase)

それぞれ 3 回ずつ実験を行い、その平均値を実験結果に記している。各フィードバックでランダムに属性を選択する手順は、次に述べる提示文書に使用されている属性のみを用いる手順と比較するため、探索空間の大きさが同じになるように各フィードバック回で増やす属性の数を設定した。

3.2 提示文書に使用されている属性のみを用いる手順

次に、システムがユーザに提示した文書で使用されている属性のみを用いて、探索空間を縮小する手順を説明する。以下の 3 つの手順を用意した。

- 提示文書中の適合・非適合文書両方に使用されている属性のみを用いる手順 SVM(reduction)
- 提示文書中の適合文書に使用されている属性のみを用いる手順 SVM(reduction relevant)
- 提示文書中の非適合文書に使用されている属性のみを用いる手順 SVM(reduction non-relevant)

これら手順では、フィードバック $(m-1)$ 回目までにシステムの提示した文書で使用されていた属性のみを用いた探索空間を作成し、その探索空間に基づいて m 回目の検索を行う。例えば 2 回目のフィードバックでは、それまでの 0 回目、1 回目のフィードバックでの提示文書で使用されていた属性のみを用いて、再検索を行う。「システムが適合と判断をしたが、実際は非適合であった文書 (非適合文書)」と、「システムが適合と判断をし、実際に適合であった文書 (適合文書)」に使われていた属性のみを用いることで、適合・非適合の判断に有用であろうと考えられる属性を選択していく。大規模データベースでは、データベース中の全文書数と比べユーザに提示する文書数は非常に少ないため、これら 3 つの手順を使用することで、使用する属性を大きく減らすことができる。したがって、探索空間を大幅に縮小することが可能である。

4. 実験

4.1 実験条件

実験用のデータには参考文献 [1] 等文書検索の評価実験で使用されている、国際会議 TREC の adhoc タスクで使用されたデータセットを用いた。このうち、約 13 万の新聞記事の文書データからなるデータセットを用いた。100 個の検索課題（トピック）が用意されている。それらの検索課題にはそれぞれ適合文書が用意されており、本論文ではこの中から十分に適合文書が用意されている 20 個の検索課題を用いた。検索課題は、複数の単語で表現されている。また、各文書とクエリには、smart system のリスト [*1] を使った stopword の除去と Porter Stemming Algorithm による stemming[*2] を行った。

SVM の分類性能はベクトル空間の文書ベクトル表現に依存するため、TF と TF-IDF の 2 種類で比較を行った。TF-IDF は一般的に使われている次の計算式を使用した [1]。

$$w(t,d) = \frac{\log(tf(t,d)+1)}{\log(uniq(d))} \log \frac{N}{df(t)} \tag{3}$$

- $w(t, d)$：文書 d における単語 t の重み。
- $tf(t, d)$：文書 d における単語 t の出現頻度。
- N：データ集合内の文書総数。
- $df(t)$：属性 t を含む文書数。
- $uniq(d)$：文書 d における属性数

文書ベクトルの属性数は約 17 万である。SVM に基づく適合フィードバックの初回フィードバック次では、コサイン類似度を用いて適合度を計算し、初回の提示文書を選んでいる。その際にはすべての属性を使用している。それ以降のフィードバックでは、判別超平面からの距離が適合文書領域側で最も遠い文書からユーザに提示する。SVM の学習にはすべての提示文書を使用している。

∗1 http://www.lextek.com/manuals/onix/stopwords2.html
∗2 http://tartarus.org/?martin/PorterStemmer/

4.2 評価指標

参考文献 [1] で用いられている指標を基にした。検索性能を評価する指標として、各フィードバック回数で終了した場合に、提示された全文書中の累積適合文書の割合 P を用いた。具体的には、ユーザが 1 回に判定する文書数を S, フィードバック回数を m(初回は $m=0$) として、そのフィードバック回までにユーザに提示された文書の数 $S(m+1)$ とその文書中の適合文書の数 R から、

$$\mathrm{P} = \frac{R}{S(m+1)} \tag{4}$$

で計算した。また、学習性能の評価は「上位 30 文書における精度 P30」を適用する。 これにより、最終的に生成された分類器の検索における学習性能が比較できる。以下の式で計算した。p は各回の上位 30 文書中の適合文書数である。

$$\mathrm{P30} = \frac{p}{30} \tag{5}$$

各フィードバック回の提示文書数 $S=10$ 、最大フィードバック回数 $M=9$ とした。各検索課題で、M 回再検索を行い各回で S 個の文書をユーザに提示する。各フィードバック回で評価指標を計算し、検索課題全ての平均値を計算し、グラフにした。

4.3 実験結果

表 1 は、提示文書に使用されている属性のみを用いて探索空間を縮小する手順で、SVM を使用した適合フィードバックを行った際の属性数の推移の平均である。適合・非適合文書に使用されている属性のみを用いた場合と、適合文書のみ、非適合文書のみの属性を用いた場合の計 3 つの手順の属性数の推移を示している。各条件での全検索課題の各フィードバック回における探索空間の大きさの平均をとっている。縮小前の属性数は 172896 である。元の探索空間と比べ、非常に小さい探索空間で検索が行われていることがわかる。なお、各フィードバック回でランダムに属性を選択し、属性数を増やしていく手順では、このうち適合・非適合文書の属性を使用した場合の属性数の平均と同様の探索空間の大きさで適合フィードバックを行うように設定し、実験をおこなった。

表 1: 属性数の推移

提示文書に使用されている属性を用いる手順

適合・非適合文書	$m=1$	$m=2$	…	$m=8$	$m=9$
TF	1154	2103	…	5340	5662
TF-IDF	447	1316	…	4249	4581
適合文書のみ	$m=1$	$m=2$	…	$m=8$	$m=9$
TF	581	798	…	1928	2016
TF-IDF	223	601	…	1803	1884
非適合文書のみ	$m=1$	$m=2$	…	$m=8$	$m=9$
TF	676	1425	…	4241	4656
TF-IDF	245	653	…	2672	2956

図 3、図 4、図 5、図 6 の凡例において、SVM と表記されているグラフは探索空間を縮小していない通常の SVM に基づく適合フィードバックのグラフである。SVM(reduction) は提示文書全てで使用されていた属性のみを用いる手順のグラフである。SVM(reduction relevant) は提示文書のうち、適合文書で使用されている属性のみを用いる手順のグラフであ

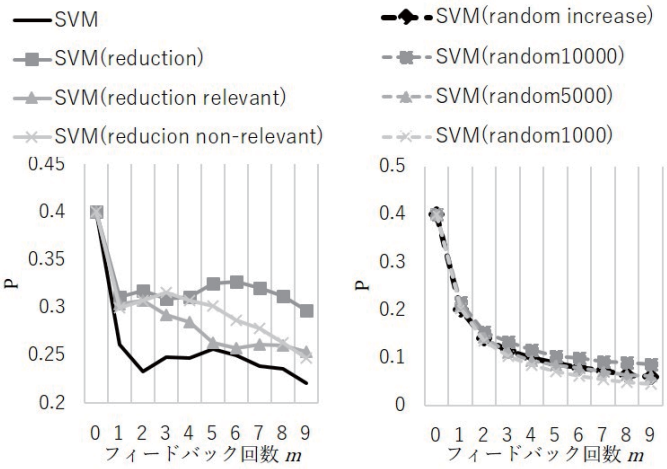


図 3: TF における検索性能 P

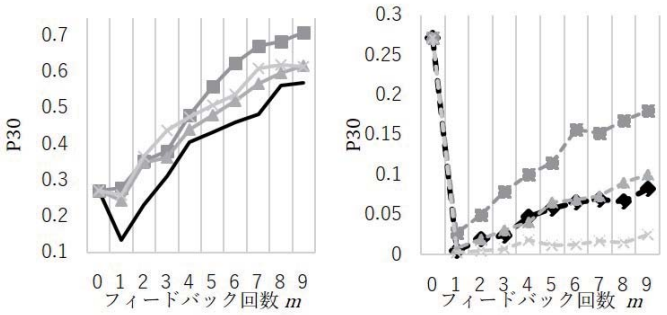


図 4: TF における学習性能 P30

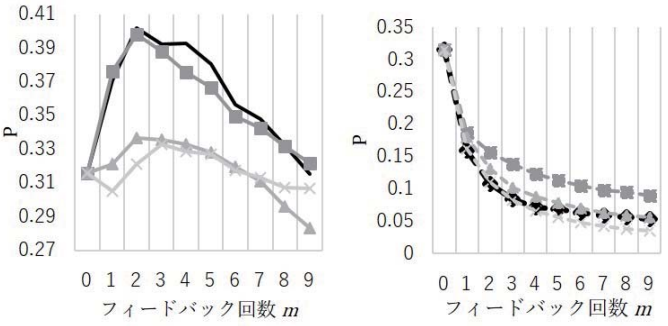


図 5: TF-IDF における検索性能 P

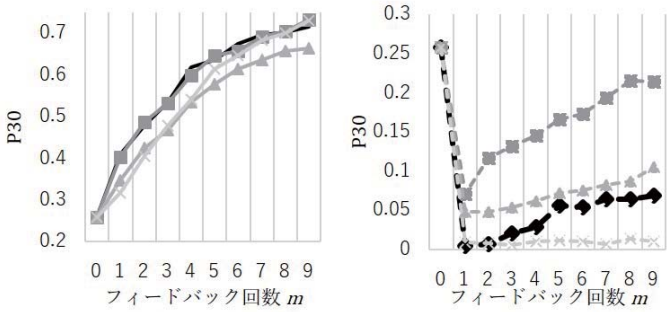


図 6: TF-IDF における学習性能 P30

り、SVM(reduction non-relevant) は提示文書のうち、非適合文書で使用されている属性のみを用いる手順のグラフである。SVM(random) は属性をランダムに選択し、探索空間を縮小した SVM に基づく適合フィードバックのグラフである。ここで、random10000 は、属性をランダムに 10000 個選択したことを示している。SVM(rendom increase) は各フィードバック回において、属性をランダムに選択し、探索空間を広げていく手順を示している。SVM(reduction) と同様の探索空間の大きさで検索を行うように各フィードバック回で増やす属性数を決めている。これらの図より、提示文書全てで使用されていた属性のみを用いる手順により探索空間を縮小した SVM に基づく適合フィードバックでの評価指標の値が、最終的なフィードバック回では、どの条件においても最も高い値を示していることがわかる。ランダムに属性を選択した場合の性能が、探索空間を縮小していない通常の SVM に基づく適合フィードバックと比べ大きく下がってしまうことがわかった。特に、選択する属性数が 1000 の場合では、ほとんど適合文書を発見できていない。通常の SVM と比較し、提示文書全てで使用されている属性のみを用いる手順により探索空間を縮小した場合、最終的なフィードバック回での P の値は TF では約 0.07、TF-IDF では約 0.01 向上した。これは提示した 100 文書のうち、それぞれ平均して TF では 7 文書、TF-IDF では 1 文書、通常の SVM よりも多くの適合文書を発見できていることを示している。

5. 考察

ランダムに属性を選択する手順では、適合フィードバックの性能が大きく下がってしまった。今回の実験のような文書検索では、全ての属性の数に対し、適合文書を判別するための有用な属性の数は非常に少ないと考えられる。このため、ランダムに属性を選択する手順では、適合・非適合の判別に有用な属性を能動的に選択することはできず、選ばれた属性のほとんどが、検索に無意味な属性になってしまうため、性能が大きく下がったと推測することができる。

一方、提示文書のうち、適合・非適合文書で使用されていた属性のみを用いる手順により探索空間を縮小した場合、評価指標は最終的なフィードバック回でどの条件においても最も高い値を示している。この手順は、「システムが適合と判断をしたが、実際は非適合であった文書 (非適合文書)」と、「システムが適合と判断をし、実際に適合であった文書 (適合文書)」に使われていた属性のみを用いることで、適合・非適合の判断に有用であろうと考えられる属性を選択していくものである。ランダムに属性を選択した場合と比べ、能動的に検索システムが分類に必要な属性を選択していくため、多数の検索に無意味な悪い影響を与える属性を除外することができる。このため性能が向上したと考えることができる。

提示文書で使用されている属性のみを用いる場合と、非適合文書で使用されている属性のみを用いる場合では、先ほどの適合・非適合文書両方で使われている属性を用いる手法と比べ、評価指標の値は低くなった。このことより、適合・非適合文書それぞれに用いられている属性の中に、適合フィードバックの性能向上に有効な属性が含まれていることがわかる。

2 種類の探索空間縮小手順の比較により、ランダムに選択した空間では、性能が著しく落ちてしまうが、検索に有用な属性を選択していくことで適合フィードバックの性能を向上させることが可能であることを示すことができた。

TF と TF-IDF による提示文書で使用されていた属性のみを用いる手順により探索空間を縮小した場合の結果を比較すると、TF において性能の向上が TF-IDF より大きかった。これは、TF では単語の頻度のみを重みとしているので、TF-IDF のように、全文書中でのその語の重要度を考慮していない。そのため、通常の SVM に基づく適合フィードバックでは、TF-IDF と比べ検索に無意味な属性の影響をより強く受けてしまと考えることができる。提示文書全てで使用されていた属性のみを用いる手法で探索空間を縮小することにより、この無意味な属性を除くことができていると考えられる。このため、TF の文書ベクトル表現において探索空間を縮小することは、TF-IDF と比べ、適合・非適合文書に含まれていない属性を除くことによる効果が大きかったため、より性能を向上させることができたと考察することができる。

6. まとめ

本研究では、SVM に基づく適合フィードバックにおける探索空間の縮小が性能に与える影響を実験的に分析した。ランダムに属性を選択する手法と、提示文書で使用されていた属性のみを用いる手法の 2 種類の探索空間縮小手順を比較し、TF と TF-IDF の 2 つの文書ベクトルの違いを考慮した実験を行った。その結果、ランダムに属性を選択する手法では性能が著しく落ちてしまったが、提示文書全てで使用されていた属性のみを用いる手法では、特に TF の文書ベクトル表現において、最終的なフィードバック回での性能が大きく向上した。TF において、探索空間を選択することは適合フィードバックの性能向上にとても有効であることが確認できた。検索に有用な属性を選択できる手法であれば、探索空間を縮小することで SVM に基づく適合フィードバックの性能を向上させることが可能であると示すことができた。

参考文献

[1] 村田博士, 小野田崇, 山田誠二:SVM を用いた対話的文書検索における適合性評価の比較分析, 知能と情報 (日本知能情報ファジィ学会誌)Vol23,No.6,pp.853-862(2011)

[2] 小野田崇:サポートベクターマシン, オーム社,(2007)

[3] 黒岩真吾, 柘植覚, 獅々堀正幹, 任福継, 北研二:Simple PCA を用いたベクトル空間情報検索モデルの次元削減, 電気学会論文誌 C 巻：125 号 11pp.1773-1779(2005)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

経営情報キュレーションのための事前学習付き重要文ランク学習

Neural Ranking with Pretraining for Curation of Important Sentences in Business Operations

是枝祐太 Yuta Koreeda　黒土健三 Kenzo Kurotsuchi　柳瀬利彦 Toshihiko Yanase　柳井孝介 Kohsuke Yanai　間瀬久雄 Hisao Mase　佐藤美沙 Misa Sato

日立製作所研究開発グループ
Research & Development Group, Hitachi, Ltd.

We have developed a machine learning method for ranking sentences based on their importance, to assist decision making in business operations. The proposed method is based on deep learning that is trained end-to-end from user feedbacks to capture semantic importance of sentences without relying on domain knowledge of business operations. We employ pretraining to avoid needs for large training data, which we cannot obtain easily because there are numerous groups of people with different interest in business operations and the each group tends to be small. The proposed method outperformed conventional ranking methods in an automated evaluation. We validated the quality of the ranking with a subjective impression evaluation.

1. 重要性に基づくランキング

営業活動，経営管理，知的財産，マーケティングなどの経営活動において，合理的な意思決定のためには多様で，深い見識が必要である．自らの役割に関係のあるニュース記事，有価証券報告書などの経営情報を日々読むこと理想的であるが，アクセス可能な情報のすべてを読み解くのは現実的ではない．意思決定を支援するために，それぞれのユーザにとって重要度が高い情報を効率よく集める方法が必要とされている．

効率的に重要度の高い情報を集める方法として，情報を重要度に基づきランキングし，ユーザにとって重要と思われる情報のみを提示するキュレーションが注目されている．経営活動に関するキュレーションは以下理由から人手で行うコストが高い．

- ユーザがどのような情報を重要とするかを理解するためには高度なドメイン知識が求められる．
- そのようなドメイン知識はユーザ群の特性により無数に存在する．

本研究の目的は，ユーザにとっての情報の重要度をユーザフィードバックから学習し，情報を自動でランキングできるシステムを実現することである．特に，企業の一部署など類似した嗜好性を持つユーザ群のために，異なる日付，あるいは異なる取引先など，異なる情報のグループごとに，重要な情報を文単位でまとめ，提示する問題に取り組む．

情報のランキングは情報検索のコンテキストで盛んに研究されている（[Liu 09]）．情報検索におけるランキングでは検索クエリと検索対象の関係性を捉えることが主たる研究対象とされてきた．本研究で対象とするキュレーションには検索クエリが存在せず，文の内容自体の重要性に基づくランキングを対象にしている点が異なる．

検索クエリとの関係性に基づかない，あるいは検索クエリとの関係性を補完するために使われる重要性に基づくランキングは，リコメンデーションや情報検索などで使われてきた．リコメンデーションで使われる協調フィルタリングはユーザ間の嗜好の類似性を基礎としているため，新しい情報を他のユーザに薦めるためには，その情報に対して十分なフィードバックを取得する必要がある．経営情報キュレーションでは，各ユーザ群の大きさが限られ，かつ新しい情報が重要とされるため，これらの手法は適用できない．情報検索の枠組みで重要性をモデリングする方法として例えば [Page 99] が知られているが，この手法はウェブサイト間の被リンク関係を用いているため，協調フィルタリングの場合と同様に，本研究の用途には効果が小さい．

ランク学習において，文の内容から重要性をモデリングしようとした試みに [Duan 10, Beigman Klebanov 14] などがあるが，これらの研究ではドメイン依存の重要性を捕らえるために相応の特徴量エンジニアリングを行っている．前述したとおり，経営活動を支援するためには異なる嗜好を有するユーザ群の要求に応える必要があるため，ドメイン知識を前提とした手法は経営支援には適さない．一般的な情報の質について検討した研究には [Lee 02, Zhu 00] があるが，本研究でとらえようとしているような経営判断における意味的な重要性については言及していない．

以上より経営情報キュレーションのための重要文のランク学習には，次の要素が特に重要だと考えられる．

1. メタ情報や，他ユーザの評価からだけではなく，文の意味情報から重要性をとらえ，ランキングを行う必要がある．
2. 重要性の観点はユーザ群ごとに多様であるため，人手で重要性のドメイン知識をモデリングすることは望ましくない．
3. 異なる嗜好を持つユーザ群が多数存在する一方で，各ユーザ群の大きさは限られるため，(2) を補うために大量のデータを取得することが難しい．

本研究では，ドメイン知識へ依存することなく意味情報の抽出とランキングを end-to-end で学習できる深層学習によるランク学習法を開発する．データが大量に必要であるという深層学習の欠点は経営情報キュレーションにおいて致命的であるため，それ補うために経営文書に特に効果的と考えた [Kiros 15] の事前学習を用いることを提案する．本報告では，自動評価に基づく評価実験で提案手法をベースラインと比較し（3.2 節），実験の妥当性を検討するため

連絡先: 是枝祐太，株式会社日立製作所，〒 185-8601 東京都国分寺市東恋ヶ窪一丁目 280 番地，042-323-1111，yuta.koreeda.pb@hitachi.com

に人手による A/B テストを行う（3.3 節）.

2. 経営の意思決定支援のためのランク学習

2.1 問題設定

本研究における問題設定を定義する.

複数の文から構成される情報のグループが複数個と，類似した嗜好性を持つユーザ群があるとする．ここでグループとは，同一ドメインだが条件が異なる文の集合であり，たとえば異なる日付ごとのニュース記事や，異なる会社の有価証券報告書である．あるユーザが 1 つのグループを選択すると，ランク関数によりグループ内の文がランキングされ，所定の数の上位文がユーザに提示される．ユーザは提示された文に対して，ユーザの考える重要性の観点から，*Like* ボタンのような形式で各文にフィードバックを与える．1 回の提示で得られた文とフィードバックのペアが複数個集まったものをセッションと呼ぶこととする．前述した提示とフィードバックを異なる情報のグループ，異なるユーザで行い，得られた複数のセッションからランク関数を更新する.

2.2 意味表現エンコーダ

文を入力に，文の意味を表現する固定長のベクトル出力する関数をエンコーダと呼称する．そこで，本研究ではディープラーニングを用い，文から end-to-end でランキングを行う.

セッション i の文 j が $L_{i,j}$ 個の形態素から構成されるとする.

$$\mathbf{x}_{i,j} = \{\mathbf{x}_{i,j,t}\}_{1 \leq t \leq L_{i,j}} \tag{1}$$

ただし $x_{i,j,t}$ はセッション i の文 j の t 番目の形態素の one-hot 表現である．各行に one-hot 表現に対応する分散表現を持つ行列 $\mathbf{W}_E$ を用い，各形態素を分散表現 $\mathbf{u}_{i,j}$ に埋め込む.

$$\mathbf{u}_{i,j} = \mathbf{x}_{i,j,t} \cdot \mathbf{W}_E \tag{2}$$

Long Short-Term Memory([Hochreiter 97]) を用い，形態素の分散表現列から，LSTM に $\mathbf{u}_{i,j,L_{i,j}}$ を入力したときの LSTM の状態を，文の意味表現ベクトル $\mathbf{e}_{i,j}$ として取得する.

$$\mathbf{e}_{i,j} = \mathrm{LSTM}\left([\mathbf{u}_{i,j,1}, \mathbf{u}_{i,j,2}, \cdots]\right) \tag{3}$$

2.3 経営文書に適した事前学習

ビジネス文書はルールや慣習により定型文が頻繁に用いられる. 例えば有価証券報告書では, 企業のとった具体的な施策のあとにはその施策が経営指標に与えた影響が書かれることが多い．したがって，似たような意味合いの文で挟まれた文は同じようなトピック，意味的な特徴を共有していると考えられる．このようなビジネス文書の特徴を踏まえ，RNN を用い前後の文を予測する事前学習 ([Kiros 15]) を活用し，得られるデータが少ないことを補う．エンコーダの出力 $\mathbf{e}_{i,j}$ を入力に，前後の文を予測するデコーダを導入し，エンコーダとデコーダを同時に学習する.

2.4 文の意味表現を用いたランク学習

ランク学習においては，デコーダは破棄し，エンコーダの出力のみを使用する．文ごとに全結合層を使い，文の意味表現ベクトル $\mathbf{e}_{i,j}$ から予測スコア $y_{i,j} \in \mathbb{R}$ を取得する.

$$\mathbf{y}_i = \sigma(\mathbf{e}_{i,j} \cdot \mathbf{W}_0 + \mathbf{b}_0) \cdot \mathbf{W}_1 + \mathbf{b}_1. \tag{4}$$

ただし，σ は各要素に対する正規化線形関数 $\sigma(x) = \max(x, 0)$，$\mathbf{W}_0$，$\mathbf{W}_1$，$\mathbf{b}_0$，$\mathbf{b}_1$ はモデルパラメータである.

ユーザフィードバック $\tilde{\mathbf{y}}_i = \{y_{i,j}\}$ と，予測間の差が小さくなるように学習を行う．本研究では，ユーザは 1 回に提示された文の相対評価を行っているものと考えられるため, 2 つの並び順の差異を比較する permutation probability loss [Cao 07] を採用する. 本手法では, $k = 1$ の permutation probability distribution function $f_P : \mathbb{R}^N \mapsto \mathbb{R}^N$ を使用する.

$$f_P(\mathbf{y}_i) = \left[\frac{\exp(y_{i,j})}{\sum_n^N \exp(y_{i,n})}\right]_{j \in \{1,2,\ldots,N\}}. \tag{5}$$

最終的な損失関数は，2 つの分布の Kullback-Leibler divergence D_{KL} を用い，式 (6) とする.

$$D_{KL}\left(f_P(\tilde{\mathbf{y}}_i) \| f_P(\mathbf{y}_i)\right) + \lambda \sum_{\mathbf{W} \in \{\mathbf{W}_0, \mathbf{W}_1\}} \|\mathbf{W}\|_2 \tag{6}$$

ただし，$\| \bullet \|_2$ はフロベニウスノルムである.

損失関数から求めた勾配をもとに $\mathbf{W}_E$ とエンコーダを含むモデルパラメータをミニバッチ確率勾配法を用い学習する．パラメータの更新には Adam（[Kingma 14]）を用いる．学習データへの過剰適合を防ぐために 0.1 の Dropout（[Srivastava 14]）を式 (4) の全結合層に適用し，L2 正則化の係数 λ を 0.005 とした.

3. 評価実験

3.1 対象とする経営活動

本報告では，様々な経営活動の中でも，営業部署が顧客の動向を洗い出す工程を対象とする. 2.1 節のグループが各顧客企業の動向を示す文に対応しており，顧客名称を選択するとグループ内の文がランキングされ，所定の数の上位文が結果としてユーザに提示される.

下記に本実験において対象とした文の例[*1]を示す.

この表示方法の変更を反映させるため，前事業年度の財務諸表の組替えを行っている.

企業の行動ではあるが，会計上の手続きであり，財務部署の役には立っても営業部署にとって役に立つ情報とはいえない．一方で，下記の例では，適当な具体性を有しており，顧客が生産管理に関して注力していることが読み取れる.

製品の品質当社グループは優れた品質の製品を提供するため，開発から生産まできめ細かい管理体制を敷き最善の努力を傾けている.

3.2 自動評価に基づく評価実験

本実験の目的は，経営情報キュレーションのための重要文ランク学習において，提案手法をベースラインと比較評価することである．人手で付与したフィードバックのアノテーションからオフラインで学習を行い，テストデータ上で自動評価を行う.

*1 日産車体株式会社，2014 年度有価証券報告書より抜粋

表 1: 提案手法とベースラインの性能比較

手法		ランク性能 (nDCG)	提案手法との差
提案手法 (ランク学習	+ 意味表現エンコーダ)	**0.873**	–
SVR	+ 意味表現エンコーダ	0.854	−0.019
ランク学習	+ tf-idf	0.829	−0.044
SVR	+ tf-idf	0.843	−0.030
ランダム		0.682	−0.191

表 2: 異なる事前学習手法の比較

事前学習方法	ランク性能 (nDCG)	提案手法との差
[Kiros 15]	**0.873**	
オートエンコーダ	0.852	−0.021
事前学習なし	0.772	−0.101

[Yanai 17] を用い企業の活動を示す述語の辞書を作成し，構文解析に基づいたルールによりマッチングを行い，有価証券報告書，新聞データから各顧客企業の動向を示す文を抽出した．各企業ごとに，復元法でランダムに抽出した 4 文を 1 セッションとして，セッションの各文に +1(相手企業のことを知るうえで役にたつ)，−1(相手企業のことを知るうえで役にたたない)，0(どちらともいえない) のラベルを付与した．自動車業界の会社の 16 つの企業に対し，それぞれ 5 つのセッションを 4 人のアノテータで独立にアノテーションした (のべ 5120 文)．本実験で用いた 16 社は EDINET で有価証券報告書が閲覧できる自動車業界の会社である．訓練データとテストデータで企業が重複しないように，企業を単位とした k-分割交差検証（$k = 8$）にて各手法を評価した．

学習器の評価を行う際，テストデータを 1 企業ごとに Schulze の選挙方法で単一の順列に統合し，そのデータを予測値と比較した．抽出されたセッションに対してユーザフィードバックを受けるため，学習データとしてのセッションは短いが，実際にランキングを行うのは全文に対してであるためである．評価指標はランキング問題の指標としてよく用いられる normalized Discounted Cumulated Gain (nDCG) を採用した．

文の tf-idf を特徴量としたサポートベクトル回帰（SVR）とランダム推測をベースラインとして採用した．比較対象として，2.3 節の事前学習を行った意味表現エンコーダにより抽出した特徴量を用いた SVR と，tf-idf を特徴量とした 2.4 節のランク学習についても評価する．

提案手法とベースラインの結果を表 1 に示す．文の tf-idf を特徴量とした SVR からは 0.030，ランダム推測からは 0.191 の向上が見られた．SVR と意味表現エンコーダを組み合わせたモデルが次点であり，ドメイン知識へ依存しない意味表現の抽出を意図した意味表現エンコーダが有効であったことが示唆された．一方で，tf-idf を特徴量とした深層学習によるランク学習は，tf-idf を特徴量とした SVR よりも劣った．このことから，ランク学習に深層学習を用いたこと自体ではなく，事前学習した意味表現エンコーダを，ランク学習時に end-to-end でファインチューニングしたことが寄与したものと考えられる．

事前学習法の効果を検証するために，類似する事前学習法としてオートエンコーダを用いた場合と，事前学習を用いらなかった場合についても検証した．オートエンコーダは入力文の前後文ではなく，入力文自身を再構成する事前学習法である．

事前学習なしの条件では，tf-idf を特徴量とした SVR よりも性能が低く，ランダム推測に性能が近かった (表 2)．深層学習をそのまま経営情報キュレーションに適用することは難しく，事前学習が重要であったことが示唆された．また，[Kiros 15] の事前学習はオートエンコーダより性能が優れており，[Kiros 15] が本問題設定に対して有効であったことが確認できた．

表 3: 主観評価における順位の割合

	順位		
手法	1	2	3
提案手法	53 %	34%	13 %
SVR + tf-idf	39 %	55%	6.3%
ランダム	7.8%	11%	81 %

3.3 人手による評価実験

指標を用いた交差検証の結果は指標の選択に大きく依存するため，3.2 節の結果の妥当性を確認するために，A/B テストによる主観評価を行った．

3.2 節の提案手法，tf-idf を特徴量とした SVR，ランダム推定の 3 つの学習済みモデルを用い，それぞれ同じ企業の有価証券報告書からランキングで 4 つの文を選んだ．1 手法 1 列とし，二重盲目の設定でそれぞれ上位文を 4 人の被験者に提示し，企業ごと，モデルごとに順位 $r \in \{1, 2, 3\}$ (低い値は良い順位を示す) を付与するよう指示した．

実験結果を 表 3 に示す．提案手法は過半数の試行において，最も良いと評価された．

本研究において抽出した顧客の動向を示す文には，3.1 節に示したような単なる会計上取り決めが相当数含まれていた．これら会計上の取り決めは企業を問わず類似した表現がなされているため，提案手法と SVR はこれらを取り除くことに成功していた．会計上の取り決めを上位に出力した場合低い評価がなされることが多く，提案手法とベースラインがほとんどの場合ランダムベースラインに打ち勝っていることはこのことに起因している．

主観評価実験において相対的に提案手法が優れていたデータを抜きだしたものを表 4 に示す．SVR が最上位に出力した結果は，具体性にかけており，3.2 節のアノテーションにおいても低い評価が付与されている．“課題”，“向上” といった形態素を含む他の文は具体的な動向について触れられているものが多く，SVR はその仕組み上，形態素レベルの特徴に影響されたものと考えられる．一方で，提案手法が最上位に出力した文は企業の具体的かつ新しい取り組みについて言及されており，価値が高い．本実験では自動車業界の会社を学習にもちいているため物流事業に関する記述は稀であり，SVR では稀な内容語を捉えられなかったものと考えられる．じど提案手法の事前学習が他業界にも及んでいることが寄与したものと考えられる．

4. おわりに

効率的に重要度の高い情報を集め，経営における意思決定を支援するために，ユーザのフィードバックから，特定のユーザ群が重要と考える情報をランキングできる手法を開発した．交差検証に基づく定量的な実験において，提案手法の nDCG は 0.873 であり，非深層学習のベースライン

表 4: 主観評価における出力例と主観評価．文の隣に 3.2 節のアノテーションを Schulze 法で並べ替えた時の順位を示す．

	提案手法		SVR + tf-idf		ランダム	
出力	今後は宅配便の受け取りなど「日々の生活に時間とゆとりを生みだす」サービスの拡充を図るとともに，企業・保育園・病院・駅といった人々が集まる場所への設置による物流ロッカー事業のさらなる拡大も視野に入れ，本サービスを開始します．♠	*	より強固な経営基盤を築き企業価値の一層の向上に向け，グループの総力をあげて次の課題に取り組んでまいります．♡	4	（注）1「自動車」につきましてはトヨタ自動車株式会社および株式会社デンソーから生産計画の提示を受け，生産能力を勘案し，見込生産を行っているため，記載を省略しております．◇	3
	連結財務諸表提出会社を中心として，「魅力ある新商品の開発」という考えのもとに，年々高度化・多様化する市場のニーズを先取りし，お客様の満足が得られるよう，先進技術を導入した積極的な新商品開発を進めております．◇	2	品質第一に徹してお客様の信頼におこたえいたしますとともに，各市場の動きに的確に対応して，販売の拡大に努めてまいりました．♣	1	より強固な経営基盤を築き企業価値の一層の向上に向け，グループの総力をあげて次の課題に取り組んでまいります．♡	4
	品質第一に徹してお客様の信頼におこたえいたしますとともに，各市場の動きに的確に対応して，販売の拡大に努めてまいりました．♣	1	連結財務諸表提出会社を中心として，「魅力ある新商品の開発」という考えのもとに，年々高度化・多様化する市場のニーズを先取りし，お客様の満足が得られるよう，先進技術を導入した積極的な新商品開発を進めております．◇	2	連結財務諸表提出会社を中心として，「魅力ある新商品の開発」という考えのもとに，年々高度化・多様化する市場のニーズを先取りし，お客様の満足が得られるよう，先進技術を導入した積極的な新商品開発を進めております．◇	2
	（注）1「自動車」につきましてはトヨタ自動車株式会社および株式会社デンソーから生産計画の提示を受け，生産能力を勘案し，見込生産を行っているため，記載を省略しております．◇	3	（注）1「自動車」につきましてはトヨタ自動車株式会社および株式会社デンソーから生産計画の提示を受け，生産能力を勘案し，見込生産を行っているため，記載を省略しております．◇	3	加えて，当期純利益等の表示の変更および少数株主持分から非支配株主持分への表示の変更を行っております．♣	6
人手評価	3.0		1.75		1.25	

♠ 日本経済新聞，2016 より抜粋　♣ 株式会社豊田自動織機，2015 年度有価証券報告書より抜粋　◇ 株式会社豊田自動織機，2014 年度有価証券報告書より抜粋
♡ 株式会社豊田自動織機，2013 年度有価証券報告書より抜粋　* 順位情報なし．3.2 節ではセッションを無作為抽出しているため，アノテーションがなされていない文がある．

を上回った．事前学習なし，あるいは異なる方法で事前学習を行った場合と比較し性能が向上したことから，事前学習を行うことが重要であったこと，前後のコンテキストを予測する事前学習法が定型性の高い経営文書において有効であったことが示唆された．実験の妥当性を評価するために A/B テストを行った．提案手法は過半数の試行において，最も良いと評価され，経営活動のための重要文キュレーションにおいて提案手法が有効であることが示唆された．

本報告における実験は規模が小さかったため，今後規模を大きくし実験を行う．また，異なる手法間の比較実験だけではなく，実際の経営活動を更に詳しく分析し，より多面的に手法の有用性を評価する．

参考文献

[Beigman Klebanov 14] Beigman Klebanov, B., Madnani, N., Burstein, J., and Somasundaran, S.: Content Importance Models for Scoring Writing From Sources, in *the 52nd Annual Meeting of the Association for Computational Linguistics*, pp. 247–252 (2014)

[Cao 07] Cao, Z., Qin, T., Liu, T.-Y., Tsai, M.-F., and Li, H.: Learning to Rank: From Pairwise Approach to Listwise Approach, in *the 24th International Conference on Machine Learning*, pp. 129–136 (2007)

[Duan 10] Duan, Y., Jiang, L., Qin, T., Zhou, M., and Shum, H.-Y.: An Empirical Study on Learning to Rank of Tweets, in *the 23rd International Conference on Computational Linguistics (Coling 2010)*, pp. 295–303, Beijing, China (2010)

[Hochreiter 97] Hochreiter, S. and Schmidhuber, J.: Long Short-Term Memory, *Neural Computation*, Vol. 9, No. 8, pp. 1735–1780 (1997)

[Kingma 14] Kingma, D. and Ba, J.: Adam: A Method for Stochastic Optimization, in *3rd International Conference on Learning Representations* (2014)

[Kiros 15] Kiros, R., Zhu, Y., Salakhutdinov, R. R., Zemel, R., Urtasun, R., Torralba, A., and Fidler, S.: Skip-Thought Vectors, in *Advances in Neural Information Processing Systems 28*, pp. 3294–3302 (2015)

[Lee 02] Lee, Y. W., Strong, D. M., Kahn, B. K., and Wang, R. Y.: AIMQ: A Methodology for Information Quality Assessment, *Information & Management*, Vol. 40, No. 2, pp. 133–146 (2002)

[Liu 09] Liu, T.: *Learning to Rank for Information Retrieval*, Foundations and Trends(r) in Information Retrieval, Now Publishers (2009)

[Page 99] Page, L., Brin, S., Motwani, R., and Winograd, T.: The PageRank Citation Ranking: Bringing Order to the Web., Technical Report 1999-66, Stanford InfoLab (1999)

[Srivastava 14] Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R.: Dropout: A Simple Way to Prevent Neural Networks from Overfitting, *Journal of Machine Learning Research*, Vol. 15, pp. 1929–1958 (2014)

[Yanai 17] Yanai, K., Sato, M., Yanase, T., Kurotsuchi, K., Koreeda, Y., and Niwa, Y.: StruAP: A Tool for Bundling Linguistic Trees through Structure-based Abstract Pattern, in *the 2017 Conference on Empirical Methods in Natural Language Processing: System Demonstrations*, pp. 31–36 (2017)

[Zhu 00] Zhu, X. and Gauch, S.: Incorporating Quality Metrics in Centralized/Distributed Information Retrieval on the World Wide Web, in *the 23rd Annual International ACM SIGIR Conference on Research and Development in Information Retrieval*, pp. 288–295 (2000)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

統計的機械翻訳における RIBES による最適化の効果

The effect of optimization by RIBES in statistical machine translation

河田　尚孝 *1　　磯崎　秀樹 *2　　菊井　玄一郎 *2
Naotaka Kawata　　Hideki Isozaki　　Genichiro Kikui

*1岡山県立大学大学院システム工学専攻
Okayama Prefectural University Graduate School of Computer Science and Systems Engineering

*2岡山県立大学情報工学部情報システム工学科
Okayama Prefectural University Faculty of Computer Science and Systems Engineering Department of Systems Engineering

Parameter optimization is indispensable for improving the performance of statistical machine translation. MERT is a standard optimization tool that uses BLEU as the typical objective function. However, for translation between very different language such as English - from/to - Japanese translation, BLEU has very low correlation with human judgement. Therefore, it is better to use more human-like evaluation function like RIBES instead of BLEU as the objective function in the optimization process. In this paper, we investigate effects of RIBES used as the objective function of MERT and found that RIBES achieves better than BLEU when SMT is forced to determine the word order which is very different from the source sentence.

1. はじめに

統計的機械翻訳（Statistical Machine Translation, SMT)[Koehn 09] においては，翻訳モデルや言語モデルなどを素性関数として対数線形モデルによって統合したモデルが広く利用されている．この方法では，個々の素性関数のパラメータを推定したあと，対数線形モデルにおける重みパラメータ（単に「重み」と呼ぶ）の推定（最適化と呼ぶ）が行われる．この最適化の手法として MERT(Minimum Error Rate Training)[Och 03] が知られている．MERT では，翻訳結果が参照訳（正解訳）とどの程度意味的に乖離しているかを評価するエラー関数を用意し，これを目的関数として検証用の対訳コーパスの翻訳結果に対して関数値が最小となるように対数線形モデルの重みを調整する．MERT では目的関数として翻訳評価関数 BLEU[Papineni 02]（の値を逆にしたような関数）がよく利用される．

しかしながら， BLEU は欧米言語間の翻訳のように語順が大きく変わらない言語間の翻訳では人手評価とある程度の相関あるが, 日英翻訳や英日翻訳では人手評価との相関が非常に低いことが報告されている [Echizen-ya 09]．当然ながら目的関数は人間の判断を反映していることが望ましいため，人手評価との相関が低い BLEU は目的関数として不適切である．この問題に対して，平尾ら [平尾 14] が提案した RIBES（の値を逆にしたような関数）を目的として用いることが考えられる．

ところが, Duh ら [Duh 12] によれば, RIBES は非常に「滑らかでない (unsmooth)」ため，翻訳最適化の目的関数として使うのは難しいことが指摘されている．この問題を回避するために，彼らは多目的最適化の枠組みを用いて BLEU と RIBES を混合したような評価関数を提案している．彼らは粗い近似として BLUE と RIBES を 3:1 で加重和した翻訳評価関数を推奨している．

本研究では統計的翻訳への入出力の語順の違いと MERT における評価関数の関係について再検討する．我々の仮説は次の通りである

> 「翻訳処理 (SMT) において語順を大きく変える必要がある言語対の場合は MERT の目的関数として BLUE より RIBES が適切であり，そうでない場合は BLEU の方が適切である」

本研究では Head Finalization を適用することによって統計翻訳において対応すべき語順の差を変更することにより，この仮説について検討する．以下，本稿の構成は次の通りである．2 章では我々が利用した統計的機械翻訳について，3 章では翻訳自動評価法のうち本研究で用いた BLEU と RIBES について説明する．4 章では実験について述べる．

連絡先: 河田　尚孝，岡山県立大学大学院, c226017c@cse.oka-pu.ac.jp

2. 対象とする統計的機械翻訳

本研究では以下の式で示される対数線形モデルに基づく統計翻訳を用いる．

$$\begin{aligned}\hat{e} &= \arg\max_{e} P(e|f) \\ &= \arg\max_{e} \sum_{m} w^{\mathrm{T}} h_m(f,e) \qquad (1)\end{aligned}$$

$P(e|f)$ を表す式 (1) において w_m は素性関数 $h_m(f,e)$ の重みである．素性関数としては翻訳モデル, 言語モデル（に対応する関数）のほか任意の関数が利用可能である．また，重み w_m は後述する MERT により学習される．

2.1 誤り率最小化学習 (MERT)

MERT(Minimum Error Rate Training) は, 対訳データ $< F, E >$ に対して，以下の損失関数 $l_{error}(\cdot)$ を最小化する w_m を探索する．

$$l_{error}(F, E, C; \mathbf{w_m}) = error(E, argmax_{<e,d>\in c^{(i)}} \mathbf{w_m^{\mathrm{T}} h(f^{(i)} e, d)}$$

ここで，$< f, e >$ は $< F, E >$ の各対訳を表し, C は k-best リストである．そして, 対訳データに対して適切な前処理を施すことでより正確に学習することができると考えられる．例として本実験でも使用している前処理手法である Head Finalization について説明する．

2.2 Head Finalization

本研究では英日翻訳については，統計的翻訳の前処理として磯崎ら [Isozaki 10] により提案された Head Finalization（以下,「ヘッド・ファイナル化」）と呼ぶ処理を適用する．ヘッド・ファイナル化とは，フレーズ内の主辞を最後（一番右）に並び変える処理であり，英日翻訳のように 1 ）目的言語が主辞後置型の言語であり，2 ）原言語の語順がそれを大きく異なる言語であるような言語対において有効な統語的前処理手法である *1．この処理により, 言語間の語順の差が相当程度解消され, 翻訳精度が向上する．ヘッド・ファイナル化が行われた文章を図 1 に示す．

並び替え前　when the fluid pressure cylinder 31 is used , fluid is gradually applied .

並び替え後　the fluid pressure 31 cylinder used is when , fluid gradually applied is .

図 1: 英語データの事前並べ替え

3. 自動評価尺度

翻訳機を自動的に評価する方法は翻訳評価の効率化という観点から従来より様々な手法が提案されている．そこで用いられるのが, 出力された機械訳を用意された参照訳と比較して自動でスコアを与える自動評価尺度である．以下に, 今回の実験で比較対象とした自動評価尺度を示す．

3.1 BLEU

BLEU は n-gram 適合率 p_n に基づいてスコアの計算を行う．BLEU のスコアは以下の式で表される．

$$BLEU = BP * exp(\frac{1}{N}\sum_{n=1}^{N}\log p_n) \tag{2}$$

適合率 p_n については n-gram 精度の幾何平均を表す．また BP は機械訳が参照訳と比較して短い場合に課せられるペナルティ係数である．BP は機械訳の単語の総和を c, 参照訳の単語の総和を r とすると, 次の式 (3) で表される．

$$BP = \begin{cases} 1 & (c > r) \\ e^{1-\frac{r}{c}} & (c \leq r) \end{cases} \tag{3}$$

3.2 RIBES

RIBES[平尾 11] はグローバルな語順に注目し, 順位相関係数を用いて翻訳品質の評価を行う．RIBES スコアは次の式で表される．

$$RIBES = NKT \times P^{\alpha} \quad (0 \leq \alpha \leq 1) \tag{4}$$

RIBES は参照訳 R と機械訳 H の語順の順位相関係数を用いるので, まず参照訳 R の単語に出現した順に 0 から順位を与え, 整数のリストを作る．このリストを r とする．次に機械訳 H の単語の内, 参照訳に出現したものをリスト r の整数値に置き換えた整数リスト h をつくる．リスト r と h の順序列間の順位相関係数を計算することで参照訳と機械訳の間で一致して出現する単語の出現順の近さを測ることが出来る．本研究では順位相関係数として Kendall の τ を採用している．順位相関係数 τ は以下のように表す．

$$\tau = \frac{\text{昇順ペア数}}{\text{全ペア数}} \times 2 - 1 \tag{5}$$

ここで式 (7) 中の NKT は以下の式で表される．

$$NKT = \frac{\tau + 1}{2} \tag{6}$$

しかしこの NKT は機械訳の単語が短いと過剰に高い値となる可能性があるため, 平尾ら [平尾 14] より BLEU で用いられているペナルティ係数 BP を用いた RIBES の式が提案されている．

$$RIBES = NKT \times P^{\alpha} \times BP^{\beta} \quad (0 \leq \alpha \leq 1, 0 \leq \beta \leq 1) \tag{7}$$

本実験では式 7 を用いて実験を行う．また式 7 中の α, β については参考文献 [平尾 11][平尾 14] より, $\alpha = 0.25$, $\beta = 0.1$ で評価している．

4. 実験

4.1 対訳データの準備

統計翻訳のトレーニングデータとして NTCIR-7 特許翻訳タスクの英日翻訳データ約 180 万文を使用する．最適化には同タスク内の開発データ 2655 文のうち無作為に抽出した 2155 文を用いる．残りの 500 文を自動評価尺度によるスコアを計算する際のテストデータとして使用する．以下に使用した対訳データの内訳を示す．

表 1: 対訳データの内訳

データの種類	文章の数
トレーニングデータ	約 180 万文
チューニング用データ	2155 文
テストデータ	500 文

全ての対訳データに対して, 以下のような処理を行った．

処理 1 日本語データを半角に変換

処理 2 特定の使用不可記号を文字列に変換

処理 3 括弧で囲まれている部分の削除

処理 4 データの分かち書き

処理 5 英語データの事前並び替え

処理 1 では, 日本語のデータに対して全角数字, アルファベット, 記号, カタカナをすべて半角に変換する処理を行う．

処理 2 では, Moses で使用が禁止されている記号を実体参照表現に置き換える．(例. & → &)

処理 3 では, 単語を補足する目的で括弧を使用している部分を括弧ごと削除した．　ただし ’ (a) ’ や ’ 1) ’ などの図や表を表しているものは中身を残して括弧のみを取り除く．理由は NTCIR-7 のデータには, ある単語を補足する目的で括弧を用いている部分が存在する．しかし, 括弧の位置が日本語と英語で対応していないものや, 片方の言語でしか括弧が現れていな

*1　日英翻訳のように逆方向の翻訳において，後処理として語順を並び変える方法 [Sudoh 11] が提案されているが本研究では利用しない

いもの, 括弧内の単語の対応が取れていないものが多数存在するため, 単語アライメントの計算や構文解析がより正確に行えるようにするためである.

処理 4 では, 日本語データの単語分割にはオープンソースの形態素解析エンジンである MeCab を使用した. 英語はカンマやピリオドなどの記号を分割する必要があったため, Moses に含まれる tokenizer.perl を用いて分割した.

処理 5 では, ヘッド・ファイナル化により, 英語の語順をあらかじめ単語を並び替えて日本語の語順に近づけておく. 単語の並び替えを行うためには英語の係り受け解析を行う必要があるため, 英語構文解析器である Enju[Yusuke 08] を用いた.

4.2 実験環境

前述した処理を行った対訳データと機械翻訳システム Moses を用いて英日, 日英翻訳機を作成した. 単語アライメントツールには GIZA++[*2] を使用した. 言語モデルの学習には KenLM を用い, トレーニングデータに含まれる文のみを使用した. 今回は最大 5 グラムまで学習させている. MERT による重み最適化には Moses に含まれる. mert.cpp を使用している. mert.cpp 内の目的関数を RIBES に変更することで RIBES による最適化を可能にしている.

4.3 実験項目

本研究では最適化における RIBES の効果を調べるために RIBES と BLEU を目的関数とした最適化によるスコアの推移を調べた. なお, 今回は英日, 日英翻訳機を使用しており, ヘッド・ファイナル化を行ったものを「HF あり」, ヘッド・ファイナル化を行っていないものを「HF なし」としている. また, RIBES と BLEU を線形結合した目的関数を用いることで, 語順と単語の適合率のどちらを重視した方がより最適化の効果が大きいのかを確かめた. RIBES と BLEU を線形結合した目的関数を以下に示す.

$$\text{目的関数} = \alpha BLEU + (1-\alpha) RIBES$$

二つの関数の割合について, α を以下のように設定して実験を行った.

$$\alpha = (1, 0.7, 0.5, 0.3, 0)$$

なお, $\alpha = 1$ は BLEU のみでの最適化を表している.

4.4 評価指標

翻訳機の品質を人手で評価することはコストがかかるため, 自動で評価できることが望ましい. そこで自動評価尺度を翻訳機の評価指標として用いる. 本実験では評価指標として RIBES を使用する. 使用した RIBES は式 (7) である. また, $\alpha = 0.25$, $\beta = 0.1$ で実験を行っている.

4.5 実験結果と考察

評価関数を RIBES に変更し, RIBES と BLEU を目的関数として最適化を行った結果を図 2 に示す. 図 2 より, ヘッド・ファイナル化を行ったものについて, BLEU の方が最適化後のスコアが高いことが分かった. しかし, BLEU のみで最適化した場合と BLEU と RIBES を線形結合した場合のスコアは同程度であった. これは Duh らが述べているように RIBES での最適化がうまくいかない原因の一つとして考えられている RIBES が「滑らかではない」関数であるという問題が BLEU を加えることで緩和されるからだと考えられる. 次にヘッド・ファイナル化を行っていない場合について, RIBES で最適化した方が BLEU よりも最適化後のスコアが上がっていることが分かった. また, RIBES の割合を大きくするほどスコアが上がっている. この結果から, 語順が異なる言語対に対して RIBES は語順を正そうと働くため, 単語の適合率を重視する BLEU よりも最適化の目的関数として適していることが分かった.

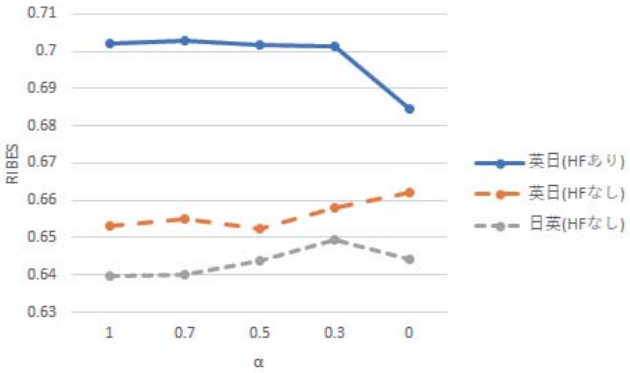


図 2: RIBES と BLEU の比率を変えたときの最適化

次に RIBES と BLEU を線形結合した目的関数を用いた最適化による RIBES スコアの推移について図 3(a)〜3(c) に示す. 図 3(a) より, ヘッド・ファイナル化を行った場合に効果がある BLEU を目的関数としたとき, スコアは単調に増加していることが分かる. 一方 RIBES での最適化では, 1 回の学習によるスコアの変化が大きく, 最適化が BLEU よりも早く終わっている.

続いて図 3(b) について, ヘッド・ファイナル化を行わない場合, RIBES での学習により単調にスコアが増加していった. 図 3(c) の場合は, 最適化のときに BLEU の方が大きくスコアが変化していた. また図 3(a) と図 3(b) の共通点として, 学習後のスコアがより高くなる目的関数を用いた学習ではスコアが単調増加している. それに対してスコアが低くなる目的関数を用いた場合, 学習の回数は少なく, 1 回の学習によるスコアの変化が大きくなる傾向が見られた.

5. おわりに

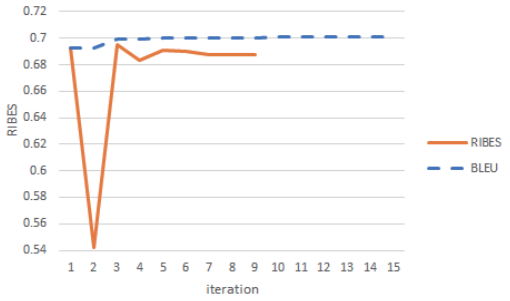
本研究では ngram 再現率による翻訳自動評価尺度である BLEU，および，大域的な語順を考慮した翻訳自動評価法である RIBES を目的関数として MERT の最適化の効果について日本語一英語間の特許文翻訳を対象として検証した. その結果, RIBES は日英翻訳やヘッド・ファイナル化なしの英日翻訳のように統計翻訳において語順を大きく並び替える必要がある言語対に対して BLEU より効果的であることが分かった. 一方，ヘッド・ファイナル化による事前処理を行って統計的翻訳における語順の並び替えが限定的である場合には BLEU のほうが効果的であり，さらに RIBES と BLEU を線形結合することで BLEU のみよりやや効果的であることが分かった.

今回は最適化の効果を RIBES で評価したが，今後の課題として, 人手評価による検証があげられる.

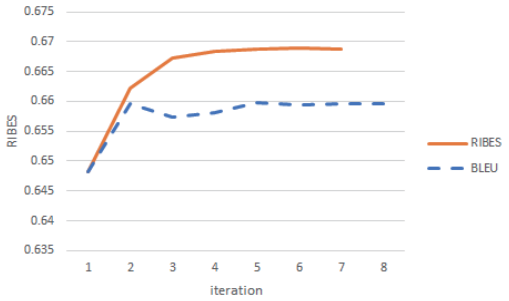
参考文献

[Duh 12] Duh, K., Sudoh, K., Wu, X., Tsukada, H., and Nagata, M.: Learning to Translate with Multiple Objectives, *Proceedings of the 50th Annual Meeting of the Associateion for Computational Linguistics*, Vol. 1, pp. 1–10 (2012)

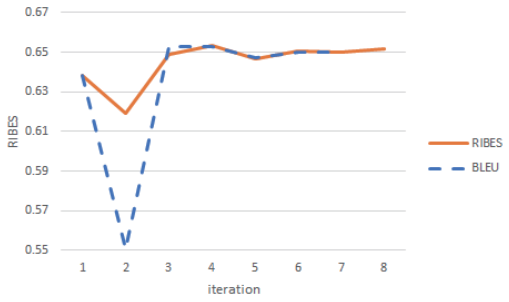
*2 http://www.statmt.org/moses/giza/GIZA++.html



(a) 英日 (HF あり) の最適化の推移



(b) 英日 (HF なし) の最適化の推移



(c) 日英 (HF なし) の最適化の推移

図 3: 最適化の推移

[Echizen-ya 09] Echizen-ya, H., Ehara, T., Shimohata, S., Fuji, A., Utiyama, M., Yamamoto, M., Utsuro, T., and Kando, N.: Meta-Evaluation of Automatic Methods for Machine Translation using Patent Translation Data in NTCIR-7, *Proceedings of the 3rd Workshop on Patent Translation*, pp. 9–16 (2009)

[Isozaki 10] Isozaki, H., Sudoh, K., Tsukada, H., and Duh, K.: Head Finalization: A Simple Reordering Rule for SOV Langages, *Proceedings of the Joint Fifth Workshop on Statistical Machine Translation and MetricsMERT*, pp. 244–251 (2010)

[Koehn 09] Koehn, P.: Statistical Machine Translation, *Cambridge University Press* (2009)

[Och 03] Och, F. J.: Minimum Error Rate Training in Statistical Machine Translation, *Proceedings of the 41th Annual Meeting of the Association for Computational Linguistics (ACL)*, pp. 160–167 (2003)

[Papineni 02] Papineni, K., Roukos, S., Ward, T., and Zhu, W.-J.: BLEU: a Method for Automatic Evaluation of Machine Translation, *Proceedings of the 40th Annual Meeting of the Association for Computational Linguistics (ACL)*, pp. 311–318 (2002)

[Sudoh 11] Sudoh, K., Wu, X., Duh, K., Tsukada, H., and Nagata, M.: Post-ordering in statistical machine translation, *Proceedings of the 3rd Workshop on Patent Translation* (2011)

[Yusuke 08] Miyao, Y., Jun'ichi Tsujii:Feature Forest Models for Probabilistic HPSG Parsing, *Computational Linguistics*, Vol. 34, No. 1, pp. 35–80 (2008)

[平尾 11] 平尾努, 磯崎秀樹, 須藤克仁, Duh, K., 塚田元, 永田昌明：RIBES: 順位相関に基づく翻訳の自動評価法, 言語処理学会 第 17 回年次大会 発表論文集, pp. 1115–1118 (2011)

[平尾 14] 平尾努, 磯崎秀樹, 須藤克仁, Kevin, D., 塚田元, 永田昌明：語順の相関に相関に基づく機械翻訳の自動評価法, 自然言語処理, Vol. 21, No. 3, pp. 421–444 (2014)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

ラフセット理論を用いた特許公報分類支援システムの提案

An Idea of Patent Document Classifier Support System Using Rough Set Theory

樽松理樹[*1]
Masaki KUREMATSUI

[*1] 岩手県立大学ソフトウェア情報学部
Iwate Prefectural University, Faculty of Software and Information Science

In this paper, I proposed a framework of estimating invention task and means using Rough Set Theory. It is important to check exists patents before submitting own patents or sailing new products. However, it is take long time to check a lot of patents. In order to support this task, I propose a framework which estimates decision rules from labeled patent journal using Rough Set Theory and predicts invention task and means from unlabeled patents using them. First, this framework extracts terms from abstracts of patents which experts identified invention task and means in advance. Secondly, it selects terms based on document frequency and makes a Document Term Matrix. Thirdly, it makes decision rules by Rough Set Theory. Finally, it predicts invention task and means using these rules. In order to evaluate this system, I am doing experiments with an expert. I will tell the experimental results and evaluation results about this method on the conference.

1. はじめに

特許公報[発明協会 05]は，代表的な知的財産情報である．その情報を有効活用するためには，内容把握，分類が重要である．これまでに提案されてきた特許処理支援システムの多くは，特許公報の請求項や付与されたコードを用いた検索システム[藤井 12]である．しかし，実務においては，コードとは異なる分類を用いる場合がある．研究協力者である企業の知的財産部門に所属する専門家は，その特許が述べている課題と手段で分類している．特許公報が膨大であるため，このような独自の処理に対応するツールが必要となっている．

以上の背景から，私は企業と協力し，これまでに特許公報利用支援の一環として，特許が解決を試みる課題とそれに対する手段を推定する手法 [樽松 16] [樽松 17]に取り組んでいる．先行手法は，専門家が課題・手段を付与した特許公報から得た語句の出現頻度の類似度に基づき，ナイーブベイズや ANN を用いて分類することを試みてきた．一定の効果は得られたものの，精度は不十分である．その理由として，語句の出現頻度と分類との関係が十分反映されていないことが考えられる．

本稿では上記の問題点を解決するために，専門家が課題・手段を分類した特許の要約から抽出した語句と課題・手段との関係を，ラフセット理論[Zdzislaw 82]によりモデル化し，それを用いて推定する手法を提案する．また，従来手法との比較を行い，その有用性を評価する．

2. 提案手法

2.1 システム概要

本システムは図1に示すように，大きく「DTM 構築部」「決定ルール抽出部」「分類推定部」からなる．「DTM 構築部」では，専門家によって課題と手段ごとに分類された特許公報から，それらの分類を抽出するために有用と思われる語句を選択，それをもとに文書語句行列（以後，DTM）を構築する．「決定ルール抽出部」では，ラフセット理論に基づき，構築した DTM から決定ルールを抽出する．「分類推定部」では，決定ルールをもとに新たな特許の課題，手段の候補を推定する．以降で各部分の説明を加える．

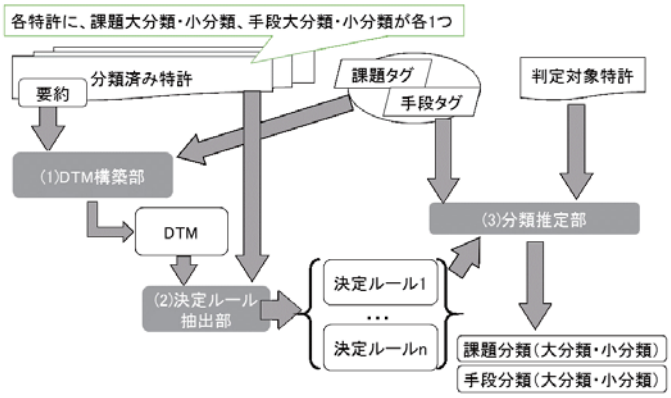


図1 システム概要

2.2 対象とする特許公報

本システムでは，専門家によって一定の範囲（対象）に絞り込まれた特許公報を対象とする．これらの特許公報に対し，専門家は，特許が解決しようとする課題と課題を解決するための手段について，それぞれ課題の分類を示す課題分類ラベル，手段の分類を示す手段分類ラベルを付与する．課題分類ラベルと手段分類ラベルは，大分類1つと小分類1つから構成されている．これらは特許公報に付与されている分類とは異なるものである．

2.3 DTM 構築部

専門家に分類付けされた特許公報から，以下の方法で分類出現語句情報を抽出する．

(1) 対象とする文章の抽出…特許公報に含まれる要約文を取り出す．要約文は，【課題】文 *1*, ･･･, 文 *n*【解決手段】文 *n+1*, ･･･, 文 *m* または【目的】文 *1*, ･･･, 文 *n*【構成】文 *n+1*, ･･･, 文 *m* ような構造をとる．このうち，文 *1*, ･･･, 文 *n* を課題について述べている課題文，文 *n+1*, ･･･, 文 *m* を手段について述べている手段文として抽出する．

連絡先：020-0693 岩手県滝沢市巣子 152-52 岩手県立大学ソフトウェア情報学部，電話 019-694-2582，FAX：019-694-2501，eMail：kure@iwate-pu.ac.jp

(2) 語句の抽出…課題文, 手段文それぞれから, (a)形態素列, (b)カタカナ列, (c)英字列いずれかの方法で語句を抽出する. 形態素列としては, 名詞に着目する. 名詞の後に名詞, 語尾, 形容動詞語幹が連続する場合はそれらをまとめて形態素列として抽出する. カタカナ列, 英字列はそれぞれ連続する 2 文字以上の並びとする.

(3) 語句の抽出…(2)で抽出した語句から以下の条件を満たす語句を抽出する.

条件 特定の分類の特許に対する DF 値が閾値 θ 以上.

本システムの目的が分類推定であるため, 特定の分類に出現が偏っている語句を抽出することで, 分類の絞り込みを図れると考え, 本条件を利用する. TF 値については, 対象とする文書が短いことを考慮し, 今回は利用しない.

(4) DTM の構築…(3)で抽出した語句を元に DTM を構築する. DTM の各要素は出現の有無を示す 2 値からなる.

2.4 決定ルール抽出部

前述までの処理で構築した DTM に対し, 次に示すラフセット理論の考えに基づき, 決定ルールを抽出する.

(1) 決定表の作成・・・DTM を条件属性集合, 分類を決定属性集合とし, 決定表を作成する. ここで決定属性とは回帰分析における目標変数, 条件属性とは説明変数にそれぞれ相当する. また決定表の各行が, 各特許に対応する.

(2) 決定ルールの作成・・・決定属性の 1 つである分類 c の決定ルールを次の方法で構築する.

(2a) 下近似集合の抽出・・・決定表より, 決定属性が分類 c のうち, 条件属性の値が, 他分類の特許の条件属性の値と一つでも異なる異なる特許のみを抽出する. これを下近似集合と呼ぶ.

(2b) 決定行列の作成・・・抽出した分類 c の下近似集合に含まれる特許 i を行, 分類 c 以外の特許 j を列とし, その交点に特許 i の決定属性の値のうち, 特許 j と異なる部分を記載した決定行列を作成する.

(2c) 決定ルールの作成・・・決定行列の各行に対し, 決定行列の交点の論理積からなるルールを作成する. このとき, 交点内の要素については, 論理和と見なす. 生成された各ルールの論理和をもとめ, 各要素の包含関係から, 要素をまとめていく. 最終的に残った要素を条件部, 決定属性を結論部とする決定ルールを抽出する. また, 抽出したルールを満たす特許を求め, その中で分類 c に属する特許の割合を, 同ルールの重さとする.

(3) すべての分類に対し, 決定ルールを取り出した場合は終了する. また構築していない分類がれば, (2)を繰り返す.

以上の過程で求めた決定ルールを用い, 分類を推定する.

2.5 分類推定部

分類推定部では, 推定対象の特許の要約文から, DTM 構築部と同様に, 課題文, 手段文を抽出する. 各文に対し, DTM 中の語句の出現の有無を確認する. 得られた結果に対し, 決定ルールを次のように適用し, 分類を推定する.

(1) 前件部をすべて満たす決定ルールを求める. 該当するルールがある場合, そのルールの重さの和を分類の評価値とし, 評価値の降順で並べたリストを推定結果とする.

(2) 前件部が一致するルールが無い場合は, 各分類の評価値として, 決定ルールの成立した条件部の割合と重さの積和を求める. 得た評価値の降順で並べたリストを推定結果とする.

3. 評価実験

3.1 実験概要

提案手法の有用性を評価するために, 3 章で示した考えをもとに JAVA 言語を用いて実装したシステムを用いて, 実験をおこなっている.

実験においては, 専門家から提供をうけた分類済み特許公報を, 1998 年以前の特許 297 件(Data-1), 1998 年から 2008 年まで特許 283 件(Data-2), 2009 年から 2010 年の特許 59 件(Data-3)に分割し, Data-1 から抽出した決定ルールを用いて Data-2 の分類を, Data-2 から抽出した決定ルールを用いて Data-3 の分類をそれぞれ推定する. それぞれ, 事前に付けられた分類を正解とし, 抽出したリストにおける順位との比較により評価する. 現時点では評価中であり, 発表時に結果を示す.

3.2 考察

評価実験は実施中であるが, 予備実験においては, 今回の提案手法では, 従来手法より良い正答率を挙げている. その理由としては, 従来手法では扱えていなかった「語 x を含まない」という否定が決定ルールに反映できていることが挙げられる. また, 従来手法に比べ, 決定ルールは可読性が高いことから, 専門家による検証も進めやすいものと考えられる.

4. おわりに

本稿では, 特許公報処理支援を行うために, 特許公報で述べられている, 解決しようとする課題とその手段の候補を, ラフセット理論を用いて推定する手法を提案した. 本手法では, 専門家により事前に分類された特許公報の要約文における語句の出現情報をもとにラフセット理論で抽出した決定ルールを用いて未分類特許公報の分類を推定する. 現在, 専門家の協力のもと評価実験を行っており, その結果に基づく評価, 抽出されたルールの検証, 評価結果の分析に基づく推定方法の改善などが今後の課題である.

謝辞

評価実験にご協力いただいた A 氏に感謝の意を表します. また本研究の一部は, 科研費・基盤 C(課題番号 15K00154)の助成を受けております.

参考文献

[藤井 12] 藤井敦, 谷川英和, 岩山真, 難波英嗣, 山本幹夫, 内山将夫:特許情報処理:言語処理的アプローチ, コロナ社(2012)

[発明協会 05]社団法人発明協会:産業財産権標準テキスト 特別編, 東京書籍(2005)

[樽松 16] 樽松理樹:語句出現頻度を利用した公開特許からの課題・手段推定システムの検討, 人工知能学会全国大会第 29 回(2016)

[樽松 17] 樽松理樹:単語出現頻度と機械学習手法を利用した公開特許の課題・手段分類システムの検討, 人工知能学会全国大会第 30 回(2017)

[Zdzislaw 82] Pawlak, Zdzisław :Rough sets, International Journal of Parallel Programming, Vol. 11, No. 5, pp.341–356, Springer, Heidelberg (1982)

[1J3] [General Session] 9. NLP / IR

座長:平岡 拓也（NEC）

Tue. Jun 5, 2018 5:20 PM - 7:00 PM Room J (2F Royal Garden B)

[1J3-01] A Study of Frame Importance Detection by Link Relationship among Frames on Comics

○TAKASHI HIRAOKA[1], RYOSUKE YAMANISHI[2], YOKO NISHIHARA[2] （1. Graduate School, Ritsumeikan University, 2. Ritsumeikan University）

5:20 PM - 5:40 PM

[1J3-02] Classifying Personality of Comic Character Based on Egogram

○Byeongseon Park[1], Kanae Ibayashi[1], Mitsunori Matsushita[1] （1. Kansai University）

5:40 PM - 6:00 PM

[1J3-03] A Novel Story Analysis Method based on the Distributed Representation of Sentences

○Kiyohito Fukuda[1], Naoki Mori[1], Keinosuke Matsumoto[1] （1. Osaka Prefecture University）

6:00 PM - 6:20 PM

[1J3-04] Preliminary Analysis of Weibo Emojis for Sentiment Analysis of Chinese Social Media

○Da Li[1], Rafal Rzepka[1], Kenji Araki[1] （1. Hokkaido University）

6:20 PM - 6:40 PM

[1J3-05] Filtering out improper accounts from Twitter user accounts for discovering individuals interested in certain topic

○Chao Cai[1], Shun Shiramatsu[1] （1. Department of Computer Science, Graduate School of Engineering, Nagoya Institute of Technology）

6:40 PM - 7:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

コミックのコマ間のリンク関係による コマの重要度推定についての一検証

A Study of Frame Importance Detection by Link Relationship among Frames on Comics

平岡誉史 *1 Takashi Hiraoka　山西良典 *2 Ryosuke Yamanishi　西原陽子 *2 Yoko Nishihara

*1立命館大学大学院情報理工学研究科
Graduate School of Information Science and Engineering, Ritsumeikan University

*2立命館大学情報理工学部
College of Information Science and Engineering, Ritsumeikan University

This paper proposes a method to detect important frame on comics using link relation among frames; the idea of page-rank is introduced. The proposed method links frames based on visual and text information of the characters. The importance of the frames is estimated by using the number of links. Through the result of tests, we discussed the potential of the proposed method for detecting important frames from comics.

1. はじめに

スマートフォンやタブレットと言った携帯端末が普及したことで、電子コミックも広がりを見せている．電子コミックは購入した様々な作品を個人の端末等にダウンロードすることで携帯可能であり，外出先や移動の合間など場所や場面を選ばないコミック閲読ができるようになった．このような電子コミックの特性はコミック閲読の機会を増やすと同時に，電子コミック独自の利点についてのニーズも高まりを見せている．

コミックの多くは，一話や一冊で話が完結することはなく，数話・数冊に分かれて話が進行していくため，読者は前回までの内容を思い出しながら読み進めていく必要がある．紙媒体の場合，背表紙や表紙近くに前回までのあらすじが記載されているものもあるが，あらすじのみでは内容を十分に思い出すことは難しく，読み返しが発生している．また，閲読するコミックを選定する過程では，「試し読み」によって内容の把握を行うことが多い．しかし，ストーリーの前半部分のみの試し読みでは内容の把握には不十分であったり，試し読みによるネタバレで閲読の楽しみが奪われてしまうといった危険性も存在する．これらの問題を解決する 1 つの方法として，重要コマの抽出が考えられる．重要コマの抽出は，コミックの要約の一種として捉えることができ，読み返しや試し読みに代わった読書体験支援に繋がると考える．

コミックは各コマに描かれている画像情報と台詞などの言語情報を組み合わせたマルチメディア情報と捉えることができるため，重要コマの抽出では画像情報と言語情報の両面からのアプローチが考えられる．画像情報に対する重要度推定は，動画要約に関する場面で様々な研究が行われており，料理映像中の重要なシーンを自動で抽出する研究 [三浦 02] や深層学習によってハイライト映像を検出する研究 [Yao 16] などがある．また，言語情報については文章要約の研究が古くから行われており，単語の重要度を用いた手法 [Zechner 96] やタイトルと文との類似度を用いた手法 [Yoshimi 98] など，様々な重要度推定の手法が提案されている．コミックの重要コマ選出に関する研究は，藤岡ら [藤岡 15] のコマの位置や大きさ，キャラクターや台詞の出現回数などの情報を用いた研究が挙げられる．

連絡先: 平岡誉史，立命館大学大学院情報理工学研究科，滋賀県草津市野路東 1-1-1，is0230ff@ed.ritsumei.ac.jp

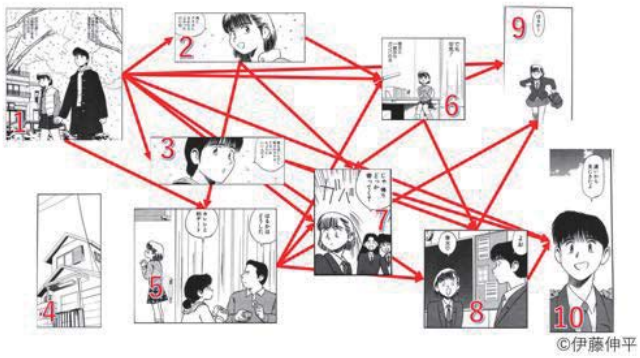


図 1: コマ間のリンク関係のイメージ．

また，久行ら [久行 16] はキャラクターやセリフ，コマの形状などのコマの持つ属性からシーンの転換箇所となるコマを判定している．コミックの重要コマ推定には，画像情報と言語情報を互いに考慮した重要度推定の手法が必要になると考えられる．本稿では，コミック中のコマの重要度推定において，コマ中の画像情報と言語情報を用いたコマ間のリンク構造を用いる有効性について検討する．

2. 提案手法

コミックは物語であるため，コマ同士は何らかの関連性を有していると考えられる．提案手法では，重要コマの推定において，コマ同士の関連性を利用することを考え，図 1 のようにキャラクターの画像情報や台詞情報を用いてコマ間にリンク関係を構築し，そのリンク関係から重要コマの推定を行う．これは，WEB ページの重要度を示す指標である PageRank [Page 99] や文の重要度を示す TextRank [Mihalcea 04] のアイデアの応用となる．

三原ら [三原 11] は，コミックのストーリー構造とビジュアル要素についての記述モデルを提案しており，コマ中の情報を「VisualObject」,「Dialog」,「Symbol」の 3 つの要素に分けている．図 2 に示すように,「VisualObject」はキャラクターの画像情報,「Dialog」は吹き出しを用いて書かれる台詞のテキ

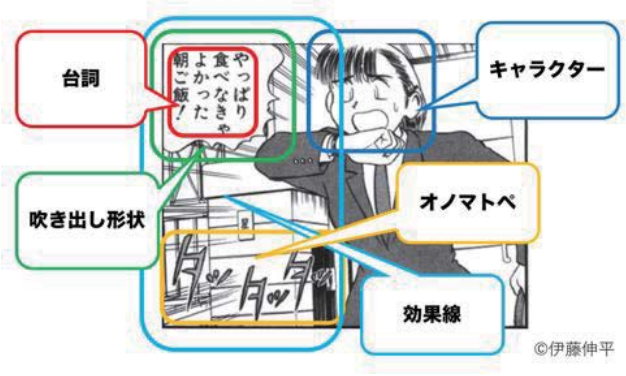


図 2: コマ中のメタデータ.

スト情報,「Symbol」はオノマトペや効果線が該当する．他にも，吹き出しの形状などの情報もコマ中に含まれる情報の一つであると考えられる．

以下で，これらのメタデータを用いてコマ間にリンク構造を構築する手法の詳細を述べる．なお，本稿で用いたコミックのメタデータは著者のうち 1 名が人手で付与した．

2.1 コマ間のリンク関係の構築

コマ間のリンク関係構築には，キャラクターに関する画像情報と台詞情報の 2 つの情報を用いる．

キャラクターに関する画像情報によるリンク：コマ中に出現する様々なキャラクターの中でも，同一のキャラクターが出現するコマ同士は，何らかの関連性があると考えられる．提案手法では，キャラクターの画像情報をリンク関係構築に用いる．キャラクターの画像情報は，コマ中にキャラクターの顔が描かれているかによって判断し，横顔や後頭部が描かれている場合もキャラクターの画像情報として判断した．コマ同士を比較し双方のコマに同一のキャラクターが出現している場合にコマ間をリンクする．

キャラクターに関する台詞情報によるリンク：台詞は，キャラクターの会話や心情，状況の説明など様々な役割がある．提案手法では，台詞情報のうち特にキャラクターの名前をリンク関係構築に用いる．キャラクターの名前が出現する台詞は，そのキャラクターまたは作品の内容に関連性があると考えられる．台詞情報としては，吹き出しを用いて書かれているテキスト情報を対象としキャラクターの名前を抽出した．キャラクターの名前が姓名あるものについては，姓と名それぞれを独立に扱った．コマ同士を比較し双方のコマ中の台詞中に同一のキャラクター名が出現する場合にコマ間をリンクする．

2.2 リンク数からの重要度の算出

コミックは最初のコマから徐々に物語が進行していくものであるため，リンク関係からのコマの重要度推定には時系列情報を考慮する．リンク関係構築では 3 種類の時系列モデルを用意した．

1 つ目は，コマの出現する順番が小さいものから大きいものへリンクをつなげたもの（以下 PtoF 型）である．PtoF 型は，物語の進行に沿ったリンク関係であると言える．PtoF 型は，出現順序に従って有向リンクが構築され，コマ k の重要度 $pfFI(k)$ が式 (1) に従って算出される．

$$pfFI(k) = \sum_{i \in \boldsymbol{K}} R(i), \tag{1}$$

表 1: 分析に使用したコミック作品の書籍情報

No.	作品名	作者	ジャンル	話数	コマ数
1	はるかリフレイン	伊藤伸平	少女・SF	1 話	73
				2 話	66
				3 話	68
2	ベルモンド Le VisiteuR ～地下に潜む男～	石岡ショウエイ	少年・ファンタジー	1 話	264
				2 話	136
				3 話	119
3	ラブひな	赤松健	少年・ラブコメ	1 話	425
				2 話	159
				3 話	134

表 2: キャラクターの画像情報を用いたリンク関係による重要度推定の結果（作品 No.1）

PtoF 型		FtoP 型		HV 型	
コマ番号	リンク数	コマ番号	リンク数	コマ番号	リンク数
60	74	2	77	45	84
66	71	7	73	60	81
58	68	5	73	58	81
56	62	6	71	56	81
47	58	8	67	54	81

ここで，$R(i)$ はコマ i のコマ k へのリンク数，$\boldsymbol{K}$ は，1 話を構成するコマの中でコマ k が出現するまでに出現したコマの集合をそれぞれ示す．

2 つ目は，出現する順番が大きいものから小さいものへリンクをつなげたもの（以下 FtoP 型）である．FtoP 型は，物語の結論から過去に向けてのリンク関係であると言える．FtoP 型は，出現順序に遡って有向リンクが構築され，コマ k の重要度 $fpFI(k)$ は式 (1) と同様に算出される．ただし，FtoP 型と FtoP 型では，リンク数計算を行うリンク・被リンク関係が異なっている．

3 つ目は，PtoF 型と FtoP 型の両方を組み合わせたもの（以下 HV 型）である．HV 型は，双方向リンクによってリンク関係が構築され，単純にリンク数が多いコマの重要度が高く推定される．HV 型のコマの重要度は式 (2) を用いて算出される．

$$hvFI(k) = pfFI(k) + fpFI(k). \tag{2}$$

3. コマの重要度推定実験

提案手法の適用によって，どのようなコマが高い重要度を持つと推定されるのか検証した．なお，本稿の実験では，各コマ間のリンク関係構築は全て人手によって行った．キャラクターに関する画像情報を用いたリンク構造とキャラクターに関する台詞情報を用いたリンク構造，2 つの情報を組み合わせたリンク構造それぞれを用いてコマの重要度推定を行った．実験対象は，表 1 に示した Manga109[Matsui 17] の 3 作品とし，各第 1 話から第 3 話までの計 9 話分に対して実験を行った．

3.1 実験結果

表 2～表 10 に，それぞれ作品 No.1，作品 No.2，作品 No.3 の第 1 話に対する提案手法によるコマの重要度推定の結果上位 5 コマを示す．このうち，表 2～4 は画像情報によるリンク構造，表 5～7 は台詞情報によるリンク構造，表 8～10 は画像情報および台詞情報によるリンク構造それぞれを用いた結果を示す．画像情報および台詞情報によるリンク構造を用いた場合，画像情報と台詞情報それぞれでのリンク数に大きな偏りが見られるため，式 (3) に従って正規化された重要度 $stFI(k)$ を算出した．

表 3: キャラクターの画像情報を用いたリンク関係による重要度推定の結果（作品 No.2）

PtoF 型		FtoP 型		HV 型	
コマ番号	リンク数	コマ番号	リンク数	コマ番号	リンク数
263	240	85	212	113	302
230	202	42	206	85	302
244	163	65	179	230	245
250	162	113	171	263	241
195	161	59	171	65	241

表 4: キャラクターの画像情報を用いたリンク関係による重要度推定の結果（作品 No.3）

PtoF 型		FtoP 型		HV 型	
コマ番号	リンク数	コマ番号	リンク数	コマ番号	リンク数
385	573	7	633	100	653
372	519	77	542	148	652
376	483	100	513	77	638
422	443	124	462	7	638
419	438	126	455	385	637

表 5: キャラクターの台詞情報を用いたリンク関係による重要度推定の結果（作品 No.1）

PtoF 型		FtoP 型		HV 型	
コマ番号	リンク数	コマ番号	リンク数	コマ番号	リンク数
70	9	2	10	2	10
68	8	10	8	70	9
66	7	21	7	68	9
63	6	31	6	66	9
51	5	44	5	63	9

表 6: キャラクターの台詞情報を用いたリンク関係による重要度推定の結果（作品 No.2）

PtoF 型		FtoP 型		HV 型	
コマ番号	リンク数	コマ番号	リンク数	コマ番号	リンク数
263	19	23	27	23	30
264	16	4	16	64	20
250	15	64	15	263	19
247	14	31	14	264	16
249	13	18	14	250	16

$$stFI(k) = \frac{R_{image}(k)}{\sum_{k \in \boldsymbol{N}} R_{image}(k)} + \frac{R_{serif}(k)}{\sum_{k \in \boldsymbol{N}} R_{serif}(k)}, \quad (3)$$

ここで，R_{image} と R_{serif} はそれぞれ画像情報と台詞情報によるリンク数を示し，N は 1 話を構成するコマ集合を示す．

図 3，図 4，図 5 は，各作品に対して重要度推定を行った結果，表 2〜表 10 で最も重要度が高く推定されたコマ画像である．

3.2 考察

まず，リンク構築に用いた情報に着目する．どの作品においても画像情報を用いた場合に比べて台詞情報を用いた場合は，繋がるリンク数に大きな偏りがある．これは，コミックの台詞中ではキャラクター名が直接明記されることが少なく，「私」や「おまえ」，「あいつ」といった代名詞を用いてキャラクターを表す場合が多いためであると考えられる．台詞情報をリンク関係構築に用いる場合は，キャラクター名だけでなく代名詞も考慮する必要性が示唆される．リンク構築に用いた情報によって，同じ時系列モデルによるリンク構造であっても重要度が高く推定されるコマは異なる．画像に着目した要約，台詞に着目した要約など，リンク関係構築に用いる情報を変えることで様々な意図に沿ったコミック要約が実現できる可能性が考えられる．

続いて時系列モデルに着目する．表 2〜4 に示すように，PtoF 型では物語終盤のコマ，FtoP 型では物語序盤のコマについてそれぞれ高い重要度が推定される．HV 型では，表 2 のコマ番号 45 や表 4 のコマ番号 148 のように，PtoF 型や FtoP 型では重要度が高く推定されなかったコマが上位に位置している．このことから，HV 型では物語中盤のコマも内容に応じて重要度が高く推定されることが示唆された．PtoF 型は物語の結論となるコマの推定に，FtoP 型は物語の起点となるコマの推定にそれぞれ適しており，HV 型は物語の起点と結論をつなぐコマの推定に利用可能であり，これら 3 種類の時系列モデルを併用することでストーリーの起承転結に相当するコマの抽出の実現可能性が示唆された．

最後に，画像情報および台詞情報を用いたリンク構造に着目する．画像情報と台詞情報といった複数の情報を組み合わせることで，時系列モデルの違いによらず，各情報を単独を用いた場合では高い重要度が推定されなかったコマ（例えば，表 8 のコマ番号 65 や表 9 のコマ番号 50，表 10 のコマ番号 145 など）が上位に現れている．全体的にどの作品でも，台詞情報を用いたリンク構造が重要度推定に大きな影響を与えていると考えられる．これは，画像情報によるリンク関係の総リンク数と台詞情報によるリンク関係の総リンク数の差異が影響しているためであると考えられる．本稿では，式 (3) を用いた正規化を試みたが，両情報をよりバランス良く扱うための工夫を考案する必要があると考える．

4. まとめ

本稿では，コミックのコマの重要度を推定する手法を提案し，その有用性について検討した．提案手法では，画像情報や台詞情報などのコマ中に含まれるメタデータをもとに構築したコマ同士のリンク関係を用いてコマの重要度を推定する．実験の結果，リンク構築に用いる情報によって重要度が高く推定される要因が異なるため，リンク関係構築に用いる情報を変えることで様々な意図に沿ったコミック要約が実現できる可能性が示唆された．リンク構築に参照する時系列モデルに関しては，用いる時系列モデルによって物語の起点となるコマや結論となるコマが推定できる可能性が示唆された．今後は，提案手法によって重要度が高く推定されたコマが，読者がコミックを読む際に重要視しているコマと一致するのかを検証する．

謝辞

本稿では，実験のデータセットとして，またコミックのコマ画像の例示のために，Manga109 の [Matsui 17] を利用させていただいた．

参考文献

[Matsui 17] Matsui, Y., Ito, K., Aramaki, Y., Fujimoto, A., Ogawa, T., Yamasaki, T., and Aizawa, K.: Sketch-based manga retrieval using manga109 dataset, *Multimedia Tools and Applications (MTAP), Springer (in press)* (2017)

[Mihalcea 04] Mihalcea, R. and Tarau, P.: TextRank: Bringing Order into Texts, in *Proc. of EMNLP 2004*, pp. 404–411 (2004)

[Page 99] Page, L., Brin, S., Motwani, R., and Winograd, T.: The PageRank Citation Ranking: Bringing

表 7: キャラクターの台詞情報を用いたリンク関係による重要度推定の結果（作品 No.3）

PtoF 型		FtoP 型		HV 型	
コマ番号	リンク数	コマ番号	リンク数	コマ番号	リンク数
236	12	7	14	236	14
416	8	160	9	160	14
417	7	16	7	7	14
171	6	143	7	416	8
237	6	93	6	171	8

表 8: キャラクターの画像情報と台詞情報の両方を用いたリンク関係による重要度推定の結果（作品 No.1）

PtoF 型		FtoP 型		HV 型	
コマ番号	重要度	コマ番号	重要度	コマ番号	重要度
70	0.168	2	0.197	2	0.099
68	0.151	10	0.158	44	0.092
66	0.147	7	0.116	10	0.091
63	0.119	21	0.109	66	0.091
65	0.104	31	0.108	31	0.084

Order to the Web., Technical Report 1999-66, Stanford InfoLab (1999)

[Yao 16] Yao, T., Mei, T., and Rui, Y.: Highlight Detection With Pairwise Deep Ranking for First-Person Video Summarization, in *Proc. of CVPR 2016*, pp. 982–990 (2016)

[Yoshimi 98] Yoshimi, T., Okunishi, T., Yamaji, T., and Fukumochi, Y.: Evaluation of Importance of Sentences based on Connectivity to Title., *In COLING-ACL'98*, pp. 1443–1447 (1998)

[Zechner 96] Zechner, K.: Fast Generation of Abstracts from General Domain Text Corpora by Extracting Relevant sentences, *In COLING-ACL'96*, Vol. 2, pp. 986–989 (1996)

[久行 16] 久行 智恵, 三原 鉄也, 永森 光晴, 杉本 重雄: コマの持つ属性を用いたマンガシーン自動抽出, 2016 年度人工知能学会全国大会（第 30 回）, pp. 2J4–OS–08a–3 (2016)

[三浦 02] 三浦 宏一, 浜田 玲子, 井手 一郎, 坂井 修一, 田中 英彦: 動きに基づく料理映像の自動要約手法, *MIRU2002*, Vol. 2, pp. 203–208 (2002)

[三原 11] 三原 鉄也, 永守 光晴, 杉本 重雄: ディジタルマンガにおけるストーリー構造とビジュアル構造を表すメタデータモデル, IPSJ SIG Technical Report 9, 情報処理学会研究報告 (2011)

[藤岡 15] 藤岡 恭平, 渡辺 裕: マンガ要約手法に関する一考察, 電子情報通信学会基礎・境界ソサイエティ/NOLTA ソサイエティ大会, p. 151 (2015)

表 9: キャラクターの画像情報と台詞情報の両方を用いたリンク関係による重要度推定の結果（作品 No.2）

PtoF 型		FtoP 型		HV 型	
コマ番号	重要度	コマ番号	重要度	コマ番号	重要度
263	0.086	23	0.106	23	0.058
250	0.066	4	0.063	263	0.043
264	0.061	18	0.061	64	0.038
247	0.060	64	0.056	250	0.035
249	0.057	31	0.056	50	0.034

表 10: キャラクターの画像情報と台詞情報の両方を用いたリンク関係による重要度推定の結果（作品 No.3）

PtoF 型		FtoP 型		HV 型	
コマ番号	重要度	コマ番号	重要度	コマ番号	重要度
236	0.117	7	0.143	7	0.071
416	0.082	160	0.088	236	0.070
417	0.066	16	0.070	160	0.069
237	0.062	143	0.066	416	0.041
361	0.059	145	0.059	171	0.041

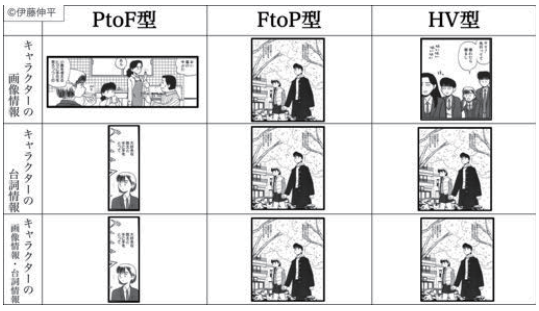


図 3: 重要度推定の結果において最も重要度が高く推定されたコマ画像（作品 No.1）

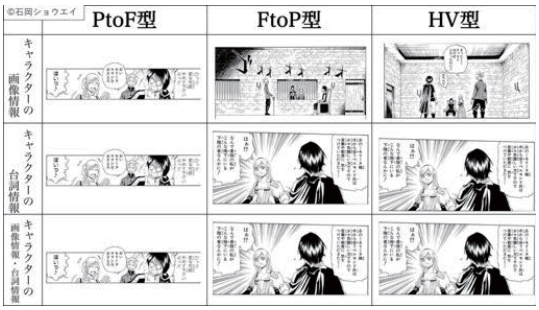


図 4: 重要度推定の結果において最も重要度が高く推定されたコマ画像（作品 No.2）

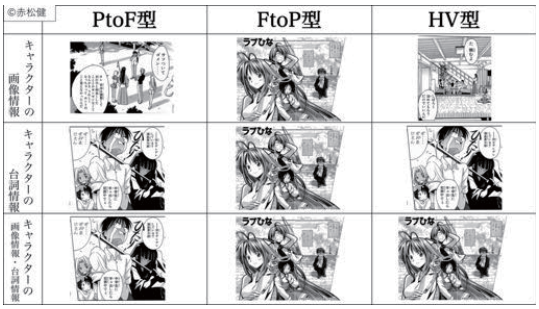


図 5: 重要度推定の結果において最も重要度が高く推定されたコマ画像（作品 No.3）

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

エゴグラムに基づいたコミックキャラクタの性格分類

Classifying Personality of Comic Character Based on Egogram

朴 柄宣 *2 Byeongseon Park　居林 香奈枝 *1 Kanae Ibayashi　松下 光範 *1 Mitsunori Matsushita

*2関西大学大学院 総合情報学研究科 Graduate School of Informatics, Kansai University

*1関西大学 総合情報学部 Faculty of Informatics, Kansai University

The aim of this research is to develop a comic search system based on the characteristics of characters appearing in comics. For that purpose, this paper examines classification of characters using the egogram, which is used to classify personality. In the proposed method,texts that express the comic character's characteristics are acquired from Web resources and semantic vectors are allocated based on the texts using the egogram. The resulting egogram pattern is used to estimate the typical properties. Our experiment revealed that the performance of classification was 55.0 %.

1. はじめに

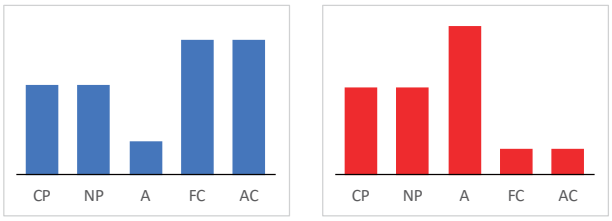
出版月報 2018 年 2 月号（公益財団法人全国出版協会・出版科学研究所発行）によれば，2017 年度に出版された新刊コミックの点数は 12,461 点であった．こうした莫大な量のコミックの中からユーザの興味に沿った内容の作品を探し出すには，各コミックの内容を把握し，ユーザの興味に応じてそれらを取捨選択し提示する情報アクセス支援システムの実現が求められる．

本研究では，こうした支援システムのひとつとして，登場キャラクタの性格タイプを考慮した検索システムの実現を目指している．ユーザは，好みの要素を多く含んだキャラクタに深く共感したり，感情移入したりする傾向がある．そのため，似たようなキャラクタが出現する作品は，そのユーザの嗜好に合致する可能性が高い．また，登場キャラクタはコミックのストーリーを構成する上で重要な役割を持っており，同じような状況であっても，キャラクタの性格によってその後のストーリー展開は大きく変化する．こうしたことから，本研究では「登場キャラクタの性格がコミックを選択する際のひとつの基準になる」と考え，キャラクタの性格の類似性に着目したコミック検索の実現を目指す．その端緒として，本稿では性格診断ツールとして広く利用されているエゴグラムを利用し，コミックキャラクタの性格分類を試みる．

2. エゴグラムによる性格の診断

エゴグラム [1] は交流分析理論に基づく性格診断法であり，質問紙法により性格の類型を判別する．この手法は客観性や信頼性，妥当性が高いとされており，教育現場や医療現場など様々な場で活用されている [5].

現在，日本で多く使用されているエゴグラムは東大式エゴグラム第 2 版（以下，新版 TEGII と記す）[4] である．新版 TEGII では人の性格を，義務感，責任感，信念，理想の追求などの側面に関わる心性である Critical Parent (CP)，受容，思いやり，自他の心身の育成などの側面に関わる心性である Nurturing Parent (NP)，論理性，合理性，客観性，計画性などの側面に関わる心性である Adult (A)，自主性，活動性，積極性，創造性などの側面に関わる心性である Free Child (FC)，協調性，社会性，妥協，依存などの側面に関わる心性である Adapted Child (AC) の 5 つの自我状態の領域に分けて測定する．TEGII では，これら 5 つの領域にどの程度該当しているかによって，性格を 29 タイプに分類する．例えば，図 1 の左図は FC と AC が同程度に高くなっている点に着目して「C 優位型」に分類される．これは，成人しても子どものままの自我状態であり気分中心に振る舞う性格であることを示している．また，図 1 の右図は A のみが突出している点に着目して「A 優位型」に分類される．これは，論理的かつ知的で計画的な行動が多い性格であることを示している．



C 優位型　　A 優位型

図 1: エゴグラムパタンの例

本研究では新版 TEGII に従ってコミックの登場キャラクタの性格分類を行う手法を提案する．

3. コミックキャラクタの性格分類

3.1 提案手法の概要

提案手法ではまず，Web 上から収集可能な文書データの中からキャラクタの性格を端的に表現した文章を抽出し，その記述からキャラクタの性格分類を行うための性格語辞書を作成する．性格語とは，性格を端的に表現した単語（e.g., 明るい，冷静，優しい）および短文（e.g., 世話好き，情が深い）を意味する造語である．

あるキャラクタの性格タイプを判断するには，Web 上のリソースからそのキャラクタの性格に関して言及している文書を収集し，その文書集合中の性格を表す単語から，作成した辞書を参照してベクトル（性格ベクトル）を作成する．この性格ベ

連絡先: 松下 光範　関西大学総合情報学部 〒 569–1095 大阪府高槻市霊仙寺町 2–1–1 Tel: (072) 690–2437 Fax: (072) 690–2491 e-mail: mat@res.kutc.kansai-u.ac.jp

表 1: 獲得された表現の例

ゴン・フリークス	うずまきナルト	孫悟空
明るい	諦めない	明るい
好奇心旺盛	正義感	裏表がない
裏表がない	負けず嫌い	お人好し
素直	優しい	自信過剰
冷静	我が儘	素直
負けず嫌い	無鉄砲	優しい
優しい	まっすぐ	冷静

表 2: 性格的特徴の例 [2]

自我状態	値が高い場合	値が低い場合
CP	義理堅い	おっとり
	責任感がある	友好的
	頑固	ルーズ
NP	世話好き	サッパリしている
	親切	マイペース
	おせっかい	淡白
A	理性的	純朴
	冷静	お人好し
	冷たい	現実離れ
FC	好奇心	物静か
	自由奔放	おとなしい
	明るい	控えめ
AC	協調性	活発
	素直	積極的
	従順	マイペース

クトルと事前に登録してあるエゴグラム基本パタンとの類似度を算出して．形状が近いものをそのキャラクタの性格タイプとする．以下にその詳細について述べる．

3.2 性格語辞書の作成

まず，Wikipedia[*1]，ニコニコ大百科 [*2]，pixiv 百科事典 [*3]，アニヲタ wiki（仮）[*4] からキャラクタの性格を表現する記述を収集し，キャラクタの性格分類の礎となる辞書を作成した．

辞書作成のための基本語彙は，2017 年 6 月の時点で漫画全巻ドットコムに記載されていた漫画歴代発行部数ランキング上位 19 作品に出現する主要 100 キャラクタで用いられている性格に関する語を対象とした．上記の Web サイトから収集された文書集合の中から，性格を端的に表現した単語（e.g., 明るい，冷静，優しい）および短文（e.g., 世話好き，情が深い）をそのキャラクターの性格語として人手で抽出した．抽出された性格語の例を表 1 に示す．

このようにして収集・抽出された性格語集合をもとに性格語辞書を作成した．新版 TEGII に記載されたエゴグラムの 5 つの領域は各々が異なる性格を表しており，その高低から読み取れる性格的特徴がある．例えば，CP の値が高い場合は “義理堅い” や “頑固” などの性格的特徴が，CP の値が低い場合は “おっとり” や “ルーズ” などの性格的特徴が各々読み取れる．表 2 にそれらの性格的特徴の例を示す．本稿では，このようにして作成したベクトルを性格ベクトルと呼ぶ．

*1 https://ja.wikipedia.org/wiki/
*2 http://dic.nicovideo.jp/
*3 https://dic.pixiv.net/
*4 https://www49.atwiki.jp/aniwotawiki/

表 3: 性格語辞書の例

	エゴグラムの領域				
単語	**CP**	**NP**	**A**	**FC**	**AC**
冷静	0	0	1	0	0
義理堅い	1	0	0	0	0
おっとり	−1	0	0	0	0
親切	0	1	0	0	0
お人好し	0	1	−1	0	0
マイペース	0	−1	0	0	−1
自由奔放	0	0	0	1	0
素直	0	0	0	0	1

これら 664 語の性格語に対し，新版 TEGII に記載された語彙を参考に，TEGII の各領域の性格的特徴と合致するかについて評定を行って TEGII の 5 つの領域 (CP，NP，A，FC，AC) を基底とするベクトルを付与する．このとき，各領域の値が高い場合の性格的特徴に該当する場合は “1” を，値が低い場合の性格的特徴に該当する場合は “−1” を，その領域の性格的特徴と全く合致しない場合は “0” を付与した．例えば，“頑固” という性格語は CP が高い場合に現れる特徴であるため，“頑固” の性格ベクトルは CP が 1 となるベクトル (1，0，0，0，0) となる．なお，新版 TEGII に表記されている性格的特徴はそれほど多くないため，weblio 辞書 [*5] に収録された類似語のうち，2 hop 以内の語に拡張して対応付けた．これらの処理により，辞書作成に用いた 664 語のうち 534 語にベクトルが付与できた．その一部を表 3 に示す．

3.3 キャラクタの性格タイプの推定手法

3.2 節で作成した性格語辞書を参照し，各キャラクタの性格判断を行う手法を提案する．提案手法では，任意のキャラクタについてそのキャラクタの性格に対する記述を Web から収集し，その中に含まれる性格語を抽出して性格語辞書に照らすことで，キャラクタのタイプ推定を行う．

まず，収集された文書集合から，あるキャラクタの性格について言及した文書に含まれる性格語を抽出する．次に，性格語辞書を参照し，性格ベクトルを生成する．性格ベクトルは，各性格語の性格ベクトルの線形和によって求めた．なお，キャラクタによって得られる性格語数が異なるため，キャラクタ間で同数となるように補正を行っている．

得られた各キャラクタの性格ベクトルの値と，エゴグラムの基本タイプの値に基づき，式 (1) により類似度 f を算出し，キャラクタの性格推定を行った．式 (1) では，各キャラクタが持つ性格ベクトル（x_1, x_2, x_3, x_4, x_5）と，エゴグラムの基本タイプ（y_1, y_2, y_3, y_4, y_5）との距離を測っており，算出された値が 0 に近いほど類似度が高いことを示している．

$$f = \sum_{i=1}^{5}(x_i - y_i)^2 \quad (1)$$

例えば,「ワンピース」（尾田栄一郎著，集英社）の主人公である「モンキー・D・ルフィ」については，表 4 に示す性格語が抽出された．これらの語をもとに性格ベクトルを算出すると (12, 4, 5, 17, 5) となる．(図 2 参照)．この性格ベクトルを式 (1) に適用すると，エゴグラム基本タイプとの一致度が高いタイプから順に，“逆 N 型 3”，“逆 N 型 2”，“FC 優位” となるため，このキャラクタの性格タイプは “逆 N 型 3” と判定

*5 https://www.weblio.jp/

表 4: 「モンキー・D・ルフィ」の性格語

責任感	王様	リーダーシップ
カリスマ	豪胆	包容力
器が大きい	人情	優しい
柔軟	理屈	自由奔放
行動力	自分本位	根明
凶暴	無鉄砲	荒い
無謀	能天気	楽観主義
単純	無邪気	真面目
純粋	厳しい	威厳
ストレート	気まぐれ	お調子者
諦めない	鈍感	騙されやすい
明るい	豪快	

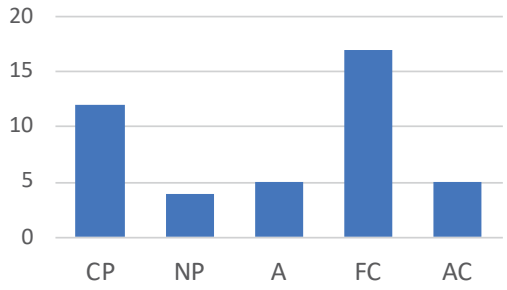


図 2: モンキー・D・ルフィのエゴグラム

される．“逆 N 型 3” は，自己中心的，自分勝手，気まま，感情にふりまわされがち，といった性格を示しており，当該キャラクタの性格として妥当なものだと言えよう．

4. 実験

4.1 実験手順

提案手法が提示したキャラクタの性格と，ユーザが認識するキャラクタの性格が一致するかを検証するためのユーザ実験を行った．

まず，質問紙法によりキャラクタのエゴグラムを作成してもらった．実験の対象データは，17 作品 20 キャラクタとし，1 キャラクタあたり実験協力者 3 名分のデータを収集することとした．

本実験には，20 代から 40 代の男女 15 名（男性 9 名，女性 6 名）が実験協力者として集められた．実験対象のキャラクタについて知らない場合は回答できないため，(1) 評定対象のキャラクタが登場するコミックを読んだことがあること，(2) 評定対象のキャラクタを認知していること，の 2 点を条件として，実験協力者に割り当てるキャラクタを決定した．この条件のもと，実験協力者 1 人につき 1 〜 18 キャラクタを割り当てた．割当数が異なるのは，読んだことがある作品数が実験協力者によって大きく異なったためである．

実験では，新版 TEGII に記載されている全 50 問のエゴグラムの質問（e.g., 他人の言うことに左右されやすい，ユーモアのセンスがある）について，割り当てたキャラクタが該当するかを回答してもらった．この際，新版 TEGII に倣い，当てはまる場合は 2 点，当てはまらない場合は 0 点，わからない場合は 1 点を記入してもらい，その合計値を算出した．

提案手法による上位 3 位までの判定結果と，実験協力者 3 名分の判定結果が示すタイプとを比較し，一致率を検証した．このとき，本手法が示す性格を表すタイプの上位 3 位までに，実験協力者 3 名分の判定結果が示すタイプが含まれていれば一致していると見なした．

4.2 結果

システムの出力結果がアンケートの上位 3 位までのタイプに一致したキャラクタは 55.0%（20 キャラクタ中 11 キャラクタ）であった．図 3 の上段に本手法で算出した各キャラクタの性格ベクトルを，図 3 の下段にシステムが示す判定結果を実験協力者 3 名分の判定結果を各々示す．また，エゴグラムのタイプを比較した結果の一部を表 5 に記す．今回の実験結果において，システムとユーザの一致度が最も高かったのは，「鋼の練金術師」（荒川弘著，スクウェア・エニックス）のキャラクタである「アルフォンス・エルリック」で類似度は 0.057 であり，最も低かったのは「金田一少年の事件簿」（さとうふみや著，講談社）のキャラクタである「金田一一」で類似度は 1.416 であった．

5. 考察

本手法での精度は，実験の結果 55.0% であった．29 の性格タイプのうち 3 つのタイプに該当する割合は，ランダムであれば 10.3% であるため，提案手法による性格タイプの推定は一定の効果を挙げていると考えられる．このことから，本稿で用いた分析手法であるエゴグラムは，人間の性格を分析することを前提に構築されているが，コミックのキャラクタにも応用可能であることが示唆された．

一方で，分類精度が 55.0% でとどまった原因として，以下のことが考えられる．

一つ目は，不要な語をそのキャラクタの性格語としてご抽出してしまっている点である．本手法では，性格語辞書に登録された語と一致する性格語を抽出する方法をとっている．この手法では，文脈による語の意味を考慮することはできない．例えば，「冷静ではなく，明るく元気な性格」という文からは，「明るい」，「元気」という単語のみが抽出されることが望ましいが，現状の手法では「冷静」も抽出されてしまう．また，「自他ともに厳しく」という文は “厳しい性格” であることを表しているが，「厳しい現実」は性格が厳しいということを表しているわけではない．これらの語を誤抽出してしまうことで，分類精度が低下している．

二つ目は，文体によって性格語が抽出できない点である．例えば，「仲間のことを誰よりも頼りにし大切に思っており、仲間からの信頼も厚い」「自分が大切に思うものを守ることに強いこだわりをもち、」といった文章からは，「優しい」，「仲間思い」，「情が深い」といった性格が推定できる．しかし，提案手法では単語や短文を表層的なマッチングにより抽出しているため，これらの文章からは性格語を抽出できず，意図された性格を推定することができない．

三つ目は，ストーリーの展開と共に，性格が変化する場合があることである．これは長期連載作品に多く見られる傾向であり，どの時期を切り取るかによって性格に違いが生じることがある．コミックではキャラクタに極端な性格付けがなされることもしばしばあり，「天真爛漫な性格と他人の過去を気にしない優しい心」という性格を持っていたキャラクタが，ある出来事により「憎しみに我を忘れ残酷な一面を持つようになる」と変化するような場合も存在する．エゴグラムではこうした物語的特徴による性格の変化を捉えることができない．

今後，これらの点について検討し，手法の精度改良を図る．

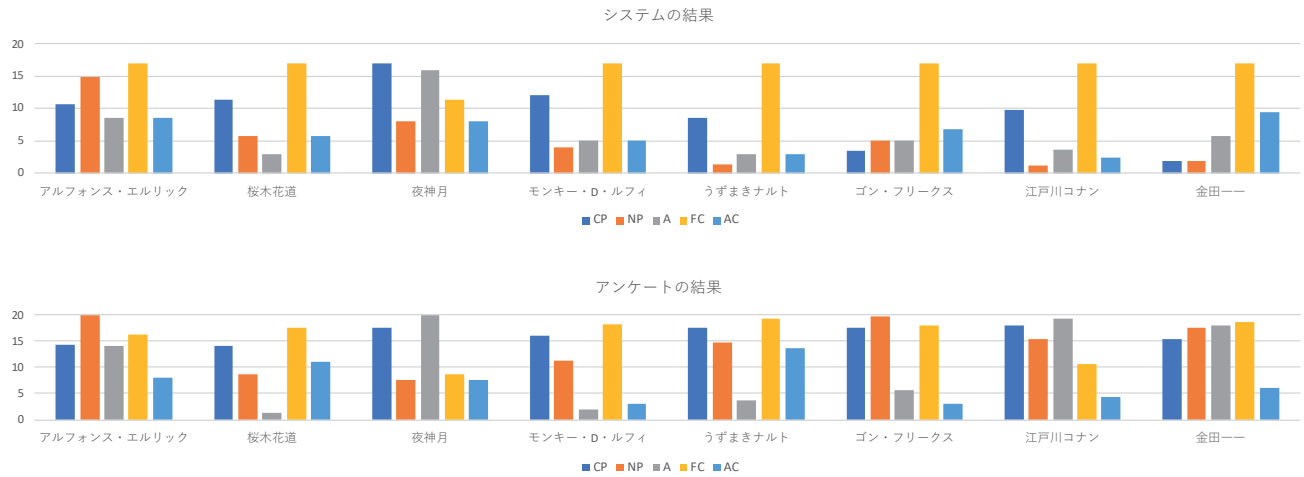


図 3: 実験で得られた性格ベクトル（上段: システムの推測結果，下段: アンケートで得られた結果）

表 5: 実験結果（太字は一致した性格タイプ）

キャラクタ名	類似度	システムの判定結果 1 位	2 位	3 位	実験協力者の判定結果
アルフォンス・エルリック	0.057	**平坦型 1**	台形 1	P 優位	平坦型 1
桜木花道	0.081	**逆 N 型 3**	逆 N 型 2	U 型 2	逆 N 型 3
夜神月	0.086	**逆 N 型 1**	平坦型 1	P 優位	逆 N 型 1
モンキー・D・ルフィ	0.140	**逆 N 型 3**	逆 N 型 2	FC 優位	逆 N 型 3
上杉達也	0.145	**N 型 1**	C 優位	平坦型 1	N 型 1
両津勘吉	0.171	**逆 N 型 3**	FC 優位	逆 N 型 2	逆 N 型 3
坂田銀時	0.263	M 型	FC 優位	**逆 N 型 3**	逆 N 型 3
黒崎一護	0.286	NP 優位	**P 優位**	台形 2	P 優位
キルア・ゾルディック	0.323	台形 3	FC 優位	C 優位	W 型
幸平創真	0.366	FC 優位	逆 N 型 2	**逆 N 型 3**	逆 N 型 3
エドワード・エルリック	0.373	FC 優位	台形 3	台形 1	逆 N 型 3
ロロノア・ゾロ	0.494	逆 N 型 1	台形 3	A 優位	AC 低位
日向翔陽	0.526	U 型 2	逆 N 型 2	**逆 N 型 3**	逆 N 型 3
エレン・イェーガー	0.561	逆 N 型 2	逆 N 型 3	FC 優位	逆 N 型 1
孫悟空	0.647	FC 優位	台形 3	C 優位	逆 N 型 3
緋村剣心	0.664	M 型	NP 優位	台形 1	P 優位
うずまきナルト	0.837	逆 N 型 2	**逆 N 型 3**	FC 優位	逆 N 型 3
ゴン・フリークス	1.006	FC 優位	C 優位	台形 3	逆 N 型 3
江戸川コナン	1.380	逆 N 型 2	逆 N 型 3	FC 優位	P 優位
金田一一	1.416	AC 優位	C 優位	FC 優位	平坦型 1

6. おわりに

本稿では，キャラクタの性格特徴に基づいたコミック検索支援システムの実現のため，ストーリーに大きく影響するキャラクタの性格に着目し，エゴグラムに基づいたキャラクタの性格分類を試みた．実験結果から，エゴグラムを用いた性格分類が可能であることを確認した．これにより，キャラクタ間の性格類似度が算出可能になるため，「このキャラクタと似た性格のキャラクタが登場するコミック」といった検索要求への対応が期待される．今後，性格語辞書の拡充と性格タイプ推定の精度向上について研究を進める．

謝辞

本研究の実施にあたり JSPS 科研費 15K12103 の助成を受けた．記して謝意を表す．

参考文献

[1] Dusay, J.: Egograms and the constancy hypothesis, *Transactional Analysis Journal*, Vol. 2, No. 3, pp. 37–41 (1972).

[2] 廣瀬俊司, 建林学, 斎藤久美, 吉川悟: プラキシズムの心理的要因の研究—リスク要因の分析—, 日本心身医学会, Vol. 55, No. 7, pp. 864–872 (2015).

[3] 金子紀子: 新版 TEGII・東京大学医学部心療内科 TEG 研究会編, 金子書房 (2006).

[4] 和田迪子, 渡部麻美, 市村美帆, 松井豊: Web 調査による新しいエゴグラムの尺度開発, 筑波大学心理学研究, Vol. 53, pp. 63–71 (2017).

[5] 山崎勝之: 日本における性格研究の動向と展望, 教育心理学年報, Vol. 41, pp. 73–83 (2002).

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

文の分散表現に基づく小説のストーリー解析手法の提案

A Novel Story Analysis Method based on the Distributed Representation of Sentences

福田 清人 *1　森 直樹 *1　松本 啓之亮 *1
Kiyohito Fukuda　Naoki Mori　Keinosuke Matsumoto

*1大阪府立大学 工学研究科
Graduate School of Engineering, Osaka Prefecture University

Recently, automatic generation and creative support of narrative works like novel and comic by the computer has attracted interest in artificial intelligence fields. Narratives can be divided into the story and the representation medium. We focus on story because it is more robust against time lapse than representation medium. Lots of studies on story analysis have been reported. However, these studies use only surface information such as frequencies of words and onomatopes.

In this study, we propose novel analysis method based on the distributed representation of sentences generated by bidirectional long short-term memory and autoencoder.

1. はじめに

近年, 計算機の爆発的な発展を背景として, 深層学習 (Deep Learning) に代表される人工知能技術が大きく成長してきた. その中で小説や漫画, 絵本のような物語を計算機によって自動生成する試みや, 人が物語を創作する際の創作支援を計算機にさせる試みが大きな注目を集めている. 物語とは人の感性に基づく創作物であり, ストーリーと表現媒体という 2 つの要素に分解できる. ストーリーは物語の内容であり, 表現媒体は言語や画像のようなストーリーを表現するための媒体である. 本研究では, 表現媒体ではなくストーリーに焦点を当てる. ストーリーの方が表現媒体よりも時間経過に対してロバストであると考えたためである. また, 今回は言語のみの単一表現で生成されている小説を解析対象とする.

物語の自動生成に関する研究は, アーサー王と円卓の騎士に材を取った小説を自動生成するシステム [Turner 93] や 4 コマ漫画での絵の時系列変化に着目した絵モデルに基づく 2 コマ漫画の自動生成手法 [Ueno 14] など, 数多く有効な手法が報告されている [福田 17]. また, 物語の創作支援に関する研究も, 子供に対して 5W1H に沿った問いかけを実行し, 生成されるストーリーの構成を誘導することで創作支援するシステム [上原 11] や, 物語論に基づくストーリーテンプレートおよび物語の盛り上がりを表す想定感情線を用いてユーザが継続的に使用可能で物語の構造を整理することができるシステム [葛井 16] など, 数多く報告されている. 一方, 物語の解析に関する研究では, 星新一の作品を構造分析の考えに基づきテキストの時系列に着目して物語のパターン抽出をする研究 [佐藤 10] や, 漫画に対してセリフ内容やフキダシの種類といった構成要素を用いて解析する研究 [林 13] などが存在する. しかしながら, これらの研究では単語やオノマトペの使用頻度といった物語の表層的な特徴のみを用いており, 文の意味のような深層特徴を用いていないことが問題点として挙げられる.

Deep Learning のような機械学習による物語の自動生成や創作支援を考えるうえで, 既存の物語に対して適切な解析をすることで有用な情報を抽出することは必要不可欠な技術であり, 最優先課題といっても過言ではない.

連絡先: 福田清人，大阪府立大学 工学研究科，大阪府堺市中区学園町 1-1，072-254-9273，fukuda@ss.cs.osakafu-u.ac.jp

以上の点を背景として, 本研究では文の意味を考慮した小説の解析方法について述べる. 具体的には, LSTM および Autoencoder を用いて生成した文の分散表現を基礎として, そこからいくつかの特徴を生成して小説におけるストーリーの展開を解析する手法を述べる.

2. 文の分散表現の獲得

本研究では, 文の意味を考慮した物語の解析を目的とする. そのため, 意味や用法の類似性を定義することができる文の分散表現を獲得する必要がある. そこで, 次元削減をすることで特徴抽出する Autoencoder を用いて, Encoder と Decoder を連結する中間表現をその文の分散表現として獲得する. 文が持つ多様で複雑な情報を抽出する必要があるため, Encoder には双方向 Long short-term memory (Bidirectional LSTM: BLSTM) を用い, ネットワーク全体を多層構造にする. 図 1 に文の分散表現を得るためのネットワーク構造を示す.

また, 文の意味とは文を構成する単語の意味を一定の合成手続きに従って決定されるという構成性原理に基づくと仮定する. 単語の意味を考慮した文の分散表現を得るため, ネットワークの入出力には事前に学習した Word2Vec[Mikolov 13] による単語の分散表現を用いる.

3. 物語の解析手法

3.1 小説におけるストーリー

本研究では物語の中でもストーリーという要素に着目して解析することを目指す. ここで, ストーリーを, イベントや登場人物の行動, 場所移動に伴う物語中の一連の状態遷移の時系列だと定義する. ここで, 小説を文の分散表現の集合であると仮定すると, ある連続した 2 つの文の分散表現に対して, 何らかの演算子を適用した結果がその 2 文間での状態遷移を表しているといえる. そのため, 小説におけるストーリーは冒頭から末尾までの連続した 2 文の分散表現にある演算子を適用した結果の集合であると言い換えることができる. しかしながら, ここでいう “連続した 2 つの文” には様々な粒度が存在する. イベントや登場人物の行動といった 1 つの事象を 1 文ではなく複数文で表現することも珍しくないためである. そのため, 扱いたい小説や場面ごとに適切な粒度を決定する必要がある.

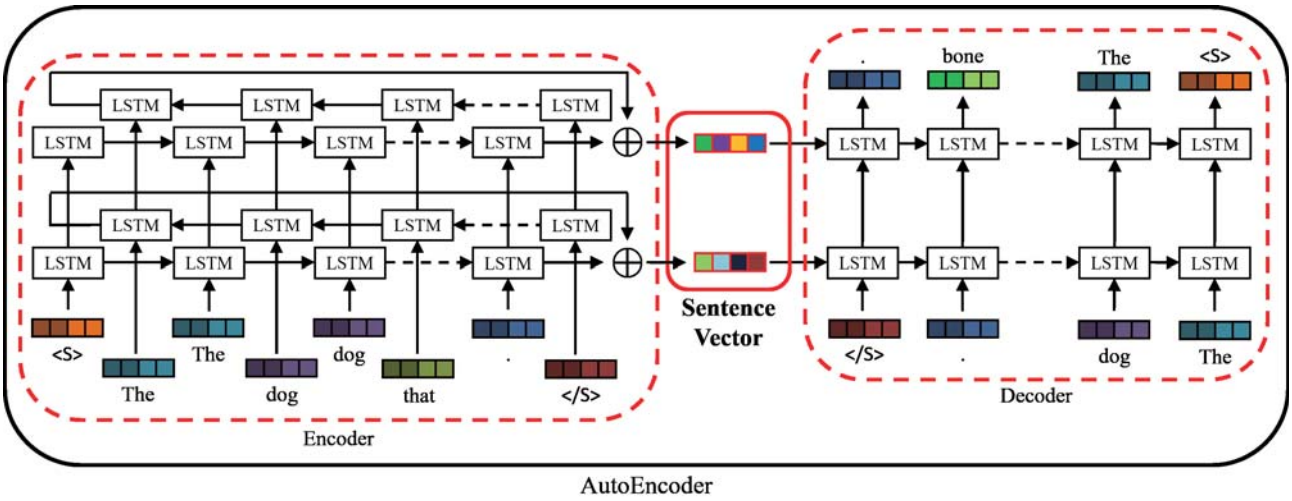


図 1: 文の分散表現獲得ネットワークの構造

3.2 ストーリー解析の方針

小説におけるストーリーを上記のように定義すると, 状態遷移の変化量の大きさがストーリーにおける展開の度合いを表すと考えられる. 同時に, 状態遷移の変化量の大きさや変化量の大きな状態遷移の間隔がストーリー中の場面転換の箇所や展開のテンポを表すと考えられる. また, ストーリーが与える全体を通しての印象は状態遷移における大域的な遷移の方向性に現れると考えられる.

以上の点から, 本研究では以下に示す方針のもと小説の解析を進めていく. 小説の解析をする事前段階として, 小説中の連続した 2 文に対して, 文の分散表現を獲得し, 得られた分散表現に対してある演算子を適用することで, 2 文間の状態遷移を獲得する.

“連続した 2 つの文” の適切な粒度
“連続した 2 つの文” の粒度を 1 文から複数文まで多様に変化させながら解析することで, 作者や作品ごとに適切な粒度を設定することができるのかや, 必要に応じて粒度を自動設定することができるのかを調査する.

ストーリー展開の度合い
小説における状態遷移の変化量を時系列データとして, 変化量の分布や時間変化を解析することで作者や物語のジャンルに特有な特徴が存在するか調査する.

ストーリーが与える大域的および局所的な印象
小説における状態遷移の大域的および局所的な方向性とストーリーが人に与えるハッピーエンドやバッドエンド, 楽しい, 悲しいといった印象や感情との間にどの様な関係性が存在するか調査する.

それぞれについての詳細な解析方法については発表時に述べる.

4. まとめと今後の課題

本研究では, 機械学習手法による物語の自動生成や創作支援手法に不可欠な, 既存作品のストーリーに対する解析方法について, 文の分散表現を基本単位とした小説のストーリーに対する解析手法を提案するためのいくつかの方針を示した. 詳細な解析方法や解析結果については発表時に述べる.

本研究では小説のストーリーに対する解析について述べた. しかしながら, 物語の表現媒体としては CG やイラストのような画像を用いられることが多い. そのため, 文ではなく画像を用いた場合の物語のストーリーに対する解析方法について考察することが今後の課題として挙げられる.

参考文献

[Mikolov 13] Mikolov, T., Chen, K., Corrado, G., and Dean, J.: Efficient Estimation of Word Representations in Vector Space, *CoRR*, Vol. abs/1301.3781, (2013)

[Turner 93] Turner, S. R.: *Minstrel: A Computer Model of Creativity and Storytelling*, PhD thesis, University of California at Los Angeles, Los Angeles, CA, USA (1993), UMI Order no. GAX93-19933

[Ueno 14] Ueno, M., Mori, N., and Matsumoto, K.: *2-Scene Comic Creating System Based on the Distribution of Picture State Transition*, pp. 459–467, Springer International Publishing, Cham (2014)

[葛井 16] 葛井 健文, 上野 未貴, 井佐原 均 : 質問集合とグラフに基づく物語全体の流れを管理可能な創作支援システムの提案, 第 31 回人工知能学会全国大会発表論文集 (2016)

[佐藤 10] 佐藤 知恵, 村井 源, 徃住 彰文 : 星新一ショートショート文学の物語パターン抽出, 情報知識学会誌, Vol. 20, No. 2, pp. 123–128 (2010)

[上原 11] 上原 大輝, 出水 ちあき, 宮里 洸司, 神里 志穂子, 野口 健太郎 : J-030 子どもの思考プロセス把握における物語自作システムの有効性検証 (HCS(2),J 分野:ヒューマンコミュニケーション&インタラクション), 情報科学技術フォーラム講演論文集, Vol. 10, No. 3, pp. 597–600 (2011)

[福田 17] 福田 清人, 藤野 紗耶, 森 直樹, 松本 啓之亮 : 機械学習に基づく対話システムを導入した絵本の半自動生成, 第 31 回人工知能学会全国大会発表論文集 (2017)

[林 13] 林 沙輝, 中山 伸一, 真栄城 哲也 : マンガの構成要素の定量的な解析と類似度判定, 第 75 回全国大会講演論文集, Vol. 2013, No. 1, pp. 845–846 (2013)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

Preliminary Analysis of Weibo Emojis for Sentiment Analysis of Chinese Social Media

Da Li Rafal Rzepka Kenji Araki

Graduate School of Information Science and Technology, Hokkaido University

In this paper, we introduce our preliminary analysis of emoticons used on Weibo, Chinese microblog. By performing a polarity annotation with a new "humorous type" added, we have confirmed that 23 emoticons can be considered more as humorous than positive or negative. We also discussed some possible related problems which might occur during any social media sentiment analysis performed on Chinese language. We believe that combining machine learning, sentiment lexicons and paralinguistic elements as emoticons can be expected to achieve better performance in the future.

1. Introduction

People have become increasingly accustomed to expressing their opinions online, especially on social media such as Twitter, Facebook and Weibo - China's biggest social media network that was launched in 2009. Such microblog data contain a vast amount of valuable sentiment information not only for the commercial use, but also psychology, cognitive linguistics or political science. Sentiment analysis of microblogs becomes the research hotspot in the field of Natural Language Processing. Study of sentiment in microblogs in English language has undergone major developments in recent years [Peng 17]. Chinese sentiment analysis research, on the other hand, is still at early stage especially in the domain of lexicons and emoticons. Emoticons convey a significant emotional information and play an important role in the sentiment analysis of social media [Novak, 15] [Guibon 16]. In this paper we focus on the emoticons used on Weibo; we analyze the characteristics of this particular set of emoticons, report on their evaluation while dividing into three categories: positive, negative and humorous. We list 23 emoticons which were annotated as "humorous" more often than "positive" or "negative". With these novel insights into Chinese emoticons we want to help sentiment analysis researchers to consider implementing emoticons in their algorithms and improve their efficiency. We also discuss possibilities and difficulties in using these emoticons in Chinese social media sentiment analysis and applying them to other domains in the future.

2. Related Research

At present, the sentiment analysis technology generally can be divided into two categories: rule-based relying on sentiment lexicons, and machine learning-based ones relying on annotated data. Tan and Zhang [Tan 08] conducted an empirical study of sentiment categorization on Chinese documents. They tested four features - mutual information, information gain, chi-square, and document frequency; and five learning algorithms: centroid classifier, k-nearest neighbor, winnow classifier, naïve Bayes (NB) and support vector machine (SVM). Their results showed that the information gain and SVM features provided the best performances for sentiment categorization coupled with domain or topic dependent classifiers. There are also researchers who have combined the machine learning approach with the lexicon-based approach. Chen et al. proposed a novel sentiment classification method which incorporated existing Chinese sentiment lexicon and convolutional neural network [Chen 15]. The results showed that their approach outperforms the convolutional neural network (CNN) model only with word embedding features [Kim 14]. However, existing approaches do not consider emoticons. Recently, a powerful system utilizing emoji in Twitter sentiment analysis model called DeepMoji was proposed [Felbo 17]. Its creators trained 1246 million tweets containing one of 64 common emoticons by bidirectional long short-term memory (Bi-LSTM) model and applied it to interpret the meaning behind the online messages. DeepMoji is also the most advanced sarcasm-detecting model, with an accuracy rate of 82.4 percent even outperforming human detectors who managed to acquire 76.1 percent accuracy rate.

3. Emoticons in Chinese Social Media

In the real-life (offline) dialogue between human beings, besides tone changes, we usually express emotions with body language. In social networks, this can partially achieve by using emoticons [Aldunate 16].

In Chinese social media (Weibo in our example), we found that in addition to the expression of positive and negative emotions, people tend to express a kind of humorous emotion, which is not sarcasm. Sarcasm reverses the emotion of the literal text, therefore sarcasm-detecting capability can play a significant role in sentiment analysis, especially in case of social media, however sarcasm and irony tend to convey negative emotions in general. We have noticed above mentioned humorous emotion of Weibo users when they post microblog entries which contain emoticons but are often difficult to be classified as positive or negative. It seems that some emoticons are used just for fun, self-mockery or jocosity which expresses a kind of implicit humor characteristic in Chinese culture. Emoticons seem to play an important role in expressing this kind of emotion. There is a high possibility that this phenomenon can cause a significant difficulty in sentiment detecting task, therefore we decided to analyze Weibo emoticons before adding them to our system for classifying emotions in Chinese microblogs.

Contact: Da Li, Graduate School of Information Science and Technology, Hokkaido University, lida@ist.hokudai.ac.jp

4. Analysis of emoticons used on Weibo

First we chose 67 most common emoticons out of 144 emoticons used in Weibo (see Figure 1). Only the emoticons with facial expression were chosen.



Figure 1: Most common emoticons of Weibo

We asked 12 Chinese native speakers to label these 67 emoticons by applying one of three following categories: positive, negative and humorous. The evaluators were 6 males and 6 females, each of them being a Weibo user for more than five years.

Table 1: Twenty-three emoticons conveying humor typical in Chinese culture

NUMBER	HUM (%)	NEG (%)	POS (%)
A1	41.7	25.0	33.3
G1	58.3	0.0	41.7
L1	66.7	33.3	0.0
E2	91.7	8.3	0.0
G2	58.3	0.0	41.7
M2	83.3	0.0	16.7
N2	58.3	25.0	16.7
O2	66.7	8.3	25.0
G3	66.7	0.0	33.3
H3	41.7	33.3	25.0
I3	75.0	25.0	0.0
J3	58.3	41.7	0.0
M3	50.0	25.0	25.0
O3	66.7	33.3	0.0
A4	50.0	50.0	0.0
E4	58.3	41.7	0.0
H4	50.0	50.0	0.0
I4	50.0	50.0	0.0
A5	50.0	33.3	16.7
C5	41.7	41.7	16.7
D5	75.0	8.3	16.7
F5	58.3	33.3	8.3
G5	75.0	0.0	25.0

The annotation results showed that there are 44 emoticons with obvious positive or negative emotion, and the remaining 23 emoticons are considered more as humorous than positive or negative. The results are summarized in Table 1.

5. Discussion

Our hypothesis is that the emoticons which are considered to be humorous expression in more than 50% of cases (see Table 1) usually convey humorous load. Moreover, the sentiment polarity of emoticons such as , , and other cases show rather clearly their ambiguity, and they should be treated with special care when we add emoticon recognition capability to our system in the future. A1 was originally a smile emoji, but more and more people believe that this emoji is used for expressing artificial smile, ridicule or self-mockery. On the other hand, when dealing with such emoticons on Weibo, we should be careful with jumping to conclusion and straightforwardly label it as a humorous, but instead we need to use a significant number of labeled examples containing these emoticons to train an appropriate model, for example by means of deep neural network. Besides, special attention should be given to emoticons such as , , , and because they tend to be considered to represent humorous meaning, and they became the most frequently used emoticons in Weibo in recent years (see Figure 2) [*1].

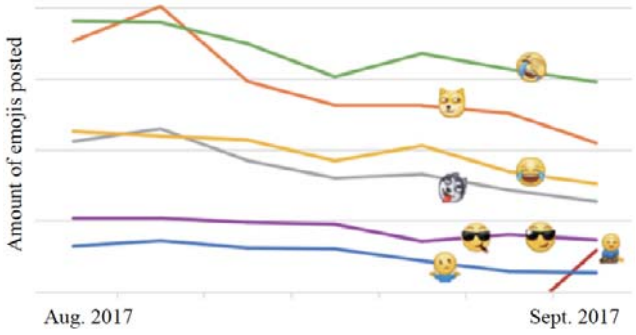


Figure 2: Top seven most frequently used emoticons in Weibo in 2017

Usually, when we process NLP tasks in social media, researchers tend to filter out images and videos as noise and concentrate on textual analysis. This often brings obvious difficulties for the sentiment analysis task. For example, as shown in Figure 3, we know that the user wants to share some gourmet food he ate during his journey, but if we only consider the text, "Morning! Third day in Sapporo, what should I eat for breakfast?" would be normally considered as neural, but because the tweet contains (100% positive in our annotation), a system could correctly mark the entry as positive. Based on this observation, we can notice that the sentiment analysis considering emoticons has could improve performance while analyzing short texts or the posts with images without any image processing.

The hypothesis that human facial expressions are universal [Darwin 72] is likely wrong [Gendron 14]. [Ekman 92] pointed out that the human beings of all races in the world have six basic feelings in common. However, as [Jack 14] study suggest, there

*1 http;//www.civiw.com/webyy/20170920175205

might be only four basic feelings. There are many unknown factors in constantly changing moods of human beings, but communication with emoticons has become a global phenomenon. On the other hand, because of different ethnic and cultural differences, misunderstandings in using facial emoticons are possible [Rzepka 17]. We noted that in the Facebook emoticons survey 2017[*2] the emoji 😂 ranked first in the list of most used emoticons top 10. This emoji is similar to the most used emoticons in 2017 on Weibo: 😓 according to their survey[*3]. It looks like a combination of 🤦 (Person Facepalming) and 😂 (Face with Tears of Joy). Both of them look like a face laughing through tears, but the expression of feelings is different when "facepalm" hand is added causing 😓 express the resignation nuance more humorous. It also shows that we need to pay attention to the cultural background of different races in the emotional processing of multiple languages.



Figure 3: Weibo post: "Morning! Third day in Sapporo, what should I eat for breakfast?"

6. Conclusions and Future Work

In this paper, we introduced our preliminary analysis of emoticons used on Weibo, Chinese microblog. By performing a polarity annotation with a new "humorous type" added, we have confirmed that 23 emoticons can be considered more as humorous than positive or negative. We also discussed some possible problems which might occur during any social media sentiment analysis performed on Chinese language. We believe that combining machine learning , sentiment lexicons and paralinguistic elements as emoticons can be expected to achieve better performance in the future. In terms of applications, tourism information detection, tourism attraction or food recommendation systems can also be expected to have better accuracy by implementing emoji processing. We would also like to draw attention of the sentiment researchers to the phenomenon of emoticons that can change their meaning in time. This can be an important clue suggesting that updating data for machine learning-based approaches might be crucial.

*2 http://www.theverge.com/2017/7/17/15984204/facebooks-most-used-emoji-hearts-tears

*3 http://weibo.com/ttarticle/p/show?id=2309351000124181543877781277

References

[Aldunate 16] Aldunate N, González-Ibáñez R. An Integrated Review of Emoticons in Computer-Mediated Communication. *Frontiers in Psychology* (2016)

[Chen 15] Chen, Z., Xu, R., Gui, L., Lu, Q.: Combining convolution neural network and word sentiment sequence features for Chinese text sentiment analysis. Journal of Chinese Information Processing. 2015;29(6). (2015)

[Darwin 72] Darwin, C.: The expression of the emotions in man and animals John Murray (1872)

[Ekman 92] Ekman, P.: An argument for basic emotions, Cognition & emotion, Vol. 6, No. 3-4, pp. 169–200 (1992)

[Felbo 17] Bjarke Felbo, Alan Mislove, Anders Søgaard, Iyad Rahwan, Sune Lehmann.: Using millions of emoji occurrences to learn any-domain representations for detecting sentiment, emotion and sarcasm. Association for Computational Linguistics, pp 1616-1626, Oct 2017. (2017)

[Gendron 14] Gendron, M., Roberson, D., Vyver, van der J. M., and Barrett, L. F.: Perceptions of emotion from facial expressions are not culturally universal: evidence from a remote culture., Emotion, Vol. 14, No. 2, p. 251 (2014)

[Guibon 16] Guibon, G., Ochs, M., Bellot, P.: From Emojis to Sentiment Analysis: WACAI 2016, Jun 2016, Brest, France. (2016)

[Jack 14] Jack, R. E., Garrod, O.G., and Schyns, P.G.: Dynamic facial expressions of emotion transmit an evolving hierarchy of signals over time, Current biology, Vol. 24, No. 2, pp. 187–192 (2014)

[Kim 14] Yoon Kim. Convolutional neural networks for sentence classification. In Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP), pages 1746–1751, Doha, Qatar. (2014)

[Novak 15] Kralj Novak P, Smailović J, Sluban B, Mozetič I, Sentiment of Emojis. PLoS ONE 10(12): e0144296 (2015)

[Peng 17] Peng, H., Cambria, E., and Hussain, A.: A review of sentiment analysis research in Chinese language. Cognitive Computation. (2017)

[Rzepka 17] Rzepka, R., Okumura, N., Ptaszynski, M.: Worlds Linking Faces — Meaning and Possibilities of Contemporary Pictograms: Journal of the Japanese Society for Artificial Intelligence 32(3), 350-355, 2017-05 (2017)

[Tan 08] Tan, S., Zhang, J.: An empirical study of sentiment analysis for Chinese documents. Expert Syst Appl. 2008;34(4):2622–9 (2008)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

Filtering out improper accounts from Twitter user accounts for discovering individuals interested in certain topic

Chao Cai[*1] Shun Shiramatsu[*1]

[*1] Department of Computer Science, Graduate School of Engineering, Nagoya Institute of Technology

Nowadays, the continuously growing popularity of Web-based Debates and online survey are requiring participants from different places and backgrounds which raises the need of the application for topic-oriented participants recommendation based on social networking service(SNS). Among several kinds of SNS, Twitter holds over 300 million users located all over the world. Therefore, the aim of this paper is to propose a filter technique applying natural language processing skill, which filters the individual users from other official or robot users of twitter for Web-based Debate system and online survey participants recommendation. To keep the balance of user groups for training, the search was divided into two parts with different list of keywords. As result, we gained the F measure of 0.93 by processing the data with SVM.

1. Introduction

Recent years, the application of Web-based debate system is gradually growing. In 2013, the debate concerning Nagoya City Time Plan by Imi et al. [Imi 2014] involved 266 people by utilizing the Online Debate System COLLAGREE. Recommending and inviting participants online has become an essential issue when organizing a debate or survey. This paper is focused on twitter which holds over 300 million users from different locations. The research A Machine Learning Approach to Twitter User Classification by Marco Pennacchiotti et al. [Pennacchiotti 2010] could gather groups of twitter user who are interested in certain topic. However, there are unavoidably official users or robot users mixed in the user group. To discover individual users who can participate in debate or survey on specific topic, we describe a user filter which can filter out the improper users.

Since the robot or official user generally has different tweet behavior and user information, the main idea of this paper is to suppose a filter based on the concept. The system is designed to analyze the tweet part (created time and tweet text) and the user information part (onscreen name and description) of each data set with TFIDF and support vector machine (SVM).

2. Designing feature vector

2.1 Details of the data

We have collected 669 data sets in advance through twitter stream API and tweet search API, in which each data set involves 4 parts: (1) tweet text, (2) tweet created time, (3) user name, (4) user description. To keep the balance of number of individual users and improper user, the data was collected based on two different lists of keywords in two separated searches. The ratio of individuals and improper users is 452:217.

2.2 Features of user groups

As the main concept defined above, to decide which group one user is, two main parts are considered, which are the tweet contents and user information. For the improper users, we separated them into 3 groups: (1) official user, (2) inactive user, (3) robot user by analyzing the data.

- Official user: specific terms in user onscreen name or description (e.g. kousiki akkaunto (official account) in description or company name in both part).
- Inactive user: retweet only the campaign contents and without a user description with random characters terms in onscreen name.
- Robot user: specific terms (e.g. bot or common entities) in user onscreen name or description, involving advertisement or promotion either in description and tweet content.

While the individual users who generally have specific terms representing their real name in onscreen name and most likely with a description involving location or date of birth. Table 1 shows the samples contents of each user group.

2.3 Pre-processing the data

As we mentioned above, the specific terms in each tweet text or user information may help judge the group of users. Hence, for words embedding and extracting the classification information, we apply MeCab and term frequency-inverse document frequency(TFIDF) algorithm. In this work, all tweets and users have been collected under a list of Japanese keywords. Meanwhile, MeCab can segment Japanese sentences into words which can be the input of TFIDF later. TFIDF is to retrieve unique terms for document in a corpus. Since the same term will unavoidably appear in both tweet content part and user information part, we process them separately by TFIDF to generate two matrix-like data which both contain 669 rows with 5110 dimensions for tweet part, 5949 dimensions for user information part. Because the same row in two matrix data refers to one user-tweet data set, we combine the two vectors to generate a xxx multiply xxx matrix. For each vector, dimension from 1st to 5110th refers to tweet contents and the rest dimensions refer to user information.

2.4 Future works

For our future works, we are planning to take the user tweet behavior (the tweet frequency in a certain period, times of retweet

Contact: Chao Cai, Nagoya Institute of Technology, Gokiso-cho, Showa-ku, Nagoya-shi, Aichi 466-8555, Japan

Table 1: Samples for each user group

Group	Onscreen name	Description	Tweet text
Official user	@HuffPostJapan	ハフポスト日本版公式アカウントです。 ライフスタイル@HPJPLifestyle	みんなに支持されるのは、どちらの歌でしょうか？
Robot user	@warakosodateBOT	ちょっと知っておくと子育てで役に立つヒントや、笑ってしまう子育てエピソードをつぶやきます！	親だって人間だから、感情的に怒鳴っちゃうことだってあるよね～。そんな時は後で素直に謝ればいいんじゃないかな。
Inactive user	@vJX3qMICBftMeco	None	RT @UNITED_CINEMAS: ★赤ちゃんと一緒に映画を観られる「抱っこ deシネマ」 10 月・11 月の上映作品決定！
Individual user	@shochan710	大阪のはずれ、ひらパー村から愛を叫ぶ…(≧ω≦)「ぶっさん大好き～！」 まだまだ強火剛担ジャニオタ高校生男子と親子で V6 応援中～	へそ出し短パンの 20 代、ミニスカ・ネイルの 30 代(OL さん)、遠征・オールの 40 代・・

et al.), user relationship (followers and followee analysis) and analysis of other contents of user information (created time, location etc.) into consideration for design of feature vector to construct a more distinguishable representation of each user.

3. Filter with SVM

SVM is known as an efficient machine learning model with high accuracy by constructing a hyperplane that can represents the largest margin between two groups of data, which have been constantly showing reliance on binary classification. By applying the Kernel Function, SVM can perform a nonlinear classification. In this paper, we apply SVM with RBF Kernel, which is with 2 significant parameters, cost parameter (C) and Gamma.

3.1 C and Gamma

C is a parameter that determines the penalty of misclassification in case that the data cannot be separated linearly (or nonlinearly). Gamma parameter will change the complexity of detective range which unavoidably decrease the compatibility of the model. The Gaussian function can be defined as below:

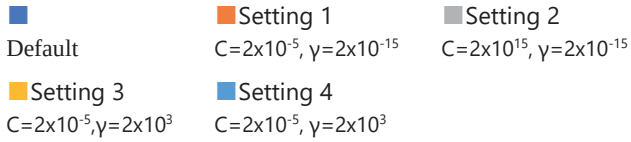
$$K(x, x') = exp(-\gamma \|x - x'\|^2)$$

We can find out that the graph of K will become more complex as the value of gamma grows. Thus, the tuning of parameter will be important for this work.

3.2 Result of experiments

We simply run the filter to process the data that we have vectorized and fabricated for 60 times. For each 10 times, the parameters are changed, and the training-test data separation will be randomly determined to gain a cross-validation like result, of which we calculate the averages of precision score, recall score and F measure. We simply show the results with different parameter settings in Figure 1, 2 , 3. In addition, the default setting is C = 1.0, Gamma = 0/number of dimensions.

We can find out from Figure 1 and Figure 3 that the precision score and F measure can be only visually affected with large C and small gamma and the recall score barely change as the parameters change.



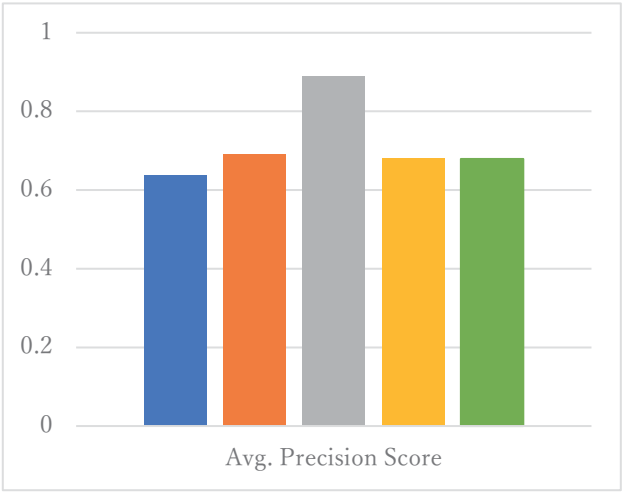


Figure 1: the average of precision score

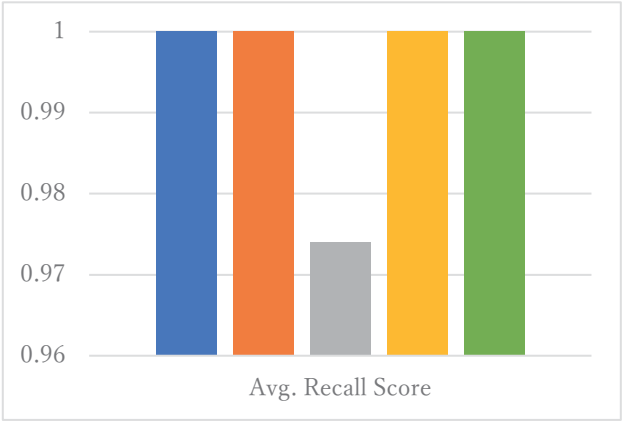


Figure 2: the average of recall score

4. Evaluation of result

Precision Score. Since the precision score is determined by the number of true positive samples and false positive samples, the miss recognition of improper user significantly affects the precision score. Because of the similarity of users group and the small size of data with less well balance, SVM runs with small C will simply misjudge the user group since there exist much user data without unique feature.

Recall score. Because of the balance of user group, the individual user prediction appears unavoidably more than improper one. Since the recall score decreases only when misjudgment of individual user occurs, the recall score stays stable as expected.

F measure. F measure is the harmonic mean of precision and recall. We suppose that F measure indicates the convincible accuracy of the model. As the result shown in Figure 3, much tolerance of misrecognition and simpler detected range by large C and small gamma significantly improve the performance of this model even though the recall score decreases.

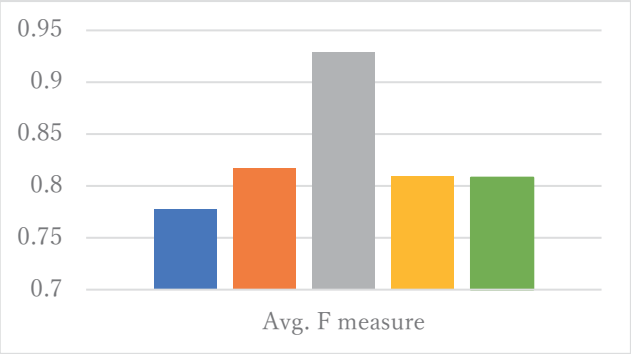


Figure 3: the average of F measure

5. Conclusions and future work

We presented a filter system that filter out the improper user from the raw data set collected by twitter API. We attempted to summarize the features of each user group with the tweet contents and user description. With the feature vector we designed, we have gained acceptable result and showed that the user filter is a feasible task.

However, the data size and balance have limited the reliance and the compatibility of this model. The design of feature vector is too simple especially when dealing with larger size of data. Hence, for future work:

- Larger size of data
- Introducing Deep Learning such as CNN into the model
- More well-thoughted design of feature vector

Acknowledgement

This work was partially supported by JST CREST (No. JPMJCR15E1) and JSPS KAKENHI (No. 17K00461).

References

[Imi 2014] 伊美祐麻 伊藤孝行 伊藤孝紀 秀島栄三, “大規模意見集約システム COLLAGREE の 開発と名古屋市時期総合計画に関する社会実験”, JSAI, 4M1-4, 2014

[Pennacchiotti 2011] Marco Pennacchiotti, Ana-Maria Popescu, ***A Machine Learning Approach to Twitter User Classification***, Proceedings of the Fifth International AAAI Conference on Weblogs and Social Media, AAAI, 2011.

Oral presentation | Organized Session | [Organized Session] OS-2

[1K1-OS-2a] [Organized Session] OS-2

Tue. Jun 5, 2018 1:20 PM - 3:00 PM Room K (3F Azisai Mokuren)

[1K1-OS-2a-01] Analysis on Elements to Motivate Reading Comics Motivation

○Kenta Sato[1], Yoshiki Maki[1], Satoshi Nakamura[1] （1. Meiji University）

1:20 PM - 1:40 PM

[1K1-OS-2a-02] Autonomous Generation of 2-panel Comics Based on Human-made Comics

○Kazushi Mukaiyama[1] （1. Future University Hakodate）

1:40 PM - 2:00 PM

[1K1-OS-2a-03] Toward a Network Analysis of Empathic and Exciting AI Conversation and Scenario

○Yasuda Yuki[1] （1. Kansai University）

2:00 PM - 2:20 PM

[1K1-OS-2a-04] A Proposal of Machine Translation from Japanese to Chinese Onomatopoeias

○KAI YANG[1], Tsuyoshi Nakamura[1], Masayoshi Kanoh[2], Koji Yamada[3] （1. Nagoya Institute of Technology, 2. Chukyo University, 3. Institute of Advanced Media Arts and Sciences）

2:20 PM - 2:40 PM

[1K1-OS-2a-05] Recognizing the Order of Four-scene Comics by Three-Path Convolutional Neural Networks

○Saya Fujino[1], Naoki Mori[1], Keinosuke Matsumoto[1] （1. Osaka Prefecture University）

2:40 PM - 3:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

コミックの読書意欲を増進させる要素に関する分析

Analysis on Elements to Motivate Reading Comics Motivation

佐藤 剣太[*1] Kenta Sato
牧 良樹[*1] Yoshiki Maki
中村 聡史[*2] Satoshi Nakamura

[*1] 明治大学大学院 先端数理科学研究科 先端メディアサイエンス専攻
Graduate School of Advanced Mathematical Sciences, Meiji University

[*2] 明治大学 総合数理学部 先端メディアサイエンス学科
Department of Frontier Media Science, School of Interdisciplinary Mathematical Sciences, Meiji University

Several Web sites show a scene of comics as an advertisement to sell them. The objective of our work is to estimate the best page in the comic for a user to increase his/her reading motivation depending on the context. In this paper, we analyze the recommended pages in each comic which we generated in our past work and clarify the characteristics of them. Also, we consider a method to estimate such pages.

1. はじめに

コミックは多くの人に長年楽しまれてきたコンテンツの一つである. 2016 年のコミック市場における年間発行部数は 4 億 6000 万冊, 推定販売金額は 4400 億円を超えており[全国出版協会 17], その規模は非常に大きいことが分かる. 近年では電子コミックの需要も拡大しつつあり, 書籍配信サービスの eBookJapan [eBookJapan 18]で取り扱われているコミック作品は約 30 万冊となっている.

コミックの売り上げを増やすために, コミックの一部を Web 広告として提示することは珍しくないが, 多くの広告は手作業によりインパクトのあるページを選定し, 画一的に提示されるものであり, 十分に読書意欲を増進できているとは言い難い. ここで, ストーリーコンテンツの内容提示により, 読者にどのような影響を及ぼすかを検証した研究はいくつか行われており, Leavitt ら[Leavitt 11]は, 小説のネタバレを読者に読む前に提示することで, その作品が面白く感じられるようになったことを明らかにしている. 一方, 我々は以前の研究[Maki 17]でコミック作品を対象とした読書実験を行い, 作品を中盤まで読み進めた段階でネタバレページを提示すると興味度合いが減少することを明らかにしている. つまり, コミックの一部を広告として提示する場合には, こうしたどの程度まで読んだのかという情報なども考慮する必要があるといえる.

我々はこれまでの研究[佐藤 18]において, コミックの読書促進を目的とした実験を行ってきた. この実験では, 読者の既読部分と未読部分に注目したページ推薦実験を行い, ある程度まで読んでいる読者に対して未読部分を提示することが, 作品を読み進めるモチベーションを高めることを明らかにしてきた. このように, どういったユーザに対してどういったコミックの部分を提示することが読書意欲増進において有効であるのか明らかにできると, 作者, 読者, 出版社, サービス提供者いずれにとっても意義深いといえる. しかし, この研究では構築されたデータセットの推薦ページに対する分析が十分ではなかったため, 実際の読者にどういうページを推薦したら読書促進へとつながるかという点が不明瞭なままであった. また, 評価実験についても人数が少ない状態であり, 正確な分析がなされているわけではなかった.

そこで本研究では, 我々が以前に構築したデータセットにおける推薦ページの分布の傾向について明らかにする. また, 推薦されたページの内容をみることにより, 何が描かれているページが好まれ, 推薦される傾向にあるのかを明らかにする. さらに, 評価実験における実験人数を増やすことによって, より正確な分析を行う.

2. 関連研究

村井ら[村井 13]は, 電子小説を対象として, 読者の効率的な立ち読みを支援するインタフェースを提案している. この研究では, 小説作品に対するレビューに含まれる単語を用いて「興味喚起度マップ」を作成しており, 読者が興味を惹かれやすい箇所を簡単に検索することを可能としている. こうした興味に関する単語は広告としても有効であると考えられるが, コミックの場合は, 絵やコマ, 吹き出しなど様々な要素があるため, こうした情報を作るのは容易ではない. また, Hinze ら[Hinze 12]は, 学術図書館の利用者を対象としたインタビューを行っており, 書籍が各利用者にとって必要なものであると判断する理由として, 目次やめくる行為が重要な役割を果たしていることを明らかにしている. コミックにおいては, 目次は参考にならないため, どういった情報を提示することが重要かについて明らかにしていく必要がある.

コミックの読書行為を支援するため, 山西ら[山西 13]は, コミックに対する感性を他者と共有するインタフェース「コマコミュ」を提案している. この研究ではコミックの読者に充実した読書経験を与えることを目的として, 読者のコミック閲覧中の心理状態に応じたインタフェースを用意することで, 読書のエンタテインメント性を拡張している. Plaisant ら[Plaisant 06]書籍の著者の年代データを利用したマイニングを行ったうえで, 文学作品の解釈を支援するインタフェースを提案している. 我々は, こうした読書行為をそもそも発生させることを目的とした研究を行っている.

3. 推薦ページに関する分析

3.1 データセット

我々は以前の研究[佐藤 18]で, 推薦ページに関するデータセット構築を行った. 対象コミックは, ラブストーリー, バトル, スポーツ, SF の 4 ジャンルについて, それぞれ 4 作品ずつ, 合計

16 作品を選定した．なお，それぞれのジャンルについて Manga109[Matsui 15]で公開されているコミックから 2 作品ずつ選定した．作品の選定基準は，そのコミックを読んだことがない人にページを提示したときの読書意欲を測るため，実験対象者（明治大学総合数理学部および同大学大学院先端数理科学研究科の 20〜24 歳の学生）が，読んだ経験がないと著者が判断したものである．

データセット構築者には，各作品の 1 巻を読んでもらい，読み終わった後に，巻の前半部および後半部から気に入ったページを見開きで 3 ページずつ選定してもらった．なお，これらの各ページには好みの度合いを 0（全く気に入っていない）〜100（とても気に入っている）の整数値で付与してもらっている．

データセット構築には，5 人の大学生（20〜23 歳）に協力してもらった．構築を実施した期間は，2018 年 2 月 6 日〜10 日の 5 日間である．また，データセット構築者が選定したページを，他者への推薦ページと読み替えて以降の分析および実験で使用する．

3.2 分析

ページと好みの度合いの分布例を図 1〜4 に示す．図の横軸の左から右に向かってページ番号が大きくなる順に並べられており，左端が巻頭，右端が巻末となっている．また，縦軸が好みの度合いの合計値を表している．ここで好みの度合いは人によって合計値が大きく異なっていたため，1 人の構築者が評価した 6 ページ分の好みの度合いの合計値が 1 になるように正規化を行っている．図 1〜4 では，構築者別に異なる色で表示しており，複数の色の棒グラフが積み上がっている箇所は複数人の構築者が同じシーンを推薦したことを示している．

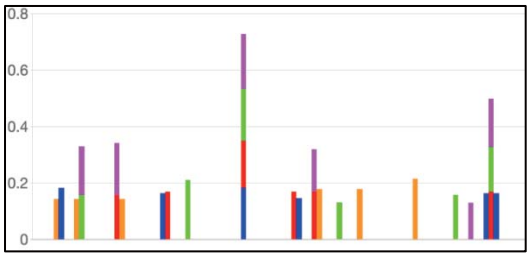


図 1 推薦ページの分布（恋は光）

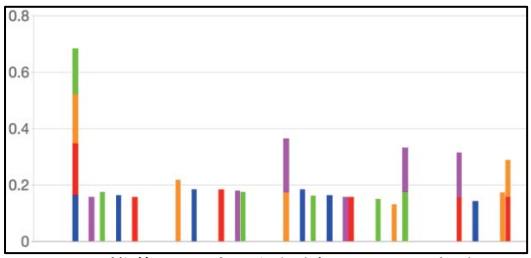


図 2 推薦ページの分布（密・リターンズ！）

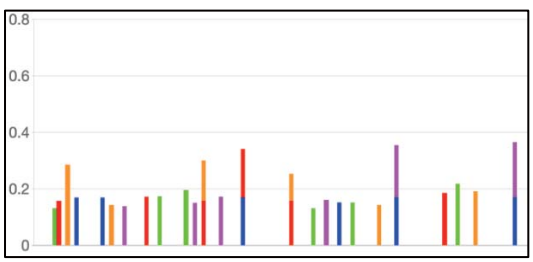


図 3 推薦ページの分布（銃夢）

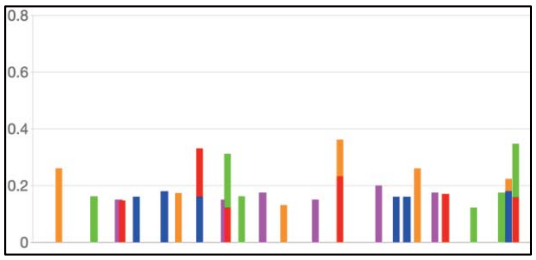
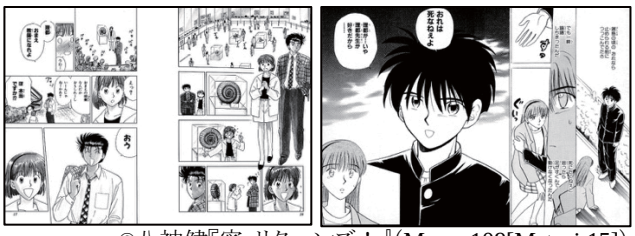


図 4 推薦ページの分布（BEMADER・P）

まず，図 1, 2 の作品に着目してみると，4 人が同一のページを推薦した箇所がそれぞれ 1 つずつ存在し，いずれのページも値が 0.7 程度となっている．また，図 1 の作品の終盤では 3 人が同一のページを推薦したものが 1 つ存在する．このことから，これらの作品では，複数人の構築者が面白いと感じたり，興味を惹かれたりした箇所が一致することが分かった．

次に，図 3, 4 の作品に着目してみると，いずれのページも好み度合いの合計値が 0.4 を下回っていることが分かる．また，どちらの作品も，同一のページを推薦した構築者の人数が最大で 2 人となっており，多くの構築者が共通して気に入ったページはあまりなかったということが分かった．すなわち，これらの作品では，人によって面白いと感じたり，魅力的だと感じたりする箇所が異なるということがいえる．

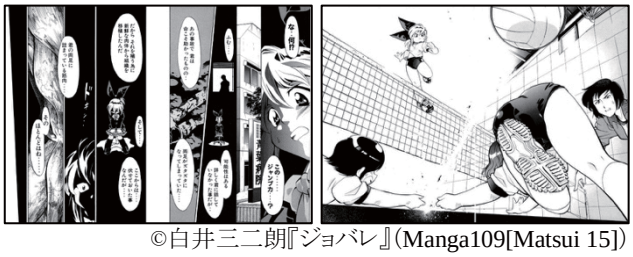
次に，選定された例を各ジャンルより見開き 1 ページずつ図 5〜8 に示す．



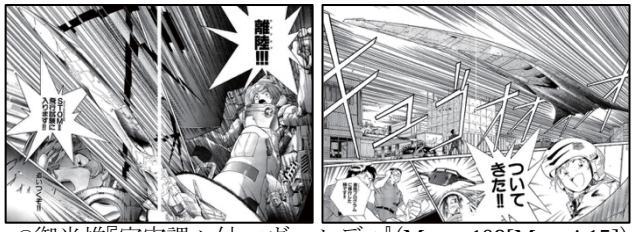
©八神健『密・リターンズ！』（Manga109[Matsui 15]）
図 5 推薦ページの例（ラブストーリー）



©島崎譲，鷹司『花影戦記 妖魔降臨』（Manga109[Matsui 15]）
図 6 推薦ページの例（バトル）



©白井三二朗『ジョバレ』（Manga109[Matsui 15]）
図 7 推薦ページの例（スポーツ）



©御米椎『宇宙課々付 エヴァ・レディ』(Manga109[Matsui 15])
図 8 推薦ページの例(SF)

まず, 他のページに比べ活字によるセリフの少ないページが推薦ページとして選定される傾向にあった. 図5(左)では, 右側のページにセリフが一切書かれておらず, イラストのみの描写となっている. 図 6(左)については, 人の発話部分であっても手書きで表現されているものが見受けられ, 活字の使用されている箇所は少ない.

次に, 見開きページを横断する大きなコマをもつものも, 推薦ページとして選出される傾向にあった. 例えば図7(右)ではコマ割りが存在せず, 1 コマだけが大きく描かれている. また, 図 5(右), 図 6(右), 図 8(左), 図 8(右)においても, 複数のコマが存在するものの, 1 つのコマがページの大部分を占めていることが分かる. 図 7(左)は縦に長いコマだけで構成されており, 通常のページにはない特徴をもっている.

以上のことから, 推薦ページを自動決定する場合には, こうしたページの特徴を利用することが効果的であるといえる.

4. 推薦ページ影響実験

4.1 実験手順

これまでの研究[佐藤 18]で, 選出された推薦ページを提示することで, 読者の作品への関心にどのような影響を及ぼすかを検証してきたが, 本研究ではこの実験協力者の数を 20〜24 歳の学生 24 名(男性 19 名, 女性 5 名)に増やし, 実験を行った(以下, 評価者). なお, 評価者は 3 章で示した 16 作品のうちいずれも読んだことのない学生である.

実験では, 評価者を 12 人ずつのグループ A, B に, コミックを 8 作品ずつの作品群 α, β に分けた. 各作品群のコミックはジャンルごとの作品数が均等になるように分けている. グループ A の評価者には作品群 α の, グループ B の評価者には作品群 β の前半部のみをそれぞれ読んでもらった. また, 担当する作品群を全て読了した評価者に対し, 全て読了した日の翌日から評価実験を開始してもらった. 各作品について 1 ページずつ評価する作業を 3 日間で計 6 セット繰り返してもらった. これにより評価者は推薦ページを 96 シーン全て評価することとなる. 評価項目は以下の 4 つである.

- 作品はどの程度読みたくなったか
- 内容および展開はどの程度気になったか
- イラストはどの程度気になったか
- キャラクタはどの程度気になったか

これらの項目を-3(全く読みたくならない, 全く気にならない)〜+3(かなり読みたくなった, かなり気になった)の 7 段階のリッカート尺度で評価してもらった.

4.2 実験結果

評価実験の項目のうち, 読みたくなる度合いの平均値について図 9 に示す. 青色が前半の推薦ページ, オレンジ色が後半シーンについての評価値を表している. 作品を途中まで読んでもらった読者がつけた平均評価値(前半, 後半)を左側に, 作品を読んでいない読者のつけた平均評価値を右側に示している. また,「読書の有無」「前半, 後半シーンの提示」の 2 要因について二元配置分散分析を行い, 各要因に関して有意差が存在するか否かを記載した.

図9より, 前半部を読んでもらった読者に対しては, 前半シーンと比較して後半シーンの評価値が 1%有意で高くなっていることが分かる. 一方, 作品を読んでいない読者に関しては, 前半, 後半シーンの評価値の間に有意差は確認されなかった. この結果から, コミックを途中まで読んだ読者に対して未読のシーンを提示することは, 作品を読みたくさせるのに有効であるといえる.

また,「内容・展開」「キャラクタ」の項目についても「読みたくなる度合い」と同じ箇所に有意差が確認された. これも以前の実験と比較してほぼ同様の結果となっているが,「キャラクタ」の項目に関して, 読書あり条件の前半シーンの評価値が読書なし条件の前半シーンの評価値と比較して 1%有意で高い結果となった.

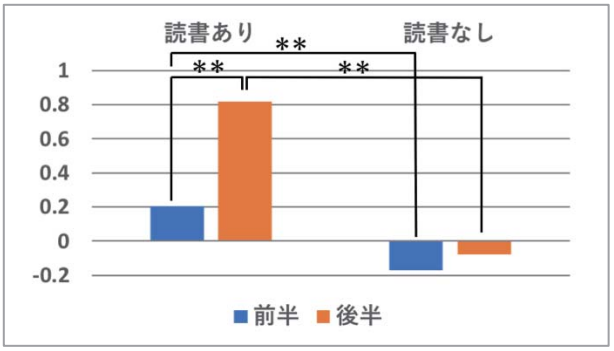


図 9 読みたくなる度合いに対する平均評価値

5. 考察

推薦ページのデータセット構築において好み度合いの分布を調べたところ, 作品によって推薦箇所が集中する場合と大きく散らばる場合の 2 つがあることが分かった. これは, コミックの作者が特定のシーンのみを強調して描いたことにより, 読者がそのシーンを面白いと感じた場合は, 推薦箇所が一点に集中しやすくなる一方で, 特にそのようなシーンが存在しなかった場合は, どのシーンが推薦されるかは読者の読み方や嗜好に委ねられるためだと考えられる. また, 推薦箇所の集中した図 1, 2 の作品はいずれもラブストーリーとして選定したものであった. つまり, 多くの読者が共通して面白さや魅力を感じるシーンがあるかどうかはジャンルによっても左右される可能性がある.

実際に推薦されたシーンの内容に着目すると, セリフの少ないシーンが推薦される傾向にあった. これは, 活字でのセリフを使用しない分, 手書きのセリフやイラストのみでシーンを表現することで, そのシーンを直前や直後のシーンより際立たせることが可能になるためと考えられる. また, ページを横断する大きなコマを持つ推薦ページも見受けられた. これは, ストーリーの展開上で重要とされる部分や, コミックの作者がキャラクタや世界観を強調したい部分というのは大きなコマを用いて描くことが多いためと考えられる.

さらに, 以前の評価実験から人数を増加して再分析した. その結果, 既読シーンが提示された場合でも, 作品を途中まで読んだ状態ならば, キャラクタへの関心が 1%有意で高くなっていた. このことから, 既読シーンであっても作品を読むことによってキャラクタへの愛着がわいていることが考えられる.

今回の実験で得られた結果は，コミックを購入して一部だけ読んで，そのまま死蔵してしまっているようなユーザに対し，未読シーンを広告などの形で提示することにより，コミックの読書意欲を増進させることも可能である．コミックを死蔵してしまうと，それ以降の巻数が購入されなくなってしまうため，作者や出版社にとっても損失が大きい．こうした状況において，ユーザの読書度合いを把握しつつ，死蔵をできるだけ発生させないような提示はとても重要であると考えられる．

6. おわりに

本研究では，コミックに関する Web 広告や推薦の効果を上昇させるため，以前の研究で構築した推薦ページデータセットに関して，推薦箇所の集中度合いやシーンの特徴についての傾向を分析した．また，読者の読み進めた量や，提示されたシーンが読者の既に読んだシーンか否かによって，読者のモチベーションにどう影響するかを明らかにする実験を，以前の研究からさらに人数を増やすことによって，より正確な分析を行った．

まず，推薦ページのデータセットについて，作品によって複数人の読者が同一の箇所を推薦する場合と，反対にそれぞれの読者が異なる箇所を推薦する場合の 2 つが存在することが分かった．また，実際に推薦されたシーンにはサイズの大きいコマが使われる傾向や，セリフが少ないという傾向があることも分かった．この知見は，コミックの推薦ページを人手ではなく，自動的に選出する際に有用であると考えている．

その後，既読および未読シーンの提示が読者の閲覧意欲にどのような影響を及ぼすかを読書実験にて検証した．その結果，コミックを途中まで読み進めた読者に対して未読部分のシーンを提示することは閲覧意欲を増幅させることが明らかになった．その要因として，作品の内容，展開やキャラクタに対する関心が高まっていることが示唆された．

本実験で扱うデータセットの構築にあたっては，複数人に作品を読んでもらい，好みのシーンを複数選出してもらう方法を用いた．しかし，シーンに含まれる情報を用いて膨大な量の作品から重要なシーンや魅力度の高いシーンを自動で選出することが必要となってくる．そこで今後の研究では，シーン選出およびデータセットの構築に関して，画像処理を用いた推薦ページの自動検出を行うことを検討している．一つは，3.2 節で触れたように，セリフの少なくなるページが推薦ページに多く見られたため，文字認識を用いて検出することを検討している．これにより，検出された文字数が前後のページに比べて急激に少なくなるシーンを推薦ページとして自動的に決定することが可能になると期待される．また，大きいコマを持つページが推薦ページとして選出されやすいことが分かっているため，直線検出を用いたコマ数の検出を検討している．コマ数が少ないほど 1 コマあたりの平均的なサイズは大きくなると考えられるため，これを推薦ページとして選出することが可能になると期待される．

さらに応用として，推薦に有効とされるページを Web 上の広告として表示することや，コミックサイトの各話のサムネイルとして推薦されたシーンを表示することなどを検討している．これにより，読者は日常生活で電子端末をあつかう中で未読シーンに触れる機会が増え，続きを読み始めることへのモチベーションを高めることが可能になると期待される．

謝辞

本研究の一部は，JST ACCEL（グラント番号 JPMJAC1602）の支援を受けたものである．

参考文献

[全国出版協会 17] 公益社団法人全国出版協会: 日本の出版統計，出版科学研究所，2017.

[ebookJapan 18] ebookJapan，2018.

[Leavitt 11] Leavitt，J． D．，Christenfeld，N． J．: Story Spoilers Don’t Spoil Stories，Psychological Science，2011.

[Maki 17] Yoshiki Maki，Satoshi Nakamura: Do Manga Spoilers Spoil Manga?，The Sixth Asian Conference on Information Systems，2017.

[佐藤 18] 佐藤剣太，牧良樹，中村聡史: 未読・既読シーンの提示がコミック読書意欲に与える影響，第 47 回エンタテインメントコンピューティング研究会，2018.

[山西 13] 山西良典，杉原健一郎，井上林太郎，松下光範: コミック読者の状態遷移に着目したソーシャルリーディングシステム「コマコミュ」，エンタテインメントコンピューティング 2013 論文集，2013.

[Plaisant 06] Plaisant，C.，Rose，J.，Yu，B.，Auvil，L.，Kirschenbaum，M. G.，Smith，M. N.，Clement，T and Lord，G.: Exploring erotics in Emily Dickinson’s correspondence with text mining and visual interfaces，Proc 6th ACM/IEEE-CS joint conference on Digital libraries，2006.

[村井 13] 村井聡一，牛尼剛聡: 電子化された小説の選別を支援する「立ち読み」インタフェース，情報処理学会論文誌，2013.

[Hinze 12] Hinze，A.，McKay，D.，Vanderschantz，N.，Timpany，C. and Cunningham，S. J.: Book selection behavior in the physical library: Implications for ebook collections，JDCL’12，2012.

[Matsui 15] Yusuke Matsui，Kota Ito，Yuji Aramaki，Toshihiko Yamasaka，Kiyoharu Aizawa: Sketch-based Manga Retrieval using Manga109 Dataset，arXiv，2015.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

既存の漫画に基づいた２コマ漫画の自律生成

Autonomous Generation of 2-panel Comics Based on Human-made Comics

迎山和司 *1
Kazushi Mukaiyama

*1公立はこだて未来大学
Future University Hakodate

This paper reports an AI has made 2-panel comics using rules of meta-information obtained from human-made 4-panel comics. The 4-panel comic consists of 4 panels, and each panel consists of characters, backgrounds, balloon texts, onomatopoeia, and cartoon marks. At the interesting point, we can restore a comic strip which was broken up into panels separately. This means that there is something about connecting in the panels. Then, this paper describes that the experiment to find such a connection rule and make a new story by combining selected panels. The analysis led the rules for dialogue and characters. As a result, the AI made stories up to 2 panels without collapse. This experiment indicated the effectiveness of abstracting different comics and creating new comics from common elements. In the future, this AI will be expected to try out not only 4-panel comics but also story comics using the similar method.

1. はじめに



図 1: 生成された２コマ漫画

本研究では，人工知能によって４コマ漫画を分析し，得られた特徴情報からルールを設定して２コマ漫画を作った．(図 1) すでに人間の作家によって描かれた複数の４コマ漫画から，登場人物とフキダシを特定し，その位置や内容を抽出した．そして性別と年齢が近い登場人物は同一人物として扱い，位置とセリフの対応を考慮して本来とは違うコマ同士を組み合わせた．

目的は人工知能が自律的に物語を作れることの可能性を確かめるためである．いまやコンピュータは芸術分野の様々なところで道具として利用されている．しかし，人間のように自律して行動するコンピュータつまり人工知能が芸術作品を作るようことは未だ少ない．[Cohen 79] ところが，2016 年には人工知能が書いた短編小説が文学賞の一次審査を通過するようになった．人間以外の存在が創造する物語が人間の鑑賞に耐えるものになっている証拠と言える．ただし，物語のあらすじに当たる部分はこの人工知能の作者によって初めから決められており完全に自律しているとは言えない．当初，この人工知能の作者はあらすじを既存の小説の切り貼りによって生成しようとしたが，単なる組み合わせだけではうまく行かなかった．一文ずつからでは大局的な文脈が抽出できないため，組み合わせれば組み合わせるほど物語の骨子が崩れてしまうのである．[Sato 16]

そこで本研究では，人工知能による物語の自律生成を実現するため，物語を形作る要素を文章だけに限らず，図像なども取り入れることを試した．情景描写を含めてすべてを文字で扱おうとすると特徴情報の抽出が複雑になる．しかし，絵を情景描写の記号として扱えば特徴情報が抽出しやすくなる．そのことで却って物語が作りやすくなるのではないかと考えたのである．

そもそもの大目標は人間の創作行為の本質を知ることである．したがって，人間のように外界を学習をする人工知能をモデル化することに注意した．学習型モデルの人工知能を用いて，コンピュータと人間を対比させると，人間の創作行為をコンピュータで置き換えられる部分と置き換えられない部分が明確になる．この違いを考察することは，人間の創作行為の本質を知ることにつながる．

人間の創作も，素材となる様々な情報を取り入れて，自分なりに消化しオリジナルの作品を作る．そこで物語の自律生成に対して，本研究では既存の漫画を分析することによって，新しい漫画の物語を作ることを試みた．おそろしく沢山の漫画を読んだ人工知能が漫画を作れるとしたら，それは人間と同じように創造したことになるのだろうか？

2. ４コマ漫画

図像と文字によって物語を表現する方法の一つに漫画がある．漫画は紙面をコマと呼ばれる枠線で分割し，その中に絵

連絡先: 迎山和司，公立はこだて未来大学，北海道函館市亀田中野町 116-2，kazushi@fun.ac.jp

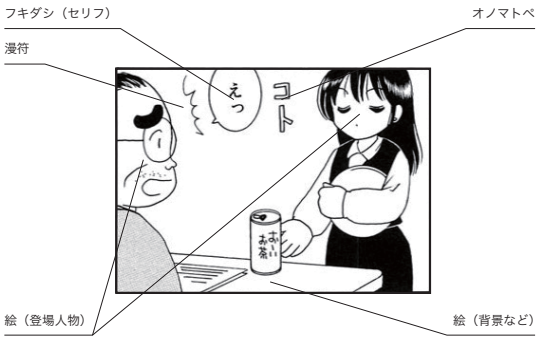


図 2: 4 コマ漫画の要素（©さんりようこ, Manga109）

（登場人物や背景）・フキダシ（セリフ）・オノマトペ・漫符などの要素を用いる．(図 2) これらの要素によって洗練された物語の表現ができるが，各要素は記号であり暗黙知による読み方のルールがあって特徴情報を把握しやすい．[Natsume 95] とりわけ 4 コマ漫画は構成要素が比較的単純なので分析が行いやすい．

3. 提案手法

3.1 分析



図 3: 4 コマ漫画の復元実験

4 コマ漫画は 4 つのコマで構成され，一つのコマは登場人物・背景・セリフ・オノマトペ・漫符の要素で構成される．興味深い点はコマの形は同じなのにコマをバラバラに分解されても読者は元に戻すことができることだ．そこで，読者はコマの中に描かれた登場人物・背景・セリフ・オノマトペ・漫符のうちの何を手がかりにしているかを確認した．(図 3) [Mukaiyama 14] 80 枚のカードから 4 コマ漫画を復元してもらい，終わった後に読者に何を手がかりにしたかを質問をした．その結果，登場人物や背景から同じ話にまとめた後，展開パターンやセリフで順番を決めていることがわかった．また，オノマトペや漫符は復元の手がかりにはほとんど使っていなかった．

3.2 方法

バラバラに分解されたコマから漫画を元に戻せるということは，コマとコマに何らかの物語のつながりがあるということである．作品から読者が得ることのできる情報は登場人物・背景・セリフ・オノマトペ・漫符の要素しかないので各要素同士につながりがある．当然，本来のコマ同士のつながりが最も強いものであるが，つながりにルールがあれば，他のコマでも近いつながりがあるかもしれない．そのようなつながりのルールを見つけて，さらに性別と年齢が近い登場人物は同一人物として扱い，選び出したコマ同士を組み合わせれば新しい物語ができると考えた．このような手法は小説の世界ではカットアップと呼ばれている．[Burroughs 99]

分析の結果から既存のコマの組み合わせて物語を作るルールを以下のように決めた．

- セリフに繋がりのあるコマ同士を見つける
- 登場人物の位置と大きさが近いコマ同士ををを見つける

漫画を復元する時に読者は最終的にはセリフを読んで物語を確認していた．したがって，違う物語でもセリフが自然につながって読めるコマの組み合わせを見つけることが重要である．4 コマ漫画の場合，背景は殆ど描かれないので登場人物のみを扱ってもほぼ問題ない．そして，登場人物の位置と大きさが揃うと図像として物語の破綻が少ないことがわかった．これは鈴木清順監督の映画のカット割りでよくみられる．[Suzuki 01]

セリフのつながりの特徴情報は会話分析の隣接ペア [Takagi 16] という概念を用いた．隣接ペアとは会話分析における行為連鎖の基本単位である．通常の会話は話者の順番交替によって進む．その際，発話は発言内容ではなく発言行為によって 2 話 1 組のペア（表 1）にまとめられるという主張に基づく．本研究では，すべての作品のフキダシを順序立てて特定して，セリフの内容から隣接ペアに該当するペアを特定した．これらの作業は自作編集プログラムを用いて手入力で行った．(図 4)

第一成分	第二成分
問い	答え
挨拶	挨拶
要請/招待	受諾/拒絶
苦情	否定/拒絶/同意
批判	否定/肯定
申込	受容/拒絶
	…など

表 1: 隣接ペア

登場人物の位置と大きさの特徴情報は，SVM による顔検出 [King 09] と 4 層畳み込みニューラルネットワークによる顔認識 [Lin 14] を用いた．その際，各登場人物の辞書を作り名前・年齢・性別の情報を付加した．ただし，誤検出率が高かったので，最終的には手作業で修正した．その他にも，描画のために顔の向き・表情などの特徴情報も顔認識によって付加した．以上の処理により XML 形式の特徴情報を抽出した．(図 5)

3.3 結果

素材となる漫画は，学術目的に公開されているデータセットのマンガ 109[Matsui 16] から 4 コマ漫画作品の「あくはむ (©新居さとし)」,「高校の人達 (©葛原兄)」,「OL ランチ (©さんりようこ)」を用いた．それぞれのコマ数は「あくはむ」では 560 コマ (140 話),「高校の人達」では 752 コマ (188 話),「OL ランチ」では 616 コマ (154 話) である．これらの合計 1928 コマから 88 コマを抽出し 44 話分の 2 コマ漫画を作成することができた．内 8 話が他作品同士の組み合わせである．(図 6) 描画は手作業で行った．ただし，抽象化された情報に基づいて描画したので，プログラムによる描画でも近い結果になると考える．(図 7)

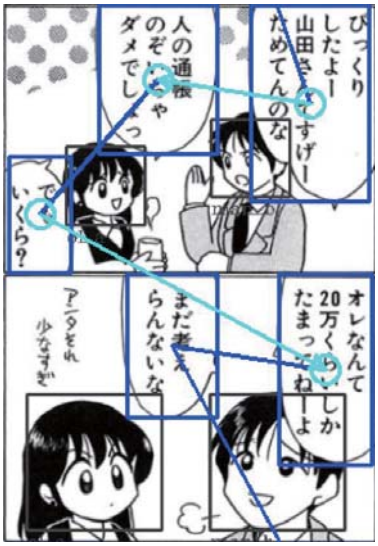


図 4: フキダシ順序（青）と隣接ペア（水色）（©さんりようこ, Manga109）

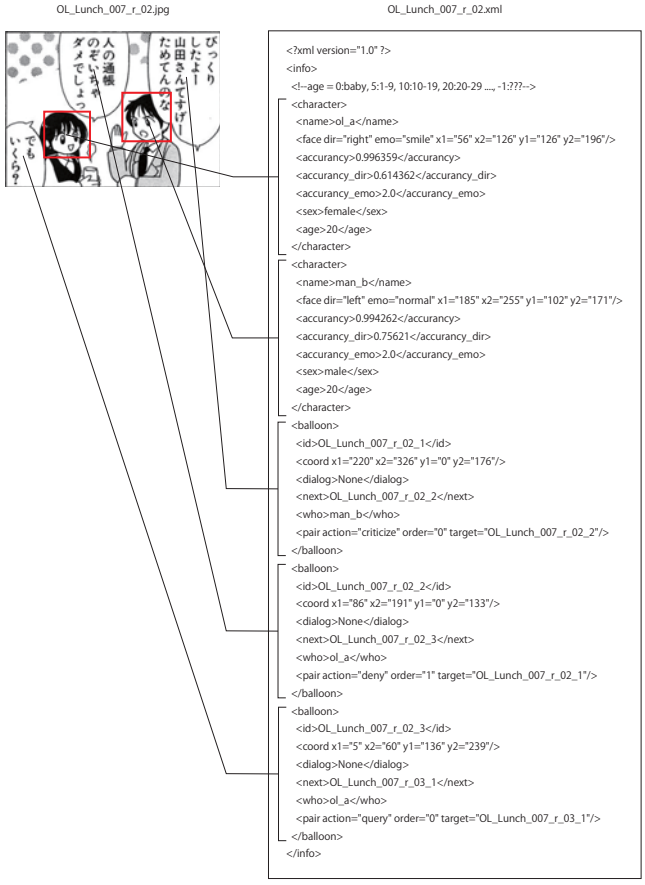


図 5: 特徴情報（©さんりようこ, Manga109）

4. 考察と展望

4.1 考察

今回は，作られた２コマ漫画作品を内容の面白さではなく物語として破綻していないかで評価したい．その意味では２コマまでであれば破綻なく物語が作れたと考える．本来であれば４コマの物語を作ることが望ましいが，その組み合わせは今のデータセットではほとんどみつからない．まず２コマで生成する場合，隣接ペアが１対１の対話であるので各成分がコマを跨いでいる必要がある．さらに，コマを増やす場合，中間のコマに対して前後のコマそれぞれが対応する隣接ペアを含んでいる必要がある．そのような中間につかえるセリフのあるコマはほとんどなかった．そもそも隣接ペアを機械学習などによって抽出する技術は現時点ではなく，完全な自律を求めたより長い物語づくりのためにはセリフの特徴情報抽出を別の手法で行う必要がある．

今回の分析から原則４コマ漫画とは登場人物の会話集であると認識した．そしてセリフを会話分析の手法に当てはめてみると，殆どの隣接ペアは１つのコマの中で収まっており，コマを飛び越えた会話は少ないことがわかった．また，当然ながらセリフのないコマもあった．このようなコマはどのコマにも組み合わせやすい．とするならば，むしろコマ単位で各要素を組み合わせることではなく，場面単位に各要素をまとめなおてコマを生成する方が柔軟な物語が作れるのではないかと考える．得られた特徴情報群は整理すれば登場人物達の会話する場面を舞台のように抽出できるだろう．

一方，人間の創作行為の本質を知るという視点において，本研究の人工知能が人間と同じように創造したかといえば，そうとはいえない．用意した既存作品の量がまだ少ないからである．とはいえ，他作品混合による物語を８つ作ることができた．したがって，あらゆる作品を抽象化して共通要素から新しい物語を作るという本手法の有効性は示せたと考える．

4.2 展望

電子書籍の発展に伴い，漫画はますますデジタル画像として保持されるだろう．それらの画像処理における領域分割や認識は今後益々活発になると思われる．そのように解析された特徴情報が充実していく将来を見通して，本研究は人工知能による物語生成の一つの手法を示した．今後は４コマ漫画にのみならずストーリー漫画でも要素を抽出して同様の手法で試したい．

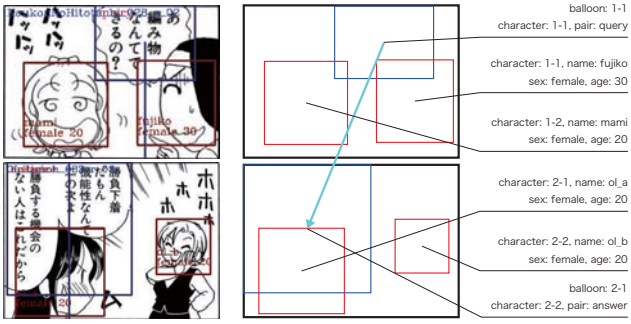


図 6: 抽象化されたコマ（©葛原兄, ©さんりようこ, Manga109）

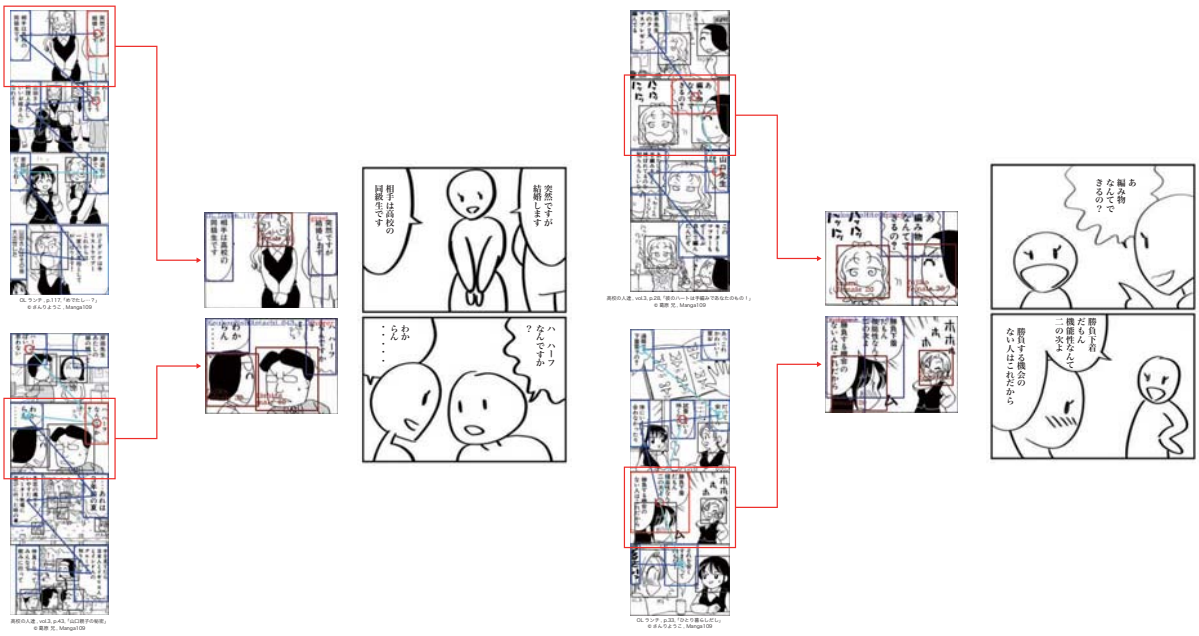


図 7: 結果（ⓒ新居さとし, ⓒ葛原兄, ⓒさんりようこ, Manga109）

5. 関連研究

5.1 きまぐれ人工知能プロジェクト作家ですのよ

松原らはショートショート作家の星新一の作品を基にして人工知能によって新作の小説をつくることを目指した．[Matsubara 13] ショートショートとは 400 字詰め原稿用紙 20 枚程度の短編小説である．本研究の成果はプロジェクトメンバーの佐藤によって 2016 年に新作を発表した．この新作は星新一賞という文学賞の一次審査を通過した．[Sato 16]

5.2 全自動４コマ

柳井は Web アプリとして 4 コマ漫画を自動生成するシステムを制作した．[Yanai 07] ブラウザ上でユーザーがキーワードを入力するとその言葉に関連する情報をネットから抽出しセリフにあてはめて物語を作る．このためセリフは多様性を持つが，絵は数点に限られているためできあがった漫画は同じ結果にみえる．

5.3 絵の時系列的状態遷移を用いた 2 コマ漫画の自動生成

上野らは 2 コマ漫画を生成するシステムを制作している．[Ueno 13] このシステムでは，ユーザーが 1 コマ目にさまざまなオブジェクトを配置すると，その情報に基づいて 2 コマ目を自動的に生成する．この時，ユーザーが扱えるオブジェクトはあらかじめ決められている．

参考文献

[Cohen 79] Cohen H.: What is an Image?, Invited paper, Proc. of the 6th International Joint Conference on Artificial Intelligence, Tokyo, (1979).

[Sato 16] 佐藤 理史: コンピュータが小説を書く日 —AI 作家に「賞」は取れるか, 日本経済新聞出版社, (2016).

[Natsume 95] 夏目 房之介, 他: マンガの読み方 (別冊宝島 EX) , 宝島社, (1995).

[Mukaiyama 14] 迎山和司: 4 コマ漫画の復元行為からみる文脈情報の考察, HCG シンポジウム 2014, 電子情報通信学会, (2014).

[Burroughs 99] Burroughs W. S.: The Naked Lunch, Limes Verlag, (1999).

[Suzuki 01] 鈴木 清順: ピストルオペラ, 松竹映画, (2001).

[Takagi 16] 高木 智世, 細田 由利, 森田 笑, 会話分析の基礎, ひつじ書房, (2016).

[King 09] King D. E.: Dlib-ml: A Machine Learning Toolkit. Journal of Machine Learning Research 10, pp. 1755-1758, (2009).

[Lin 14] Lin M., Chen Q., Yan S., Network in network, In-Proc. ICLR, (2014).

[Matsui 16] Matsui Y., Ito K., Aramaki Y., Fujimoto A., Ogawa T., Yamasaki T., Aizawa K., Sketch-based Manga Retrieval using Manga109 Dataset, Multimedia Tools and Applications, Springer, (2016).

[Matsubara 13] 松原 仁, 佐藤 理史, 赤石 美奈, 角 薫, 迎山 和司, 中島 秀之, 瀬名 秀明, 村井 源, 大塚 裕子: コンピュータに星新一のようなショートショートを創作させる試み, 第 27 回人工知能学会全国大会, (2013).

[Yanai 07] 柳井 政和: 全自動 4 コマ, http://crocro.com/auto4koma/, クロノス・クラウン, (2007).

[Ueno 13] 上野 未貴, 森 直樹, 松本 啓之亮: 絵の時系列的状態遷移を用いた 2 コマ漫画の自動生成, HCG シンポジウム 2013, 電子情報通信学会, (2013).

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

“AI 会話”技術の確立に向けた、共感関係の要素と関係シナリオ

Toward a Network Analysis of
Empathic and Exciting AI Conversation and Scenario

安田　雪[*1]
Yasuda Yuki

[*1] 関西大学
Kansai University Dept. of Sociology #1

The purpose of this paper is to specify the characteristics of empathic and exciting conversation from the texts of a cartoon, called “ ONE PIECE.”(ODA, 1997-2018) . My purpose is to build a base for AI conversation system which can understand human nature of empathy based on social networks. “ONE PIECE” is one of the best seller comics for young boys worldwide and is full of empathic and moving conversations among heroes. Using the conversation data, I try to extract the networks among heroes, human rules and emotional logics driving readers’ mind in order to build theories for empathic AI conversation.

1. 漫画からの共感と感動の抽出

本報告の目的は、なぜ、人工知能やロボットとの会話、携帯電話あるいは、コンピュータに組み込まれたソフトウェアとの会話に、共感や感動が生じないのかという問題意識の下に、共感や感動を呼び起こすシナリオに基づいた会話と筆者が定義する“AI 会話”技術の構築にむけての考察を、漫画『ONE　PIECE』の会話とシナリオを事例して行うことである。本論考は、大ヒット漫画のテキストを事例とした探索的な分析と考察に基づいた AI 会話についての開発ニーズと提案を目的としており、仮説検証型の実証研究ではない。

現在、様々な対話ロボットや会話機能をもつ家電製品の開発競争が展開している。一般的に携帯電話とともに普及している Siri との対話についても、最低限の音声認識技術と相対的な発展の程度は評価できても、実際にそれが「会話として快適である」あるいは「対話の相手に共感する」、さらには対話によって「感動をする」「癒やされる」「心が和む」にはほど遠い状態にとどまっている。

高齢化と過疎化する地域問題が象徴するように、超高速な人口減少が進む我が国においては、これまでの人間が行っていた保育、教育、介護、接待、接客などをはじめとする、多くの社会的相互作用を機械が代替するようになることは自明である。スタンデージ[スタンデージ 11]が描いたチェス差しロボットは感動への初期の形態にすぎない。そのためには、社会的相互作用の基礎となる、優れた会話のできる対話型ロボットや、ソフトウェアの開発は喫緊の課題である。西田[西田 12]が次の AI への課題として論じている、他者の問題に対する認知と理解、AI 側の失敗の許容、君と呼んでもらえるパートナーシップの確立など、対話技術に対する課題の多くが今なお解決されていない。企業のマーケティング材料となるビッグデータと呼ばれる解析向けのデータを収集する技術は会話データも含めて今後も向上し続けるが、それらを用いたユーザの感情や社会的文脈を理解した社会的相互作用を可能とする会話技術の確立は今後の課題であると考えられる。ここで、優れた信頼にもとづく社会的インタラクションを可能にし、共感や場合によっては相手に感動をもたらすような音声認識と発話を連続させられる会話技術の総称を、“AI 会話”と定義する。

目的が明らかで文脈が限定された質問、たとえば現在の日経平均はいくらか、今は何時か、や、天気予報といった事実に関する質問についていえば、比較的、安定的な対話機能が実装された機械も増加している。一方で、ゲーム内の登場キャラクターとの対話による共感や感動、ブレイドランナーのような SF 映画の世界におけるロボットとの共生への共感、メディア上でのソフトウェアやハードウェアを通じた感動は既に生じてもいる。

人工知能は記憶量と、その記憶に基づいた目的関数の最大化のための可能性の計算と判断という意味では確かに知能であろうが、1 歳の子供がその親や家族にもたらす共感や感動、そのインタラクションを、意図的であれ非意図的であれ、会話や対話を通して届けることは現時点ではきわめて不可能に近い。

AI 会話の共感力や人間性は、開発者の人間のそれと、人間観を反映する。会話のボキャブラリーと、社会的文脈、さらには人間関係への認知能力をも反映する。なぜなら、現実社会における人間の対話力は、それらに依存しているからである。

本報告では、世界的にヒットした漫画と作者の解説文章を題材に、そこにみられる典型的な感動や共感を呼ぶ会話のパターン、シナリオ（ものがたりの展開）、登場人物の相互関係のタイポロジー、作者が持つ人間観と世界観の抽出を試みる。そのうえで、AI 会話の基盤として実装されるべき、人間の信頼関係形成へ文脈に関わる関係認知の重要さを[安田　10]を論じる。

漫画のテキスト分析は、従来、メディア研究者によるアナログな、いわゆる人文学的な、反証可能性をもたない解釈を基盤とするアプローチにも基づいたメディア文化研究[金　2014]や、同性愛者や性的マイノリティなどの立場を政治的コレクトネスから論じる研究 [守 11]などが多数行われているが、これらの研究においては、「自動化」や AI との共感、対話支援や物語構築といった創造的活動への支援やエンジニアリング的な問題解決をめざすという試みはなされてこなかった。二次元の女性キャラクターを活用した創造的活動と協調行動は初音ミクの研究に顕著であるが、これらの創造的活動研究と、メディアスタディを中心とした漫画研究にはいまだ大きな乖離、すなわち連携の可能性があると考えられる。

2. 『ONE　PIECE』という言論空間の分析

2.1 データと探索的分析

本研究が対象とするのは、集英社から出版されている週刊少年漫画雑誌ジャンプに連載されている、少年漫画品『ONE PIECE』である。『ONE PIECE』は、1917 年に連載が開始され今年連載 20 年を迎える。長寿漫画であり世代や文化を超えた読者をもつことから、国民的漫画と位置づけられる。

「海賊王」をめざす主人公を中心とした 8 人の仲間が、それぞれの夢をめざしてともに航海をするという冒険と成長の物語である。登場人物は非現実的な身体能力をもち、超能力を発揮する。背景となる航海の状況も超自然的、非現実的に構成されている。主人公と仲間の共感という、複数の登場人物から連なる二次、三次以降の仲間の連帯が人間関係の基礎となっている。

日本国内の単行本の売り上げ累計数は 2017 年時点で 3 億 6 千万部を超え、二世代を超える読者層をもつ、歌舞伎の題材としてもとりあげられ舞台化されるなど、漫画オタクや少年だけに偏らず、多世代、多様な人々からの共感と評価を得ている。

この間、主人公らの関係は多元的に成長していく。

およそ非現実的な設定や主人公の能力を背景とした漫画がひろく大衆に好感をもって受け入れられるためには、登場人物の台詞、行動および人間関係が、架空の世界の物語であれ、現実社会において読者が立ち向かう困難、辛さや悲しみとともに、喜びやうれしさなどの情動をつきうごかす力、支援と希望を感じるような、感動や共感をもたらす要素とその関係をもつことが不可欠である。

共感や感動の要素をミクロとマクロのレベルに分解すると、ミクロレベルとは連載一回ごとに毎週簡潔する連載漫画内でくりひろげられる、ストーリーと登場人物の会話であり、マクロレベルとは、長期間の読者をかけて埋め込まれる要素、すなわち社会的文脈であり、人間関係と伏線の作り込みと変化である。社会的相互作用に特価した考察を行うため、ここでは、文字テキスト意外の要素については扱わず、会話や対話とその背景となる社会的関係に特価する。

この漫画を考察し、共感や感動を呼ぶ要素の類型化と一般化を行うことは、AI 会話の共感力向上に資することは可能だと考えられる。目的は、この一般化に基づいた、AI による感動を人間に呼び起こす会話技術の構築、さらにはロボットが人間に共感と感動をもたらす会話技術を習得するための基礎理論の構築である。共感と感動をもたらした漫画のテキスト要素とシナリオ構造を類型化することで、感動や共感をよびうる AI による会話の基礎情報を理論化する。

社会的文脈を理解する AI には、シナリオや物語の構築にかかわるパターンデータを AI 技術が持つ必要性がある。そのために感動と共感を呼ぶ漫画作品からパターンや典型的な会話を抽出し、それらを基礎とした技術の実装と開発を呼びかけたい。

漫画の論拠となる場面と会話の直接引用は著作権の関係で紙面では省略するが、報告当日は、作品の箇所を同定する。同作品の第 88 巻までを通じてくりかえし描かれ、読者に感動や共感をもたらすパターンとして提示される会話とその社会的文脈に関する仮説の一部を、以下にあげる。

(1)自己犠牲(または愛情)の連鎖仮説説

関係の推移性の重要さである。一対一の会話の場合でも、相手の背後につらなる社会的関係を察知ないし、(事実として把握し)、それを包含した発話をすることで、愛情、友情が連鎖し相手からの共感が得やすくなる。自己犠牲となった存在の理解とその記憶は、他者への共感と信頼力をもたらす。

(2)喪失の代償理論

現時点の情報だけではなく、過去の幸福の記憶や幸せの記憶を想起させることが、相手の幸福感と満足、理解度を増す。人々の記憶のうちでも悲しみや、喪失、事故といった辛い記憶についても、それらを失った今でも残っているもの、および、それらの記憶の美しい部分を固定化し、結晶化させることで、相手の過去を肯定し、他者を責めることのない対話が可能になる。喪失の代償として記憶を肯定し、現在から希望を生む会話により記憶が活性化し、共感を生む会話が可能になる。これは大武の共想法理論[大竹 2015]とも適合的である。

(3)当然の下方設定理論

人が他人や親しい人に対してなすべき義務と感じる行為、あるいは他者への義務と感じる行動には一定の範囲がある。これを前提、当然とせず、相手からみればそれは多分に負荷のかかる行動をも、「あたりまえだ」と言い切ることで、共感能力は圧倒的にあがる。何を社会的な規範にもとづく義務とするかの想定は人によりことなるが、これを、社会的通念よりも下方に設定し、相手だからこそ「当然だ」とすることで相手からの感謝と感動が導かれる。さらには、利害関係が無い限りにおいて、周囲の人からの共感獲得につながりやすい。

(4)愛故の危機理論

会話においては負の文脈の理解も不可欠である。相手を思うが故にその相手を傷つけ事故を起こす、あるいは死傷につながるような発話と会話が発生しうる。ロミオとジュリエットをはじめとする大多数の古典的悲劇は、愛情をもつ者同士がその愛情故に傷つき合い死に至るというパターンをとる。こういったことを避けるためにも過剰な愛情表現ではなく、他者を守ることに徹し、地理的に分散し物理的に見えない他者にも安心を与えられる会話構築力が重要である。

(5)負の感情の否定理論

恨みや怒りという負の感情にとらわれずにいる自制力が共感の獲得につながる。

3. 結論

事例から複数の理論(的仮説)を導いたが、それらの仮説に共通するのは関係の推移性の理解、社会的文脈の理解の重要性である。『ONE PIECE』という作品を通じて、得られるのは、関係の推移性(Transitivity)の重要性である。ダイアローグからモノローグへ、さらには三者関係以上の関係を推定してのソシオローグこそが、二人きりの対話においても切実な共感を呼ぶ要素である。これらを鍵とした AI 会話ロボットの実現が必要である。課題としては、以上で提案した共感を呼ぶ AI 会話のための仮説に基づいた文脈の設定と、自然言語処理、会話処理技術による実装研究を共同で行う研究者ないしチームメンバーを構成して、着実に実装とその評価の実験を行っていきたい。

参考文献

[大竹 12]大武美保子:介護に役立つ共想法, 中央法規出版.

[尾田 97～18]尾田栄一郎:ONE PIECE 第 1 巻～88 巻, 集英社 ,1998～2018.

[金 14]金俊壌 米村 みゆき(訳): イメージの帝国 : 日本列島上のアニメーション, 専修国文 (94):2014.1 p.119-146.

[スタンデージ 11] トム・スタンデージ:謎のチェス指し人形「ターク」服部桂訳,NTT 出版,2011 年.

[西田 12]西田豊昭:人工知能研究半世紀の歩みと今後の課題, 情報管理,55 巻 (2012) 7 号 p. 461-471.

[守 11] 守如子:マンガ表現学の視点からみたやおい:『ユリイカ』,vol.44-15,青土社,2012 年.

[安田 10]安田雪:パーソナルネットワーク,新曜社,2010.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

日本語オノマトペから中国語オノマトペへの機械翻訳の提案

A Proposal of Machine Translation from Japanese to Chinese Onomatopoeias

YANG KAI [*1] YANG KAI
中村剛士[*1] Tsuyoshi Nakamura
加納政芳[*2] Masayoshi Kanoh
山田晃嗣[*3] Koji Yamada

[*1] 名古屋工業大学 Nagoya Institute of Technology
[*2] 中京大学 Chukyo University
[*3] 情報科学芸術大学院大学 Institute of Advanced Media Arts and Sciences

We can see many onomatopoeias in Japanese comics. Besides that, new onomatopoeic words are created and appear in the comics day by day. The new onomatopoeias aren't found on Japanese dictionaries. Hence it is difficult for Chinese people to understand the onomatopoeias' meaning or impression. This paper proposed machine translation from Japanese to Chinese onomatopoeias. The proposal is based on sound symbolism hypothesis. We are currently constructing the translation system. The paper reported components of the system and discussed the feasibility of the system.

1. はじめに

日常の様々な状況において，日本人はオノマトペをよく用いる．オノマトペとは，「擬音語」と「擬態語」を包括的に指した言葉である．中国語にもオノマトペは存在しているが，総数は日本語オノマトペの方が多く，生活の中で用いる頻度も日本語オノマトペほど多くない．一方，日本の小説やコミックの作者が，自由に文字を並べ，新しいオノマトペを造語することが多々ある．翻訳者にとって，造語された日本語オノマトペを適切な中国語に翻訳することは難しい課題の一つである．図 1 に，漫画の日中オノマトペの相互翻訳例を示す．オノマトペの翻訳については，日本語学習支援として，教材化や意味・イメージ推定等について，いくつかの報告があるが[市岡 09, 三上 06, 土屋 12, Doizaki 17]，コミック上に現れる日本語オノマトペは，中国語オノマトペに直接変換して表現することがコミック上の表現として望まれる．しかしながら，この翻訳は，存在しない中国語オノマトペを造語する作業と同等であり，元の日本語オノマトペの持つ意味を損なわず，表現として適切な造語をすることは困難な課題の一つである．

オノマトペには，音韻象徴または音象徴と呼ばれる仮説が存在する[三上 06], [Doizaki 17]．音象徴とは，音そのものが特定のイメージを喚起する事象を表す一種の共感覚とされる．音象徴仮説が支持されるとすれば，音響的に類似した音は類似したイメージを喚起すると考えられる．そこで，我々は，意味的に対応する日中オノマトペを音響特徴量によって定量化する．また，その対応を機械学習によって汎化することで，未知の造語オノマトペを適切に翻訳可能な日中オノマトペ間の機械翻訳が実現できるのではないかと考える．

本研究では，擬音語を対象として，日本語オノマトペから中国語オノマトペへの直接的な翻訳を目指す．オノマトペの定量化には音響特徴量であるメル周波数ケプストラム係数(MFCC)を採用し，ニューラルネットワーク(NN)によって日中オノマトペ間の関係を構築する．本稿では，郭ら[郭 12]が示す日中オノマトペ間の相互翻訳に基づいて，日中オノマトペの MFCC 特徴量間の対応を学習するものとした．

本報告では，翻訳システムの提案とシステム構成要素の一部について実現可能性を示す．

連絡先：YANGKAI，名古屋工業大学,yangkai@ai.nitech.ac.jp



図 1: コミックにおけるオノマトペ(左：日本語，右：中国語)

2. システム構成

本研究の処理の流れを図 2 に示す．まず，ユーザの発話した日本語オノマトペは，MFCC 特徴量に変換される．次に，日本語オノマトペの MFCC 特徴量から意味の大分類を行う．今回の大分類は，「自然」・「人間」・「事物」の 3 種とした．この分類については，日本語オノマトペ辞典[小野 07]の意味分類に従った．意味分類処理によって三つの分類のいずれかに分類された MFCC 特徴量は，各分類の日中 MFCC 変換処理によって，中国語オノマトペの MFCC 特徴量に変換される．さらに，その中国語オノマトペの MFCC 特徴量を用いて中国語オノマトペデータベースと照合し，MFCC 特徴量空間において最近傍の中国語オノマトペを出力する．

図 2 における意味分類及び日中 MFCC 変換については，NN によって構成した．各 NN の学習に用いたデータセットとして，日本語オノマトペ音声とそれに意味的に対応する中国語のオノマトペ音声を用意した．日本語音声は音声合成システム Open Jtalk[Lee 13]を用いて作成し．中国語オノマトペの音声は BaiDu 音声合成システム[Socher 02]を用いて作成した．

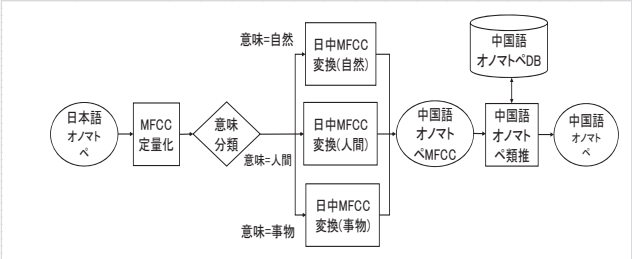


図 2: システム概要

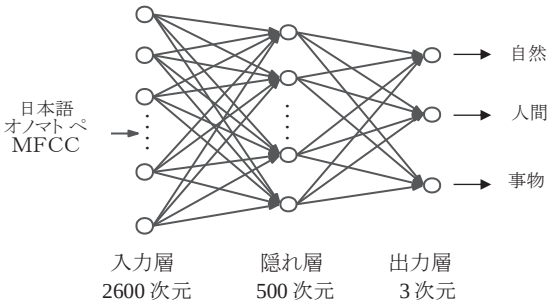


図 3: 日本語オノマトペの意味分類

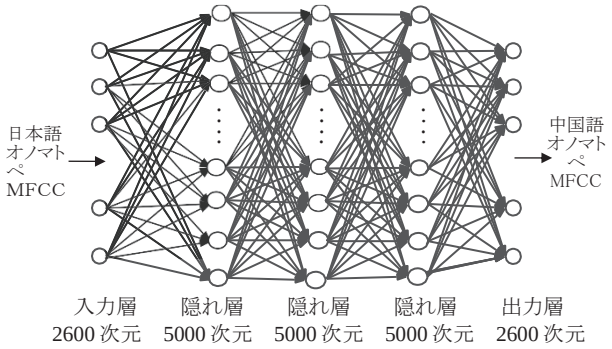


図4: 日本語オノマトペMFCCから中国語オノマトペMFCCへの変換

図 3 に，日本語オノマトペの意味分類を構成する NN を示す．NN の構造は入力層が 2,600 ノード，隠れ層が 500 ノード，出力層が 3 ノードで構成され，3 クラス分類を行う．3 クラスは，「自然」，「人間」，「事物」である．この分類は，この後の処理である日中 MFCC 変換の NN を比較的複雑化しない構造とすることができる．すなわち，各日中 MFCC 変換で扱うデータを分類によってある程度限定することで，NN の学習を容易にし，その結果，適切な変換の実現が期待される．

図 4 は，日中 MFCC 変換を構成する NN を示す．この NN は日本語オノマトペの MFCC と中国語オノマトペの MFCC 間の対応を学習した結果を利用して構築した．MFCC の次元数は 2,600 次元とした．入力出力層が 2,600 ノード，隠れ層が 3 層で，各層 5,000 ノードである．

3. 日中オノマトペのデータセット

本実験では，図 2 に示すとおり，日本語オノマトペの意味分類と日中 MFCC 変換において NN を採用した．日中擬声語・擬態語辞典[郭 12]の擬音語の相互翻訳について，意味的に対応する日中オノマトペを抽出し学習データセットとした．また，日本語オノマトペ辞典[小野 07]の分類に基づいて，その学習データセットを「自然」・「人間」・「事物」の 3 クラスに分けた．表 1-3 に日本語オノマトペとそれに対応する中国語オノマトペを示す．これらのオノマトペを各音声合成器で発話させデータセットを構成した．

なお，表 1-3 に示した日本語オノマトペと中国語オノマトペの対応を見ると，一対多対応となっているオノマトペがある．そのため，オノマトペ数は日本語と中国語間で異なる．今回のデータセットにおいては，中国語オノマトペの総数は 123 である．

連絡先：YANGKAI，名古屋工業大学,yangkai@ai.nitech.ac.jp

表1: 日中オノマトペ(自然)

分類名	日本語オノマトペ	中国語オノマトペ	日本語オノマトペ	中国語オノマトペ
自然	ざあざあ	哗哗	どぶどぶ	咕嘟咕嘟
	さやさや	沙沙	どぶん	扑通
	すーすー	咝咝	どぼん	扑通
	チクタク	滴答滴答	ぱしゃぱしゃ	啪嚓啪嚓
	どろどろ	隆隆	ぱしゃん	啪嗒
	ばさばさ	沙沙	ぱちゃぱちゃ	噼啪噼啪
	ひゅーっ	嗖嗖	ぴちぴち	泼刺泼刺
	ひゅーひゅー	呼呼	ぴちゃっ	啪嚓
	がばがば	哗啦哗啦	ぶくぶく	咕咚
	がぶがぶ	咕嘟咕嘟	ぶくぶく	噗嗤噗嗤
	がぼっ	哗	ぶつぶつ	哗哗
	ごぼ	咕嘟	ぺたぺた	吧嗒吧嗒
	ごぼごぼ	咕嘟咕嘟	ぼこぼこ	噗噗
	じゃーじゃー	哗哗	ぼちゃぼちゃ	啪嗒啪嗒
	じゃぶじゃぶ	哗啦哗啦	さくさく	刷刷
	ちゃぽちゃぽ	空隆空隆	ささっ	刷刷
	どーどー	哗哗	ざんぶり	扑腾
	どくどく	咕嘟咕嘟	しゅるしゅる	嗖嗖
	とくとく	咕嘟咕嘟	すっく	腾
	どしゃどしゃ	哗哗	つるっ	哧溜

表2: 日中オノマトペ(人間)

分類名	日本語オノマトペ	中国語オノマトペ	日本語オノマトペ	中国語オノマトペ
人間	しゃりしゃり	嚓嚓	がりがり	嘎吱嘎吱
	すたすた	哒哒	ぐい	咕嘟
	ぱかぱか	嗒嗒	ぐいぐい	咕嘟咕嘟
	ぱたぱた	吧嗒吧嗒	ぐー	咕
	ぼっくり	嘎	くしゃくしゃ	吧唧吧唧
	おぎゃー	呱呱	ぐちゃぐちゃ	吧唧吧唧
	かーかー	哑哑	ごくごく	咕噜咕噜
	がやがや	哇啦哇啦	ごくり	咕嘟
	ぎくっ	啊	こりこり	咯吱咯吱
	げー	哇	ごりごり	嘎吱嘎吱
	ごぼんごぼん	喀喀	ずるずる	哗溜哗溜
	ごろごろ	咕噜咕噜	ぼりぼり	喀啦喀啦
	ざわざわ	沙沙	ぼりぼり	喀啦喀啦
	はっ	哎呀	おいおい	呜呜
	ふんふん	嗯嗯	ぎゃーぎゃー	呱呱
	ぺーぺー	呸呸	ぴーぴー	哇哇
	むしゃむしゃ	啊呜啊呜	ぼーっ	呜
	むにゃむにゃ	呜噜呜噜	ぼーぼー	呜呜
	わっ	哇	わーわー	哇哇
	わやわや	呱啦呱啦	うふふ	嘤嗤
	ぐうぐう	呼呼	くすくす	咯咯
	くーくー	咕咕	はっはっ	哈哈
	ごー	呼噜	へーへー	嘿嘿
	ふーふー	呼呼		

4. 意味分類と日中 MFCC 変換

4.1 意味分類の学習

図3に示すNNに対して表1-3のデータセットを用いた意味分類の学習を行った．図5,6はそれぞれ正答率と損失の学習過程を示す．図5に示したとおり，正答率が0.999と高い正答率に収束していることが分かる．また，損失についても図6に示すとおり，0.002に収束しており，表1-3のデータセットを用いた分類学習が適切に行われたのではないかと考えられる．

表1-3に示す既存オノマトペの意味分類がある程度可能なことが図5,6の結果から推測できる．そこで，今回の学習に採用しなかった未知オノマトペを用いて評価実験を行った．未知オノマトペは，「からん」，「がらっ」，「がらーん」，「きしきし」，「きゅっきゅっ」，「きりっ」，「ころころ」，「するする」，「どしどし」，「どんどん」の10語である．意味分類NNの三つの出力ノード(「自然」・「人間」・「事物」)が出力した値を表4に示す．2列から4列の下線指定した値が，各未知オノマトペが属する正クラスにおける出力値を示す．例えば，一行目の「がらっ」正クラスは「自然」であり，その出力値は0.728である．

表3: 日中オノマトペ(事物)

分類名	日本語オノマトペ	中国語オノマトペ	日本語オノマトペ	中国語オノマトペ
事物	がーがー	呱呱	はたはた	哗啦哗啦
	かっこー	布谷	ばちばち	咔嚓咔嚓
	ゲロゲロ	呱呱	ばちん	咔嚓
	こけこっこー	喔喔喔	ばんばん	叭叭
	ちゅんちゅん	啾啾	びしっ	咔吧
	にゃあにゃあ	喵喵	びしびし	噼噼啪啪
	ぴよぴよ	啾啾	びしゃびしゃ	啪啪
	ひんひん	咴咴	ぴたぴた	啪嗒啪嗒
	ブンブン	嗡嗡	ぼかぼか	噼噼啪啪
	めえめえ	咩咩	ぼくぼく	笃笃
	もうもう	哞哞	かしゃっ	咔嚓
	りんりん	唧唧	かたっ	咯嗒
	ワンワン	汪汪	がちがち	咯嗒咯嗒
	がらん	哐当	かちっ	咔嚓
	かんかん	当当	がちゃがちゃ	咔嚓咔嚓
	がんがん	铛铛	ガチャン	喀嚓
	がん	咣当	かちんかちん	叮叮当当
	こんこん	咚咚	かちん	咯当
	じゃんじゃん	锵锵	かっぽかっぽ	嗒嗒
	ちゃんちゃん	叮叮咚咚	からから	啪嗒啪嗒
	ちりちり	丁零丁零	ガラガラ	嘎啦嘎啦
	ちりんちりん	叮当	からり	咔
	どん	咚	がらり	哗啦
	とんとん	噔噔	ごーん	当
	ばしっ	吧	ごつっ	嘣
	しゃんしゃん	叮当	ぽきぽき	喀吧喀吧
	ちゃかちゃか	咔哒咔哒	ぽきり	嘎巴
	ちゃりん	叮铃	ぽっきり	咔嚓
	どー	嘣	めりめり	咔嚓咔嚓
	どたっ	咚	がったり	啪嗒
	ドタドタ	咚咚	ずしずし	嘣嘣
	ぼこっ	噗	ちゃぽん	扑通
	ごーごー	轰隆轰隆	どしっ	嘣
	コトッコトッ	砰砰	どしん	扑通
	しゃかしゃか	嚓嚓	どすん	咚
	じりじり	叮铃铃	どっさり	啪嗒
	ずずん	轰隆	ぼちゃっ	哗
	ずどん	砰	かさこそ	沙沙
	だだだだっ	哒哒哒	ぎーぎー	咯吱咯吱
	だっだっ	突突	ぎしぎし	嘎吱嘎吱
	どかん	轰隆隆	きゅーきゅー	咯吱咯吱
	どんちゃん	咚锵咚锵	ぎゅーぎゅー	嘎吱嘎吱
	ばーん	砰	きりきり	吱吱
	ぴゅんぴゅん	嗖嗖	ごしごし	喀哧喀哧
	ぶーぶー	嘟嘟	さらさら	飒飒
	かりかり	咯吱咯吱	ジャラジャラ	叮叮当当
	ざくざく	嚓嚓	ぞりぞり	唰唰
	ちょきちょき	喀嚓喀嚓	ばりばり	咯吱咯吱
	ぱりぱり	哧啦哧啦	みしみし	咯吱咯吱
	びりびり	刺啦刺啦	めきめき	吱吱
	じゅうじゅう	吱吱	じーじー	吱吱

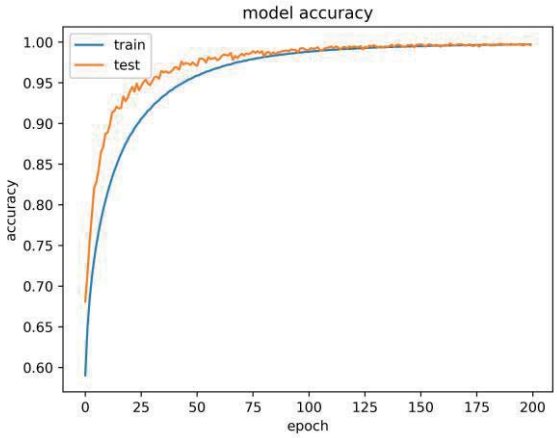


図 5: 意味分類の正答率

表 4 に示した出力値を確率分布と解釈した時, 正クラスで最大確率を取ることが望ましい. しかしながら, 表 4 が示すとおり, 10 語の未知オノマトペのうち半数において正クラスで最大値を取っていないことが分かる.

連絡先:YANGKAI, 名古屋工業大学,yangkai@ai.nitech.ac.jp

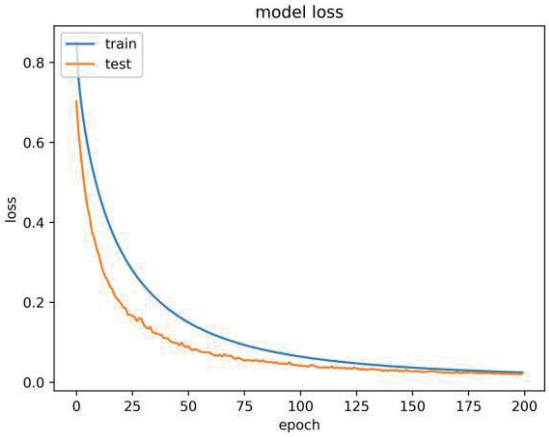


図 6: 意味分類の損

表 4 : 未知オノマトペの意味分類結果

未知データ	自然	人間	事物
がらっ (自然)	0.728	0.272	0.000
ころころ (人間)	0.811	0.004	0.185
からん (事物)	0.071	0.890	0.039
がらーん (事物)	0.014	0.361	0.625
きしきし (事物)	0.818	0.000	0.182
きゅっきゅっ(事物)	0.000	0.000	1.000
きりっ (事物)	0.005	0.994	0.001
するする (事物)	0.848	0.096	0.057
どしどし (事物)	0.000	0.000	1.000
どんどん (事物)	0.000	0.045	0.955

4.2 日中 MFCC 変換の学習

図2に示した各日中MFCC変換は, それぞれ図3に示すNNによって構成される. ここでは, 表1-3に示すデータセットを用いて, 各NNの学習を行った. 図7-9に各意味クラスにおける損失の学習過程を示す. 各損失は500epochにおいてほぼ0に近い値に収束していることが分かる.

5. 考察

本稿では, 図2に示したシステム構成の要素である図3, 4のNNの学習について実験結果を示した. 学習過程から各NNの学習は適切に行われていると思われる. 表4に示した未知オノマトペの意味分類結果は, 半分だけが正しく分類できたという結

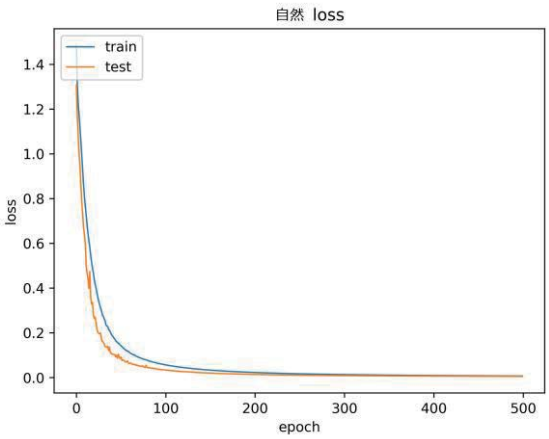


図7: 日中MFCC変換の損失(自然)

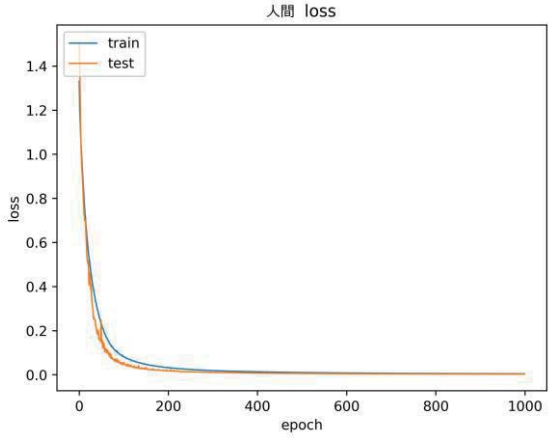


図8: 日中MFCC変換の損失(人間)

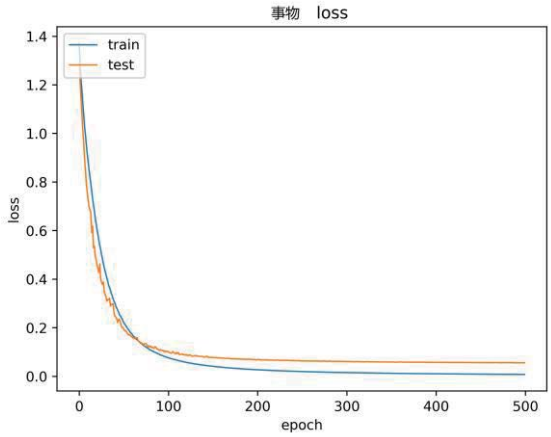


図 9: 日中 MFCC 変換の損失(事物)

果であったが，評価に用いた未知オノマトペの絶対数が少ないことから，十分な考察をするには至っていない．

また，図2の重要な構成要素である中国語オノマトペ類推については検討段階である．日中オノマトペMFCC変換から出力されたMFCCを用いて，中国語オノマトペデータベースから適当な中国語オノマトペを検索する必要がある．同時に，充実した中国語オノマトペデータベースの構築も必要である．

6. まとめ

本稿では，日本語オノマトペから中国語オノマトペに変換する機械翻訳を提案した．システム全体を構築するまでには至っていないが，重要な構成要素については，実験によって実現の可能性を示すことができた．NNの学習においてはデータセットが重要であり，本研究においても学習に用いる訓練データとテストデータ，評価のための未知オノマトペデータを充実させなければならない．今後，早急にシステム全体を完成させ，用意した未知オノマトペによって，翻訳性能について評価をしたいと考えている．

参考文献

[市岡 09] 市岡健一，福本文代：Web 上から取得した共起頻度と音象徴によるオノマトペの自動分類，電子情報通信学会論文誌，J92-D(3)，pp.428-438，2009.

[三上 06] 三上京子：日本語教育のための基本オノマトペの選定とその教材化，ICU 日本語教育研究，3，pp.49-63，2006.

[土屋 12] 土屋誠司：モーラ系列と音象徴ベクトルによるオノマトペの印象推定法，自然言語処理，19 (5)，pp.367-379，2012.

[Doizaki 17] Ryuichi Doizaki, Junji Watanabe, and Maki Sakamoto:Automatic Estimation of Multidimensional Ratings from a Single Sound-symbolic Word and Word-based Visualization of Tactile Perceptual Space, IEEE Transactions on Haptics, 10 (2), pp.173-182, 2017.

[郭 12] 郭華江：日中擬声語・擬態語辞典，上海訳文出版社版，2012.

[小野 07] 小野正弘：擬音語・擬態語 4500 日本語オノマトペ辞典，小学館，2007.

[Lee 13] Akinobu Lee, Keiichiro Oura, and Keiichi Tokuda: MMDAgent --A Fully Open-Source Toolkit for Voice Interaction Systems, IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2013.

[Socher 02] Gudrun Socher, Mohan Vishwanath, and Anurag Mendhekar:Intelligent Text-to-Speech Synthesis, U.S. Patent, No.6, 446, 040.2002.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

3 分岐型畳み込みニューラルネットワークによる 4 コマ漫画の順序識別

Recognizing the Order of Four-scene Comics by Three-Path Convolutional Neural Networks

藤野 紗耶 *1　森 直樹 *2　松本 啓之亮 *2
Saya Fujino　Naoki Mori　Keinosuke Matsumoto

*2大阪府立大学工学研究科
Graduate School of Engineering, Osaka Prefecture University

Recently, the comic analysis has become an attractive research topic in the artificial intelligence fields as comic engineering. In this study, we focused on the four-scene comics and applied deep convolutional neural networks (DCNNs) to those data for understanding the order structure. We proposed the novel approach for that problem by three-path DCNN with special input data formats. The hyperparameters of three-path DCNN are obtained by evolutionary deep learning (evoDL). The effectiveness of the proposed method is confirmed by computer simulations taking a real four-scene comics structure recognition problem as an example.

1. はじめに

近年，マンガを工学的に解析しようと試みるコミック工学 [松下 13] が機械学習の急速な発展を背景として注目されている．同分野では多様な研究可能性が示唆されているが，現状では画像に関する研究が圧倒的多数を占めている．この背景には，近年その優秀な性能により注目を浴びている深層畳み込みニューラルネットワーク (Deep Convolutional Neural Network: DCNN)[Krizhevsky 12] の存在がある．

本研究では，4 コマ漫画を対象として，DCNN によるコマの順序識別手法を提案する．コマの順序識別は，一般物体認識のカテゴリに属するキャラクター識別などとは異なり，人間の認知に直接関わるメタレベルがより高い高難度の課題であると考えることができる．一般的には，我々は画像部分と台詞部分を総合的に判断して，4 コマ漫画の識別をしているが，本研究ではこれが画像部分のみで識別可能かを示すために，コマごとに分割した画像を入力として 1〜2 コマからなる前半部分と 3〜4 コマからなる後半部分の識別を目的とする．DCNN は強力な手法であるが，一方で DCNN は非常に多くの hyperparameter を持つため，そのすべてを試行錯誤的に設定することは容易ではないという問題点もある．そこで，今回は進化型計算により優れた深層ニューラルネットワークの構造を進化的に獲得する進化型深層学習 (Evolutionary Deep Learning: evoDL)[Fujino 17] を適用し 3 分岐型 DCNN の構造を最適化した．また，実際の 4 コマ漫画の画像データを用いた数値実験によって，提案手法の有効性を示した．

2. 従来研究および本研究の位置付け

2.1 コミック工学

これまでのコミック工学は，いわゆる「マンガ」を対象としており，データセットに関する研究 [Matsui 15] や既存の画像認識手法によるコミック内パーツの識別研究を中心に発展してきた．これらの研究は，コミック工学という分野を広げるために大きく貢献している．また，ユーザの視点に立ったコミック検索システムなどについても積極的な研究がされている [山下 17].

連絡先: 藤野 紗耶，大阪府立大学，fujino@ss.cs.osakafu-u.ac.jp

一方で，狭義のコミックに収まらない対象についても研究の展開が始まっている．例えば，厳密にはコミックには分類されないアニメの絵コンテや絵本に関する研究 [Fujino 17] やストーリー生成系の研究 [Fukuda 17] などがその範疇に当てはまる．

本研究は，実際に市販されている 4 コマ漫画を対象としている点で狭義なコミック工学に属するが，一方で識別対象が具体的なパーツではなく，順序識別という点に大きな特徴がある．これはマンガリテラシー [中澤 04] を背景とした人間の認知に関する問題であり，そもそも画像認識ベースの機械学習のみで解決可能なのかすら明確ではない難解な課題であるといえる．

2.2 4 コマ漫画に関する研究

4 コマ漫画は日本における代表的な漫画形式のひとつであり，4 つのコマ (齣) によって完結した短い話を表現する．人間がストーリーを感じることができるコンパクトな表現形式として，古くから新聞や雑誌の一部に掲載されてきた．現在では，4 コマ漫画だけを扱う専門誌も数多く存在している．

4 コマ漫画の基本的なストーリー展開は，各コマを最初から順に起承転結に対応させ，結に相当する最終コマをオチとする場合が多い．それ以外にも 3 コマを序破急に対応させる場合や，2 段オチ, オチを必ずしも必要としないストーリー 4 コマなど現在では多様な形式が存在する．

従来研究としては，4 コマにおける感情識別に関する研究 [上野 16] やストーリー理解過程の解析研究 [上野 17] が報告されている．また 4 コマ漫画の自動生成に関する研究 [M. Ueno 14, Ueno 16a] や遺伝的アルゴリズムに基づく感性解析に 4 コマ漫画を用いた研究 [野村 17] もなされている．

本研究で対象とする 4 コマ漫画の順序識別に関しては，深層学習を用いた手法 [Ueno 16b] が提案されている．しかしながら従来研究では 1〜2 コマと 3〜4 コマの識別精度が 67% と十分な結果は得られていなかった．そこで，本研究では人工知能によるより高いメタレベルでの 4 コマ漫画理解を目指し，3 分岐型 DCNN による 4 コマ漫画の順序識別手法を提案する．

本研究では，ストーリーの導入に当たる 1〜2 コマとオチに関わる 3〜4 コマには画像に関する構造上の差異があることを仮定している．心理学的にこの問題を扱った研究 [Cohn 14] が報告されており，この仮定には一定の妥当性が認められるが，工学的な検証はほとんどなされていない．

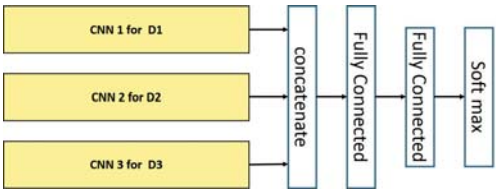


図 1: 3 分岐型 DCNN のモデル

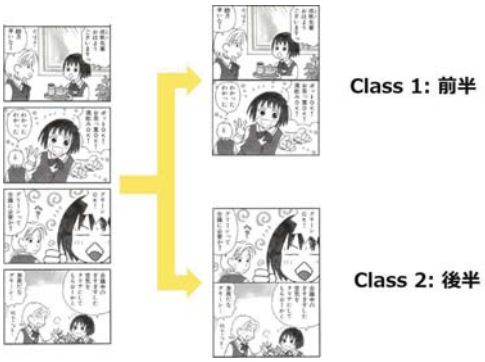


図 2: 実験におけるクラス

3. 提案手法

3.1 3 分岐型 DCNN

4 コマ漫画の順序識別に関する従来研究 [Ueno 16b] では AlexNet に類似した分岐のない深層畳み込みニューラルネットワーク (DCNN) を用いていたが，本研究では 3 分岐型 DCNN を適用する．図 1 に用いた 3 分岐型 DCNN の構造を示す．近年分岐型のモデルは多く報告されているが，これをコミック工学に応用した研究はまだ報告されていない．このモデルではそれぞれの分岐で異なる入力データおよび hyperparameter を設定することで，相補的な特徴量の抽出が期待できる．

なお，今回は 4 コマ漫画の画像のみを対象とするが，台詞の自然言語部分の消去はせずにそのまま画像として扱った点に注意を要する．

3.2 入力データ

今回は 4 コマ漫画の前半 (1〜2 コマ) と後半 (3〜4 コマ) の識別という特殊な問題を対象としたため，入力データに関して考察が必要である．一般に，人間はコマごとの情報は当然として，コマ間の連続性にも着目してストーリーを理解していると考えられる．例えば，導入に当たる前半の 1〜2 コマには大きな変化がなく，オチに関わる後半の 3〜4 コマの方が大きな変化が現れると予想される．これ以外にも，何らかの潜在的な差異が前半と後半に存在すれば，同一作家の同一作品であっても識別は可能である．以下では，本研究における 4 コマ漫画の順序識別で用いる入力データについて示す．

4 コマ漫画におけるいずれかのコマに対応する 2 画像を A, B とする．今回は A, B をサイズが 227x157，255 階調のグレイスケール画像としたが，RGB や二値画像等を用いることも可能である．ここで A, B を画素値に基づいて数値化したテンソルをそれぞれ A, B とおく．今回は A, B は行列となる．この A, B から 3 種類の入力データを作成した．

まずは従来手法と同様に A と B を縦方向に単純に連結したサイズ 227x314 のデータである．これは画像としては通常の 4 コマ漫画のコマ状態を示す．この他に，今回は $\mathcal{X}$ を A, B の各要素に作用する二項演算子として $A\mathcal{X}B$ からなるサイズ 227x157 のデータも用いる．これは人間がコマの連結を判断するときに，コマ間の差異や類似点のような相関を認識しているという仮説に基づく．$\mathcal{X}$ としては複数の演算が考えられるが，今回は最も自然な二項演算子として，加法 (A+B) と減法 (A-B) を利用した．以下では A+B によるデータを D2, A-B によるデータを D3 とする．図 2 に本実験で用いるクラスを示す．以下では，4 コマ漫画の前半を class 1，後半を class 2 とする．

表 1: GA における遺伝子表現

Design Variables	Allele
フィルター数 (NF)	32, 48, 64
フィルターサイズ (FS)	3, 5, 7
プーリングサイズ (PS)	3, 5, 7
プーリングタイプ (PT)	0(not use),1(max), 2(average)
全結合層 1 のノード数	512,1024
活性化関数 (Ac)	0(not use), 1(ReLU), 2(leaky ReLU)

4. 進化型深層学習

3 分岐の DCNN を用いるため大量の hyperparameter 調整が必要となる．そこで，進化型計算により優れた深層ニューラルネットワークの構造を進化的に獲得する進化型深層学習 (Evolutionary Deep Learning : evoDL)[Fujino 17] を利用した．

4.1 ネットワーク構造における制約

計算機資源の観点から，性能が同等の場合はよりサイズの小さいネットワークが優れていると評価するため以下の制約を導入した．

フィルター総数: 畳み込み層全体でのフィルター数の総和を 352 に固定した．evoDL によって畳み込み層 1, 2, 4, 5 のフィルター数を探索し，畳み込み層 3 のフィルター数はその他のフィルター数の和を 352 から減算することで一意に定める．

全結合層のノード総数: 今回は，出力層の直前に 3 つの全結合層を用いた．最終全結合層のノード数はクラス数に固定される．全結合層 1 および 2 のノード数を それぞれ N_1 ,N_2 と定義した場合, $N_1 \times N_2 = 2^{18}$ とする． この制約は全結合層 1 と 2 の間の重みの総数を固定することに相当する．

プーリング層 1, 2: DCNN ではプーリングが重要な役割を示すことが知られている．しかしながら進化型計算では確率的にプーリングをまったく用いない個体も生成されてしまう．このため，プーリングを持たない遺伝子型を致死個体とみなし，第 1，2 畳み込み層の後では必ずプーリングを適用するとした．ただし，この際に最大プーリングと平均プーリングのどちらを用いるかは進化的に獲得した．

4.2 個体表現

GA において，解は個体としてあらわす必要があり，それぞれの個体は染色体で表現される．この染色体を構成する記号は遺伝子と呼ばれる．さらに染色体内における遺伝子の位置を

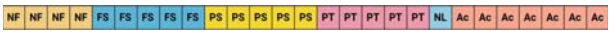


図 3: 遺伝子表現の例

遺伝子座，変更可能な遺伝子集合のことを対立遺伝子と呼ぶ．本研究において，それぞれの遺伝子座ごとに対立遺伝子の数を決定した．表 1 に設定した対立遺伝子を示す．また，図 3 に evoDL による遺伝子型の例を示す．“Ac” で表現される遺伝子は，各畳み込み層および全結合層の直後に置かれる活性化関数の種類を示す．“Ac” が 0 の場合は活性化関数を適用せず，1, 2 の場合にはそれぞれ ReLU 関数，leaky ReLU 関数を用いる．また “PT ” の遺伝子はプーリングタイプを示す．PT が 1, 2 の時それぞれ最大プーリング，平均プーリングが使われる．また，PT が 0 の時にはプーリングを適用しない．

4.3 適応度関数

GA の適応度関数 $F(s)$ として，訓練時における k 分割交差検定の識別率の総和を用いた．

5. 数値実験

evoDL により進化的に得られた 3 分岐型 DCNN を用いて数値実験をした．

5.1 問題および evoDL の設定

本実験では，全 188 話で構成される 4 コマ漫画である “こんぺいと！ 1”[ふじの 07] をデータセットとして用意した．画像サイズは **D1** を 227 × 314 pixel とし，**D2** を 227 × 157 pixel とした．本実験において，4 コマ漫画の前半 (class 1) と後半 (class 2) の間にある傾向が存在するという仮説に従い，DCNN のモデルは class 1 と class 2 の識別タスクによる適応度によって進化したモデルを用いた．

evoDL による訓練過程では 264 枚の画像を用いて，4.3 に示す適応度関数で進化させた．今回は $k = 2$ とした．それぞれの個体は DCNN モデルとして表現型に変換され，訓練がなされる．訓練の後に識別率と誤差を得るが，2 分割交差検定のため適応度関数はこれを 2 回繰り返して得ることができる．評価データとしては 112 枚の画像を用意した．このデータは最終的なエリート個体によって得られた DCNN モデルで評価される．今回は，各分岐を統合する場合の訓練に関して以下に示す手法 1, 2 による比較実験をする．

5.1.1 手法 1

3 分岐の DCNN におけるそれぞれの分岐に相当する DCNN の hyperparameter を evoDL によって進化的に設定する．また，**D1** ∼ **D3** に基づく DCNN の分岐は独立に訓練をした．evoDL によって得られた hyperparameter による各分岐の DCNN の訓練終了後，それぞれの DCNN における全結合層への入力に相当する最終畳み込み層の出力を結合し，ランダムな重みで初期化された新しい全結合層へと接続する．次に，畳み込み層のフィルターに関する重みは固定し，全結合層のみを 3 分岐の入力に基づいて訓練をする．

5.1.2 手法 2

evoDL によって 3 種の DCNN の構造を得るまでは手法 1 と同一である．手法 1 では，3 分岐のそれぞれの DCNN を独立に訓練したのちそれぞれの全結合層の結果を廃棄し，新たに 3 つの最終層を統合して全結合層の訓練をしたが，手法 2 ではこの課程を省略し最初から 3 つの DCNN を結合して分岐型 DCNN を構築した．訓練時には全結合層と畳み込み層を同時に一度だけ学習させることになる．手法 1 に比べて訓練時間が大幅に削減可能という利点がある．

表 2: evoDL における GA の設定

世代数	20
個体数	20
遺伝子長	27
交差	一様
交差率	1.0
突然変異率	$\frac{1}{L}$ (L: chromosome length)
選択	トーナメント選択
トーナメントサイズ	2
Elitism	true

5.2 実験条件

表 2 に GA の設定を示す．バッチサイズは 20 に固定し，最適化手法には Adam (学習率:2×10^{-6}) を用いた．DCNN による進化の evoDL の過程は以下に示す．

1. 最終世代で得られたエリート個体からそれぞれの DCNN の最適な hyperparameter を獲得する．
2. 得られた hyperparameter に基づく DCNN を訓練する．ここで最大訓練エポック数は 2000 と設定し，交差検定を用いないためすべての訓練データを用いた．

5.3 実験結果および考察

図 4 ∼ 6 は evoDL によって探索されたエリート個体を示す．これら 3 種のエリート個体を統合して最終的な 3 分岐型 DCNN を生成した．図 4 ∼ 6 から，畳み込み層 1, 2 のフィルターサイズはそれぞれ 7 および 3 と一致した．また畳み込み層 1 のプーリングタイプ，畳み込み層 1, 2 の直後に配置される活性化関数もそれぞれの個体で同一の遺伝子を示した．特に，それぞれの DCNN の第一活性化関数はすべて leaky ReLU が用いられていることが分かる．これは入力データが多くの負値を持つことが原因として挙げられる．オリジナルの画像は同一のものであるため，3 つの DCNN への入力データの基本的な特徴は同一なものである．以上より，evoDL によって得られた DCNN 構造が妥当であることが示された．

また， 3 分岐型 DCNN において全結合層 1, 2 のノード数はそれぞれ 1024, 256 に設定した．表 3 に それぞれのエリート個体による DCNN での 2000epoch の訓練後の識別率を示す．表 3 から **D3** を用いた際の識別率が低いことがわかる． **D3** は 2 シーンの差分であるため連続性に関する情報を含むが， class1 と class2 には連続性という観点で大きな差異が見られず，差分による情報量の減少が原因であると考えられる．表 4 に 500, 1000, 1500, 2000 epoch の訓練後の 3 分岐型 DCNN における識別率を示す．**D3** のみを用いたときの識別率は低かったが，手法 1 による 3 分岐型 DCNN が最もよい識別率を得ていることから **D3** は **D1** および **D2** の下位互換的なデータではなく，独自の重要な情報を持っていると考えられる．それぞれの分岐に相当する DCNN が異なる特徴の抽出に成功しているため， 3 分岐型 DCNN では単一の DCNN より良い識別率を得ることができたと考えられる．さらに，手法 1 の評価データの識別率は 先行研究 [Ueno 16b] の 0.67 より 0.79 と約 12% 上昇した．一方，表 4 より手法 2 の最大識別率は 2000 epoch における 0.70 で従来研究よりは改善が見られたが，手法 1 と比べると低く，また，表 3 における **D2** のみを用いた場合よりも低くなった．これは，すべての分岐を



図 4: **D1** におけるエリート個体



図 5: **D2** におけるエリート個体

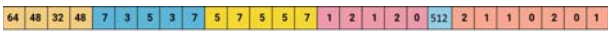


図 6: **D3** におけるエリート個体

表 3: 各 DCNN による評価識別率

モデル名	識別率
DCNN for **D1**	0.70
DCNN for **D2**	0.73
DCNN for **D3**	0.64

表 4: 手法 1, 2 による評価識別率

epoch	手法 1	手法 2
500	0.77	0.63
1000	**0.79**	0.67
1500	0.78	0.63
2000	0.77	0.70

同時並列的に学習したことで，各分岐の特徴が失われ相補的な役割を果たすことができず性能が劣化したと考えられる．**D2** と **D3** を併用した場合は， 重ね合わせデータ (**D2**) によって得られたシーンの類似性と差分データ (**D3**) によって得られたシーンの連続性をより正確に判断できたと考えられる．これらの結果より， DCNN による 4 コマ漫画の順序識別が十分に可能であることがわかった．

6. まとめと今後の課題

本研究では，機械学習による 4 コマ漫画の順序理解について検討した．evoDL によって DCNN の最適な hyperparameter を獲得し，3 分岐型 DCNN による 4 コマ漫画の前半，後半の識別をして，数値実験結果を示した．今後の課題としては提案した 3 分岐型 DCNN を用いて他の 4 コマ漫画やアニメおよび絵本などコミックに限定されないコンテンツデータによる実験が挙げられる．本研究は一部, 株式会社リバネスおよび日本学術振興会科学研究補助金基盤研究 (C) (課題番号 26330282) の補助を得て行われたものである．また，本研究を進めるにあたり，貴重なデータを提供して頂いたふじのはるか様に多大なご協力を頂いた．この場を借りて感謝の意を示す．

参考文献

[Cohn 14] Cohn, N.: You ’re a good structure, Charlie Brown: The distribution of narrative categories in comic strips, *Cognitive Science*, Vol. 38, pp. 1317–1359 (2014)

[Fujino 17] Fujino, S., Hatanaka, T., Mori, N., and Matsumoto, K.: The Evolutionary Deep Learning based on Deep Convolutional Neural Network for the Anime Storyboard Recognition, in *Distributed Computing and Artificial Intelligence, 14th International Conference, DCAI 2017, Porto, Portugal, 21-23 June, 2017*, pp. 278–285 (2017)

[Fukuda 17] Fukuda, K., Fujino, S., Mori, N., and Matsumoto, K.: *Semi-automatic Picture Book Generation Based on Story Model and Agent-Based Simulation*, pp. 117–132, Springer International Publishing, Cham (2017)

[Krizhevsky 12] Krizhevsky, A., Sutskever, I., and Hinton, G. E.: ImageNet Classification with Deep Convolutional Neural Networks, in Bartlett, P., Pereira, F., Burges, C., Bottou, L., and Weinberger, K. eds., *Advances in Neural Information Processing Systems 25*, pp. 1106–1114 (2012)

[M. Ueno 14] M. Ueno, K. M., N. Mori: 2-Scene Comic Creating System Based on the Distribution of Picture State Transition, in *Advances in Intelligent Systems and Computing*, Vol. 290, pp. 459–467 (2014)

[Matsui 15] Matsui, Y., Ito, K., Aramaki, Y., Yamasaki, T., and Aizawa, K.: Sketch-based Manga Retrieval using Manga109 Dataset, *CoRR*, Vol. abs/1510.04389, (2015)

[Ueno 16a] Ueno, M.: Computational Interpretation of Comic Scenes, in *Advances in Intelligent Systems and Computing*, Vol. 474, pp. 387–393 (2016)

[Ueno 16b] Ueno, M., Mori, N., Suenaga, T., and Isahara, H.: Estimation of structure of four-scene comics by convolutional neural networks, in *Proceedings of the 1st International Workshop on coMics ANalysis, Processing and Understanding*, p. 9ACM (2016)

[ふじの 07] ふじの はるか：こんぺいと! 1, 芳文社 (2007)

[山下 17] 山下 諒, 朴炳宣, 松下 光範：コミックの内容情報に基づいた探索的な情報アクセスの支援, 人工知能学会論文誌, Vol. 32, No. 1, pp. WII–D_1–11 (2017)

[松下 13] 松下 光範：コミック工学：マンガを計算可能にする試み, 日本知能情報ファジィ学会ファジィ システム シンポジウム 講演論文集, Vol. 29, pp. 199–199 (2013)

[上野 16] 上野 未貴, 森 直樹, 松本 啓之亮：漫画内の特徴的要素が与えるストーリーの印象についての検討, 第 30 回人工知能学会全国大会発表論文集, pp. 2J5–OS–08b–4in2 (2016)

[上野 17] 上野 未貴, 末長 寿規, 井佐原 均：漫画中の表現獲得方法に基づくストーリー理解過程の解析, 第 31 回人工知能学会全国大会発表論文集, pp. 4F1–5in2 (2017)

[中澤 04] 中澤 潤：マンガ読解力の規定因としてのマンガの読みリテラシー, マンガ研究, Vol. 5, pp. 6–25 (2004)

[野村 17] 野村 俊太, 荒井 幸代：進化計算を用いた人間の感性理解のための遺伝子解析法, 第 31 回人工知能学会全国大会発表論文集, pp. 3H2–OS–04b–2 (2017)

Oral presentation | Organized Session | [Organized Session] OS-2

[1K2-OS-2b] [Organized Session] OS-2

Tue. Jun 5, 2018 3:20 PM - 5:00 PM Room K (3F Azisai Mokuren)

[1K2-OS-2b-01] Manga Processing and its Dataset -Manga109- Construction for Academic Use

○Kiyoharu Aizawa[1] （1. The University of Tokyo）

3:20 PM - 4:00 PM

[1K2-OS-2b-02] Automatic generation of anime-like hair motion of 3D characters

○Kenji Furukawa[1], Susumu Nakata[1] （1. Ritsumeikan University）

4:00 PM - 4:20 PM

[1K2-OS-2b-03] Trials of Generating Comic Illustrations Using Deep Generative Adversarial Networks

○Jun Hozumi[1], Yutaka Matsuo[1] （1. the University of Tokyo）

4:20 PM - 4:40 PM

[1K2-OS-2b-04] Character Representation Adaption in Individual Manga

○Koki Tsubota[1], Toru Ogawa[1], Toshihiko Yamasaki[1], Kiyoharu Aizawa[1] （1. The University of Tokyo）

4:40 PM - 5:00 PM

©The Japanese Society for Artificial Intelligence

3:20 PM - 4:00 PM (Tue. Jun 5, 2018 3:20 PM - 5:00 PM Room K)

[1K2-OS-2b-01] Manga Processing and its Dataset -Manga109-Construction for Academic Use

○Kiyoharu Aizawa[1] （1. The University of Tokyo）

Keywords: Manga, Comic, Image Processing, Multimedia

本招待講演では，漫画・イラストのメディア処理として，講演者のグループが取り組んできた一連の取り組みを紹介するとともに，漫画処理のために構築した世界最大規模のデータセット Manga109について紹介する．図書であったこともあり，漫画は，これまでメディア処理の観点からの研究が十分に行われていなかった．また，漫画は，本来2値画像であり，自然画像で研究開発された多くの手法が機能しない．講演者らは，漫画に特化した基盤的な処理アルゴリズムについて研究するとともに，検索，描画支援といったインタラクティブ処理課題について取り組みを進めてきた．また，より多くの人が，この課題に学術的な立場から，著作権の問題に悩むことなく，取り組めるように，学術研究用の漫画のデータセットを構築し，公開した．そのデータセットのための膨大なアノテーションも構築した．それらのデータセットについても紹介する．

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

3 次元キャラクタにおけるアニメ風髪モーションの自動生成

Automatic generation of anime-like hair motion of 3D characters

古川健次
Furukawa Kenji

仲田晋
Nakata Susumu

立命館大学
Ritsumeikan University

In the process of Japanese anime production, three-dimensional computer graphics (3DCG) plays important roles for cost reduction and quality improvement. However, it is difficult to produce anime-like motions of 3D characters since Japanese anime has their own motions. Especially with the hair of the 3D character, in order to produce the motion of Japanese anime-like hair motion, physics-based calculation often produces undesirable results. The purpose of this research is to enable creators to automatically generate hair motion for Japanese anime of 3D characters. We formulate the anime-like hair motion based on a typical technique used in traditional Japanese animation.

1. はじめに

日本のアニメ市場は年々拡大を続けており，日本の重要な産業の 1 つとなっている．2016 年の TV アニメのタイトル数は 356 本となっており，2000 年以前の最高本数である 1999 年の 149 本よりも倍以上のタイトル数が放送されていることになる[一般社団法人日本動画協会 17]．TV アニメの制作分数を比べてみても，2016 年では 115805 分となっており，2000 年の 75890 分よりも 1. 5 倍以上になっている[一般社団法人日本動画協会 17]．しかし，増加し続けるアニメの需要に対して，十分な制作時間や人材が確保できていない現状があり[実態調査プロジェクト委員会 15]，作業の軽減や効率化が求められている．

これらの問題に対し，近年では作業効率化やクオリティ向上を目的として，アニメに 3DCG が導入されることが増えてきた．アニメで 3DCG を使用する利点としては，3DCG モデルは一度作れば繰り返し使うことができることや，作画と違って制作する人が違っても一定のクオリティが保たれることなどが挙げられる．アニメにおける 3DCG は主に，機械や背景などに使われることが多く，メインのキャラクタなどは作画のままでだった．しかし，2010 年代からは，3DCG で表現することが難しいとされていた人間のキャラクタにも，3DCG が用いられるようになってきており，日本のアニメにおける 3DCG の需要が高まっている．

3DCG の見た目を作画アニメに近づける研究や技術は多々あり，最新の 3DCG アニメでは，アニメを見慣れた人でないと見分けがつかないほどのクオリティとなっている．しかし，作画アニメと 3DCG アニメの動きを比べると明らかな違いが生じてしまう．これは，日本のアニメ作品が，少ない作画枚数で動きを表現するために，写実的とは違った，独自の手法を用いて作られていることによるものである．

その中でも特に，髪の動きは違和感が大きい．これは，作画アニメの髪が物理法則に従っていない動きをしているのに対し，3DCG では物理演算で自動的に動かされていることが多いからである．3DCG の髪を作画の動きに近づけるには，手動でモーションを調整する必要があり，非常に手間がかかってしまう．よって，3DCG 上で作画アニメの手法に基づいた髪のモーションを自動生成する手法が必要である．

連絡先：古川 健次，立命館大学 情報理工学部，
is0279fe@ed.ritsumei.ac.jp

本研究の目的は，作画アニメの髪の動きを，3DCG 上で自動生成できるようにすることである．具体的な入出力としては，骨格を設定済みの 3D キャラクタを入力とし，作画風の髪モーションを出力とする．

この研究の課題は，作風やアニメーターによって変化し，画一致的でない作画アニメにおける髪の動き方を，どのように 1 つのモデルとして定義するかということである．この課題に対し，本研究では，作画アニメの最も代表的な手法を数式で表すことで解決する．

この研究の目的を達成することにより，3D キャラクタで作画アニメの髪の動きを容易に再現することが可能となる．これにより，アニメ制作における労力の削減や，クオリティの向上に繋げることができる．

2. 関連研究

2.1 作画アニメの動きに関する研究

作画アニメと 3DCG アニメの動きの違いを解消しようとした研究は多々ある．北村らの研究[北村 13]では，各フレームの移動量から，適切なフレームの削除とコピーを行うことで，日本の作画アニメで使われているリミテッドアニメーションと呼ばれる手法を，3DCG 上で再現した．また，今間らの研究[今間 11]では，作画アニメから抽出した動きを 3DCG のスケルトンに適用させることで，作画アニメの動きを再現した．

これらの研究は，作画アニメの動きを 3DCG 上で再現しようとした研究である．これらの研究に，作画アニメの髪の動きのような，局所的で作画アニメ特有である動きを再現する方法を取り入れることができれば，より作画アニメの動きに近づけられる．

2.2 作画アニメの髪に関する研究

作画アニメの髪を 3DCG 上で再現しようとした研究も多々ある．石塚の研究[石塚 10]では，作画アニメで見られる髪の集束と分裂を 3DCG 上で再現した．また，Sakai らの研究[Sakai 13]では，陰関数曲面モデルを用いることで，髪の集束と分裂の他にも，なめらかなシェーディングと動きを実現した．さらに，森らの研究[森 16]では，ベジエ関数と軸変形 FFD を用いることで，髪幅の変形もできるようにした．

これらの研究によって，作画アニメの髪の集束や分裂，髪幅の変形などの形状の変化を，再現できるようになった．しかし，作画アニメの特有の髪の動きについては考慮されていない．こ

れらの研究に作画アニメ特有の髪の動きを取り入れることができれば，より作画アニメの髪に近づけることができる．

3. 提案手法

3.1 髪の動きの分析

本研究の目的を達成するために，作画アニメの髪の動きを定義する必要がある．そのために，作画アニメの教科書や実際のアニメの調査，さらにアニメーターへの聞き取り調査を行った．

最初に，作画アニメと 3DCG アニメにおける髪の動きを比べたときに，具体的に何が違うのかを調べた．作画アニメでの髪の動きは，髪の根本から髪先に向けて波打つように動いていることが多かった．それに対し，3DCG アニメでは波打つようには動かずに，根本を軸として全体が回転しているように動いていることが多かった．また，作画アニメの髪の動きは周期的な動きを繰り返すのに対し，3DCG アニメの髪の動きは不規則な動きをしていることが多かった．このような違いが生じる原因としては，作画アニメの髪の動きが，作画枚数削減や表現を誇張するために，3DCG アニメの物理的な動きとは，違った動きをしているからであると考えられる．

次に，アニメ制作の教科書やアニメーターへの聞き取りから，作画アニメの髪を動かす際の描き方を調べた．その結果，作画アニメにおける髪の動かし方には，ある共通する手法が存在することが見て取れた．その手法を用いて髪となる線を動かした例を，図 1 に示す．この手法は球状の空気の塊が髪に沿って動いているように描くことで，髪を動かすという手法である．実際のアニメでも，多くの作品でこの手法と見られる動かし方が見て取れた．

この手法の根源を調べたところ，日本アニメーションの父と称されている政岡憲三が，アニメーターの新人育成のために作った，「政岡憲三動画講義録」においても，同様の手法が記述されていた[萩原　15]．これらの調査から，球状の空気の塊が髪に沿って動いているように描く手法が，作画アニメにおいて髪を動かす際の，代表的な手法であるとした．この手法を数式で定義し，数値的に表せるようにすることで，3DCG 上で再現することとした．

3.2 髪の動きの定義

前項で定義した作画アニメの代表的な手法を，3DCG 上で数値的に再現できるようにするために，手法を数式化する．数式化するために，前項で定義した手法を以下の 3 つの要素に分解した．

1. 球状の空気の塊が髪に沿って移動する．
2. 重力の影響を受ける．
3. 根本はあまり動かず，先端に近づくほどよく動く．

この 3 つの要素を数式で表し，掛け合わせていくことで，作画アニメの髪の動きを 3DCG 上で再現できるようにする．

1 つ目の要素である，球状の空気の塊が髪に沿って移動する動きを定義した式を，以下のように示す(1).

$$f_1(x,t) = \sin\left(\frac{x}{k} - t + \frac{\pi}{2}\right) \qquad (0 \le x \le \pi) \qquad (1)$$

この式において，k は波の波長を調整するパラメータであり，k を大きくすると波長が大きくなる．また，t は時間，x は髪の根本からの距離を表し，根本の値を 0 とし，髪先の値が π である．

次に，2 つ目の要素である重力による影響を，$f_1(x,t)$に掛け合わせた式を，以下のように示す(2).

$$f_2(x,t) = -\frac{1}{s}\left(f_1(x,t) + \frac{1}{s}\right) \qquad (0 \le x \le \pi) \qquad (2)$$

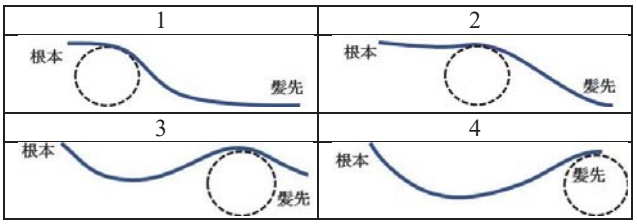


図 1: 作画アニメにおける髪の動かし方の例

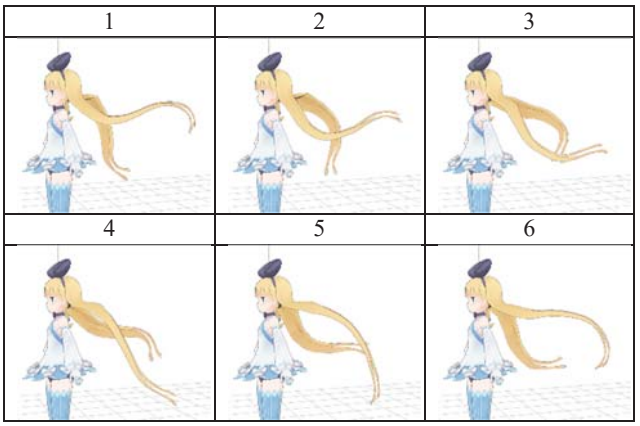


図 2: 提案手法の適用例

モデル：ニコニ立体ちゃん(株式会社ドワンゴ) [ドワンゴ　14]

この式において，s は振幅の大きさと重力を調整するパラメータであり，s を小さくすると振幅と重力による傾きは大きくなる．

最後に 3 つ目の要素である，根本はあまり動かず，先端に近づくほどよく動く要素を，$f_2(x,t)$に掛け合わせた式を，以下のように示す(3).

$$f_3(x,t) = a\left(\frac{x}{\pi}\right)^p f_2(x,t) \qquad (0 \le x \le \pi) \qquad (3)$$

この式において，p は髪の根本の動き具合を調整するパラメータである．p を大きくするほど根本付近が動きにくくなり，髪先と根本の動きの差が大きくなる．また，a は最終的な波の形を調整するためのパラメータである．

これらより，作画アニメにおける髪の動かし方の代表的な手法を数式化したものを$f_3(x,t)$とする．この式を骨格が設定済みの 3D キャラクタの髪の骨格に適用させることで，作画アニメの髪の動きを 3DCG 上で再現する．3D キャラクタの髪の骨格は，髪の根本から髪先まで，直線状に配置されているものとする．また，実際に 3D キャラクタに適用させた例を図 2 に示す．ソフトウェアは MMM(MikuMikuMoving)を用いて，3D キャラクタは株式会社ドワンゴが配布しているニコニ立体ちゃん[ドワンゴ　14]を使用した．この結果から，実際の 3D キャラクタの髪に対して本手法を適用させても，問題なく動作することが分かる．

4. 実験

4.1 目的と方法

本手法によって生成したモーションが，実際の作画アニメに近づけられていることを，実験で数値的に証明する．

実験の準備として，提案手法で生成した髪のモーションと作画アニメの髪の動きが比較できるようにするために，作画アニメの髪にボーンとジョイントを配置する．ボーンとジョイントの位置は，髪束の中心となる位置に配置する．これにより，生成した髪のモーションと作画アニメの髪の動きが比較できるようになる．

表 1: 比較に使用したアニメ一覧

番号	作品タイトル	比較箇所
1	舞-HiME(2004) [サンライズ 04]	26 話 12:47
2	魔法少女リリカルなのは StrikerS(2007) [セブン・アークス 07]	2 話 8:06
3	劇場版 艦これ(2016) [ディオメディア 16]	53:27
4	劇場版 艦これ(2016) [ディオメディア 16]	58:09
5	戦姫絶唱シンフォギア AXZ(2017) [サテライト 17]	1 話 7:26
6	戦姫絶唱シンフォギア AXZ(2017) [サテライト 17]	2 話 8:54

表 2: 提案手法と作画アニメの比較結果

番号	ボーンの角度差平均	ジョイントの位置差平均
1	18.1°	13.8%
2	19.2°	9.68%
3	10.9°	7.01%
4	7.39°	4.67%
5	10.6°	5.65%
6	9.76°	7.51%

表 3: 物理演算と作画アニメの比較結果

番号	ボーンの角度差平均	ジョイントの位置差平均
5	27.1°	11.0%

具体的な実験内容としては，提案手法で生成した髪のモーションと作画アニメの髪の動きを比較し，ジョイント位置の位置ズレとボーンの角度のズレをそれぞれ出す．また，参考として物理演算で動かした髪のモーションと作画アニメの髪の動きでも，同じ比較を行う．ズレの数値が，物理演算のものよりも小さければ，生成したモーションが作画アニメに近づけられているということが言える．実験で使用した作画アニメを表 1 に示す．また，物理演算は，MMD(MikuMikuDance)のものを使用した．

4.2 結果

提案手法で生成したモーションと作画アニメの動きを比較した結果を表 2 に示す．さらに，物理演算で生成したモーションと作画アニメの動きを比較した結果を表 3 に示す．

結果から，提案手法で生成したモーションは物理演算のものよりも，作画アニメとのズレが小さい値となっているので，5 番の作画アニメの再現に関しては，物理演算よりも作画アニメに近づけられているということが言える．

5. まとめ

本研究では作画アニメの髪の動きを，3DCG 上で再現した．本研究の目的を達成する上で，作画アニメの髪の動きをどのように定義し，3DCG 上で再現するかということが課題となっていた．この課題に対し，作画アニメの代表的な手法を数式化し，3D キャラクタのボーンに適用することで解決した．

本研究の今後の展望としては，作画アニメでよく見られる，髪の集束と分散を考慮した動きなどが考えられる．また，本研究では，キャラクタやカメラが移動した場合の髪の動きは考慮していない．作画アニメでは，カメラやキャラクタの動きに合わせて髪のなびく方向が変わることはよくあるので，この要素を考慮した髪の動かし方を新たに考える必要がある．

参考文献

[一般社団法人日本動画協会 17]一般社団法人日本動画協会:アニメ産業レポート, 2017.

[実態調査プロジェクト委員会 15] 実態調査プロジェクト委員会:アニメーション制作者実態調査報告書 2015, 公益社団法人日本芸能実演家団体協議会, 2015.

[北村 13] 北村真紀, 金森由博, 三谷純, 福井幸男, 鶴野玲治:リミテッドアニメ風表現のためのモーションタイミング調整法, 情報処理学会研究報告グラフィクスと CAD, Vol. 2013-CG-153, No. 24, pp. 1-6, 2013.

[今間 11] 今間俊博, 斎藤隆文, 神谷由季:CG化を妨げるアニメにおける動きの記号化, 情報処理学会研究報告グラフィクスと CAD, Vol. 2011-CG-144, No. 2, pp. 1-7, 2011.

[石塚 10] 石塚真貴男:3DCG における作画アニメ調髪束先の形状変形手法に関する研究, 東京工科大学大学院, 修士論文, 2010.

[Sakai 13] Takeyuki Sakai: Skeleton-based cartoon hair modeling using blobby model, SIGGRAPH Asia 2013 Posters, Article No.17, 2013.

[森 16] 森拓也, 渡辺大地:作画アニメ調髪動作の自動生成, 映像情報メディア学会技術報告, Vol. 40, No. 11, pp. 45-48, 2016.

[萩原 15] 萩原由加里:政岡憲三とその時代 「日本アニメーションの父」の戦前と戦後, 青弓社, 2015.

[ドワンゴ 14]株式会社ドワンゴ:ニコニ立体ちゃん, http://3d.nicovideo.jp/alicia/, 2018/02/19

[サンライズ 04] サンライズ:舞-HiME, 2004.

[セブン・アークス 07] セブン・アークス:魔法少女リリカルなのは StrikerS, 2007.

[ディオメディア 16] ディオメディア:劇場版 艦これ, 2016.

[サテライト 17] サテライト:戦姫絶唱シンフォギア AXZ, 2017.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

深層敵対的生成ネットワークを用いた マンガイラスト自動生成の試み

Trials of Generating Comic Illustrations Using Deep Generative Adversarial Networks

保住 純 *1　　松尾 豊 *1
Jun Hozumi　　Yutaka Matsuo

*1東京大学
The University of Tokyo

There have been lots of research of automatic generation of images using deep generative models, like Generative Adversarial Networks (GANs.) However most of these attempts are using colored photographs for training models and few researches on generating illustration are using deep generative models. In this paper, we show our results of several trials of generating comic Illustration using recent GANs, trained by black and white illustrations in frames of "Tetsuwan Atom(Astro boy)" series written by Osamu Tezuka. We confirmed GANs can learn characteristics of comic illustrations, like lines and balloons, but we also found serious defects, one of which is indistinguishability of characters and backgrounds.

1. はじめに

これまでに人間の手によって数多くのマンガが制作されてきた．マンガを制作することは，キャラクターやストーリーを創造し，それを適切なコマ割りや様々な技法を用いることで画像として表現する技術であり，それは人工知能にとって難易度が高いタスクであると考えられる．そこで，本研究ではマンガにおける 1 コマ分の画像 *1 をマンガイラストと定義し，それを自動生成することに焦点を置く．

近年，深層学習を用いて自動的に画像を生成する研究が数多く行われてきた．その際に用いられるモデルの一つに敵対的生成ネットワーク（Generative Adversarial Network, GAN）があり，高品質な画像を生成するための様々な手法が提案されてきた（[Alec 15][Ishaan 17][Naveen 17]）．ただし，これら研究の多くが検証に用いるデータセットは，MNIST のような非常に単純なものか，CIFAR-10 や CelebA などイラストに比べて情報量が多い写真画像を対象としたものとなっている．そのため，主にモノクロの線画によって構成され，かつ様々なシーンが描画されるマンガイラストには，これらの手法が適切とは言えない可能性がある．

一方で，イラストを GAN によって自動生成する研究 [Yanghua 17] や，マンガを対象として人工知能を活用する研究も従来より数多く行われている [松下 17]．しかし，マンガイラストを深層学習によって直接生成しようとする試みは，あまり行われていない．その原因の一つに，それを行う上で学習に必要なデータセットが入手しづらいことが考えられる．もし仮にマンガイラストが収集できたとしても，学習に用いるマンガイラストの作画者が異なる場合，その表現方法の差異によって学習が困難になる可能性もある．

以上を踏まえ，本研究では深層敵対的生成ネットワークを用いたマンガイラストの自動生成を試みる．学習に用いるデータセットに，手塚治虫のマンガ「鉄腕アトム」（本編）全 18 巻に含まれる各コマを切り出した画像を用いる．使用する層の数や損失関数を変更することで複数回実験を行い，その結果を考察する．本研究にて得られる示唆は，人工知能によるマンガの自動生成を研究していく上で有益なものになると考えられる．

連絡先: 保住 純（hozumi@weblab.t.u-tokyo.ac.jp）
*1　ここではフキダシ内の文章等を考慮しない．

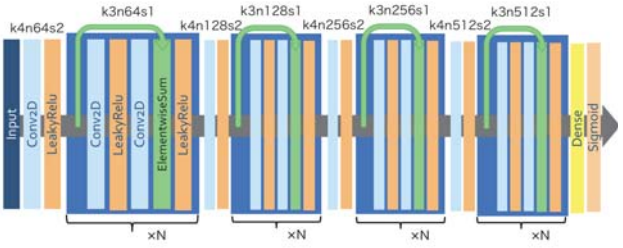


図 1: 識別ネットワークの構造

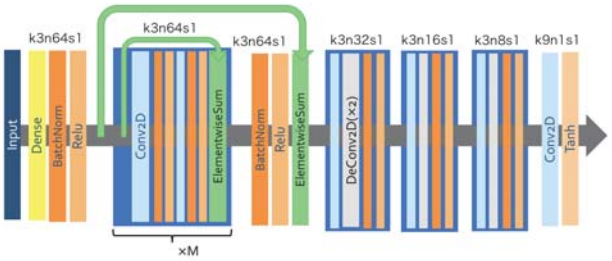


図 2: 生成ネットワークの構造

2. 手法

2.1 ネットワーク構造

本研究で用いるネットワークの構造を，図 1 と図 2 に記す．この構造を考える上で [Yanghua 17] を参考にした．図中の k はカーネル数，n は特徴マップ数，s はストライドを表す．また，図 1 での $\times N$，図 2 での $\times M$ の表記はその部分の繰り返し回数を示し，その値を変更することでネットワークの深さが変化する．

2.2 損失関数

本研究では比較のために，複数種類の損失関数 (DCGAN, WGAN-GP, DRAGAN) を採用する．どちらも生成ネットワーク側の損失関数は共通で $L_G = \mathbb{E}[\log G(z)]$ であるが，識別ネットワーク側の損失関数 L_D がそれぞれ異なる．

- DCGAN [Alec 15]
  $L_D = \mathbb{E}[\log G(z)] + \mathbb{E}[\log(1 - G(z))]$
- WGAN-GP [Ishaan 17]
  $L_D = \mathbb{E}[\log G(z)] + \lambda\mathbb{E}[|\nabla(D(\alpha x - (1 - \alpha G(z)))| - 1)^2]$
- DRAGAN [Naveen 17]
  $L_D = \mathbb{E}[\log G(z)] + \lambda\mathbb{E}[|\nabla(D(\alpha x - (1 - \alpha x_p))| - 1)^2]$

3. 実験

3.1 設定

損失関数のハイパーパラメータとして $\lambda = 0.25$，損失関数の最適化手法には Adam を採用し，$\alpha = 0.0002, \beta_1 = 0.5$ とした．ノイズ z の次元数は 100 とし，すべての重みは平均 0，標準偏差 0.02 のガウス分布によって初期化する．訓練時のバッチサイズは 64，イテレーション数は 40000 に設定した．

学習に用いるデータセットには，マンガ「鉄腕アトム」（本編）全 18 巻に含まれているコマを手動で長方形状に切り出した画像，計 26428 枚を用いる．また，各コマはサイズが 128×128 に統一されるよう拡大縮小を行った．

3.2 実験結果

実験結果を表 1 に記す．結果欄における「○」は異なるノイズで異なる画像が出力された,「×」はモード崩壊が発生しすべて同様の模様状の画像が生成されたことを示す．また，各設定の中から筆者の目視判断によって質が最も良い画像を出力できた例を図 3 に記す．

表 1: ネットワークの設定と実験結果

N	M	損失関数	結果
1	4	DCGAN	○（図 3）
1	4	WGAN-GP	○
1	4	DRAGAN	×
2	8	DCGAN	○
2	8	WGAN-GP	×
2	8	DRAGAN	×

4. 考察

今回の実験では，層の数を少なくし，損失関数に [Alec 15] のものを用いるという，よりシンプルな構造の GAN を採用するほうが良い出力結果を得られた．また，WGAN-GP や DRAGAN の損失関数の状況を見ると識別ネットワークの損失関数の最適化が生成ネットワークに比べて急激に進んでいたことが分かった．これはハイパーパラメータや各ネットワークの更新頻度を調整することで改善できる余地があると考える．

また，生成された画像を調べると，コマの外枠を出力できているとともに，細線で区切られたフキダシのような形状と，その中の文字に相当するであろう模様が生成できていた．今後も生成ネットワークのアップスケーリングの工夫や画像出力後のノイズ除去処理を行うことによって，より高品質なイラストが出力できる可能性があると考えられる．

しかし，生成画像を見ると背景とキャラの区別がつけられていない．そのため，もし次のステップとして「アトムが宇宙空間を飛行する」といった条件付き画像生成を考えるならば，ネットワーク構造の変更も含めた多方面での検討を行う必要があると考えられる．

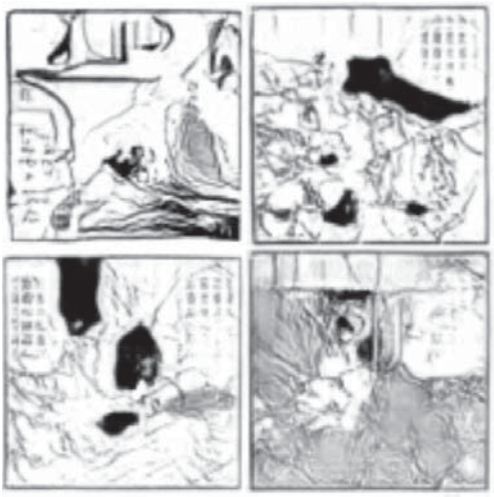


図 3: 本手法によって生成されるマンガイラストの例（4 枚分）

5. 結論

本研究では，深層敵対的生成ネットワークを用いてマンガイラストの自動生成を試みた．使用する層の数や損失関数を変更することで複数回実験を行い，その結果を考察した．今回はシンプルな構造の GAN ほど良い出力結果を得たが，それぞれの手法には様々な改良の余地があると考えられる．

しかし，マンガ自体を自動生成するためには，他にも数多くの課題が残されている．その中にはストーリー生成やキャラクターと設定の創造といった，画像処理でないタスクも多く存在する．それでも，本研究が人工知能によるマンガの自動生成に向けた研究において少しでも参考になれば幸いである．

謝辞

学習用データの準備に際し，フィールズ株式会社にご協力いただきました．この場を借りてお礼申し上げます．

参考文献

[松下 17] 松下 光範，山西 良典，松井 勇佑，岩田 基，上野 未貴，西原 陽子，中村 聡史．私のブックマーク「コミック工学（Comic Computing）」，人工知能 32 巻 6 号 (2017).

[Yanghua 17] Jin, Yanghua, et al. ”Towards the Automatic Anime Characters Creation with Generative Adversarial Networks.” arXiv preprint arXiv:1708.05509 (2017).

[Alec 15] Radford, Alec, Luke Metz, and Soumith Chintala. ”Unsupervised representation learning with deep convolutional generative adversarial networks.” arXiv preprint arXiv:1511.06434 (2015).

[Ishaan 17] Gulrajani, Ishaan, et al. ”Improved training of wasserstein gans.” Advances in Neural Information Processing Systems (2017).

[Naveen 17] Kodali, Naveen, et al. ”On Convergence and Stability of GANs” arXiv preprint arXiv:1705.07215 (2017).

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

キャラクター顔特徴量の個別漫画への適応手法

Character Representation Adaption in Individual Manga

坪田亘記 Koki Tsubota　小川徹 Toru Ogawa　山﨑俊彦 Toshihiko Yamasaki　相澤清晴 Kiyoharu Aizawa

東京大学
The University of Tokyo

Our goal is character clustering of individual manga with bounding boxes of characters' faces and frames. We propose a method to adapt character representations to individual manga for clustering. We use deep metric learning by making positive and negative pairs considering manga specific nature that the same character tends to appear in the near page and the characters in the same frame almost always differ. We showed that adapting to individual manga improves the accuracy of clustering.

1. はじめに

漫画のキャラクターの顔分類は重要な課題である．もしこれが出来れば，顔画像を名前と対応させることでキャラクター名での検索，吹き出しと対応させることで話者同定に応用できる．また，キャラクターを区別することで着色等一貫した処理に応用できる．

本研究では個別の漫画に対して，クラスタリングをすることでキャラクターの顔分類を行う．コマとキャラクターの顔のバウンディングボックスは得られているものとする．

クラスタリングにおいては，教師データを用いて汎用的な特徴抽出器を作成し，その特徴抽出器をテストデータに適用するのが一般的である. しかしこの手法は教師データとテストデータの分布が十分に同一であることを仮定しており, 漫画のように画風の幅が広い画像では性能が劣化しうる. そのため本研究では個別の漫画に対して特徴量を適応させることで性能の向上を図る．

今回前提としているバウンディングボックスを得る研究として，漫画における顔とコマの検出の研究がある．例えば Chu ら [Chu 17] は顔検出を行っており，小川ら [小川 17] は漫画における物体（顔，体，テキスト，コマ) の検出を行っている．また小川らはキャラクターの顔よりもコマが検出しやすいことを示している．そのため，顔分類に必要なキャラクターの顔のバウンディングボックスだけではなく，コマのバウンディングボックスも与えられることは大きな制約ではない．

2. 関連研究

2.1 漫画における画像特徴量

漫画における画像特徴量の作成・検討は，クラスタリングと検索の分野で行われている．柳澤ら [柳澤 17] は SURF 特徴量 [Bay 06] を用いた漫画の顔画像のクラスタリングを行っている．また松井ら [Matsui 16] は EOH 特徴量 [Levi 04] という hand-crafted な特徴量を用いた検索を行っている．その後成田ら [Narita 17] によって深層学習を用いた特徴量を用いたことで検索が改善されたことが報告されている．しかしながら，これらの手法は汎用性のある漫画の特徴量を目的としており，個別の漫画に適応した特徴量を作成をしているわけではない．

連絡先: 東京大学　情報理工学系研究科
〒 113-8656 東京都文京区本郷 7-3-1
TEL: 03-5841-6761
Email: tsubota@hal.t.u-tokyo.ac.jp

2.2 深層距離学習

画像に対して同じクラスが近く，異なるクラスが遠くなるような特徴量を作成する手法の一つに，深層距離学習がある．深層距離学習は fine-grained な画像認識・検索・顔認識といった分野で使用されている．

深層距離学習は深層学習において同じクラス同士は近づけ，異なるクラス同士は遠ざけるような損失関数を定めて学習を行う手法である．損失関数のうちの一つとしては constrastive loss [Hadsell 06] がある．contrastive loss の式は画像 I_i, I_j に対応する特徴量 x_i, x_j に対して t_{ij} を正ペアのときに 1，負ペアのときに 0 としたとき，以下の式で表される．

$$L_{contrastive} = \frac{1}{2} t_{ij} ||x_i - x_j||_2^2 + \frac{1}{2}(1 - t_{ij}) \left(\tau - ||x_i - x_j||_2\right)^2 \quad (1)$$

なお，τ はマージンである．

個別のドメインに適応した深層距離学習としては，Zhang ら [Zhang 16] の手法がある．この手法では，ビデオにおける顔のトラッキング情報とフレーム情報をもとに正ペア/負ペアを構築し深層距離学習を行い，最終的に顔画像のクラスタリングを行っている．本研究ではこの手法に倣い漫画特有の情報をもとに正ペア/負ペアを定義し，深層距離学習を行う．

3. 手法

3.1 概要

漫画に対して汎用性のある深層学習ベースの特徴抽出器から，個別の漫画に適応した特徴抽出器を作成する手法を提案する．手法の概要を図 1 に示す．最初に教師あり学習によって漫画に汎用性のある特徴抽出器（漫画用 CNN）を得る．その後，キャラクターの名前は与えられず，顔とコマのバウンディングボックスが与えられているという条件で，個別の漫画に対して適応した特徴抽出器を距離学習により作成する．漫画に汎用性のある特徴抽出器の学習に用いられる漫画と，その後適応する個別の漫画は異なることに注意が必要である．最後に，得られた特徴抽出器を用いて個別の漫画の顔画像に対する特徴量を抽出し，抽出した特徴量に対して K-means でクラスタリングを行う．

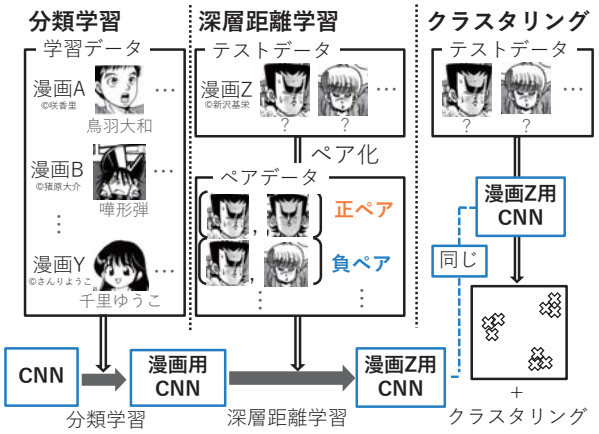


図 1: 手法の概要．分類学習によって漫画に対して汎用性のある特徴抽出器（漫画用 CNN）を作成し，その後深層距離学習により個別の漫画（漫画 Z）に適応した特徴抽出器（漫画 Z 用 CNN）を作成する．最後に K-means により分類を行う．

汎用性のある特徴抽出器の学習は成田ら [Narita 17] の手法に従って行い，個別の漫画に適応した特徴抽出器の学習は提案手法により行う．順に説明する．

3.2 分類学習による特徴量作成

成田ら [Narita 17] の手法に従い漫画に汎用性のある特徴抽出器（漫画用 CNN）を作成する．まず ImageNet [Russakovsky 15] で事前学習されたニューラルネットワークを用意する．その重みを初期の重みとして使用し，キャラクターの顔画像と名前のペアを用いて分類学習を行う．最後にネットワークの後方を除去することにより汎用性のある特徴抽出器を得る．

本研究では，ネットワークとして ResNet [He 16] の 50 層のネットワークを用いた．分類学習後には最終層の fc 層を除去し，代わりに L_2 正規化を行う層を追加したものを特徴抽出器とした．またこの特徴抽出器をベースラインの特徴抽出器とした．

3.3 深層距離学習による適応化

深層距離学習を行うためには正ペア/負ペアを作成する必要がある．しかしながら個別の漫画に対しては顔画像と名前のペアが与えられないので，明示的に正ペア/負ペアは与えられていない．一方で顔とコマのバウンディングボックスは得られているため，顔画像とその顔が属するコマとページが分かる．この情報に基づき正ペア/負ペアを推測する．

ここで漫画特有の性質として，同じキャラクターは近くのコマやページに登場する傾向があるということと，同一のコマに現れるキャラクター同士はほぼ異なるということが挙げられる．前者については，漫画では文脈としてキャラクターが一度登場するとしばらく登場するということから分かる．例を図 2 に示す．後者については，コマは基本的には情景を切り取ったものであるため，同じ情景には同じ人がほぼ登場しないということから分かる．例を図 3 に示す．

よって全ての顔画像について，漫画に汎用性のある特徴抽出器（漫画用 CNN）から得られた特徴量が近くかつ登場ページが近いものを正ペア，同じコマ内のキャラクターは負ペアと定めた．前者について具体的に説明すると，ある顔画像が与えられたときに，その顔画像が登場するページと前後一ページの顔

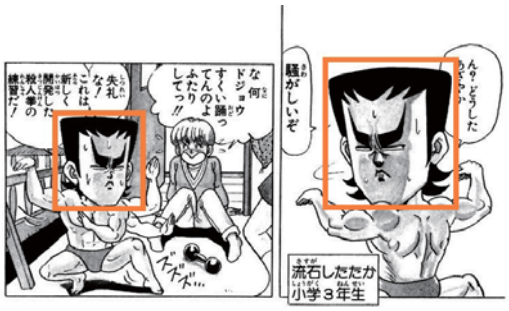


図 2: 同じキャラクターが近くに登場する例． ©新沢基栄



図 3: 同じコマに現れるキャラクター同士が異なる例． ©新沢基栄

画像の中で最も特徴量が近い顔画像を正ペアとした．また後者については，ある顔画像が与えられたときに，同一のコマに登場する全ての顔画像を負ペアとした．

さらに，教師データを増やすことによる性能改善を期待して，ペアの関係を伝搬させ，ペア数を増やした．すなわち I_i と I_j が正ペアかつ I_i と I_k が正ペアならば I_j と I_k は正ペア，I_i と I_j が正ペアかつ I_i と I_k が負ペアならば I_j と I_k は負ペアとした．なお，$I_\cdot$ は画像を意味する．

こうして定義した正ペア/負ペアを用いて深層距離学習で contrastive loss [Hadsell 06] を用いて fine-tune を行うことで個別の漫画に適応した特徴抽出器を作成する．最後に得られた特徴抽出器を用いて全ての顔画像から特徴量を抽出し，特徴量に対して K-means でクラスタリングを行う．

4. 実験

4.1 データセット

データセットとして Manga109 [Matsui 16, Fujimoto 16] を使用した．Manga109 とは学術利用可能な漫画データセットで，様々なジャンルの漫画が 109 冊含まれている．本研究では 109 冊のうち，1 タイトル 2 巻以上あるものに関しては 1 巻を除外し残った 104 冊を使用する．ページにまたがった顔が存在する可能性もあるため，ページは見開きとして扱った．

藤本ら [Fujimoto 16] による顔へのアノテーションは髪や耳を内包する形式ではないので，バウンディングボックスを上下左右に均等に拡大し 2 倍にした．バウンディングボックスは拡大しても漫画の全体ページの画像からはみ出ないようにクリッピングした．また元画像のサイズが小さい場合は顔認識が困難であるため，大きさが 30x30 pixel 以上である顔画像を対象として実験を行った．

104 冊のデータセットのうち，83 冊を漫画に汎用性のある特徴抽出器を作成するための分類学習用データ，10 冊を深層

表 1: テストデータにおける “その他” のクラスを除いたときのクラス数と画像数．括弧内は “その他” のクラスの有無（1/0）と画像数である．

タイトル	クラス数	画像数
ARMS	19 (1)	312 (6)
愛さずにはいられない	16 (1)	860 (60)
あっけら貫刃帖	14 (1)	596 (106)
あくはむ	17 (1)	1012 (9)
青すぎる春	23 (1)	508 (38)
天晴れ！ カッポーレ	14 (1)	831 (22)
ありさ[2]	15 (1)	863 (77)
BEMADER・P	17 (1)	1105 (82)
爆裂！ かんふー娘	61 (1)	988 (22)
ベルモンド	22 (0)	819 (0)
ラブひな 14 巻	20 (1)	1164 (44)

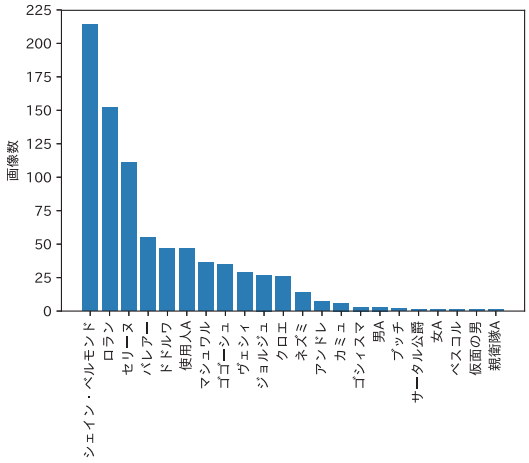


図 4: “ベルモンド” におけるクラスの分布をヒストグラムで表した．クラスのバランスが悪いデータであることが分かる．

距離学習のパラメータ決定用データ，11 冊をテストデータとして分割した．分類学習には，83 冊の漫画で 10 回以上出てくるキャラクターを用いた．クラス数は 1,031 であり，画像数は 67,328 であった，

テストデータにおけるクラス数と画像数を表 1 に示す．漫画ごとにクラス数，画像数が異なるため，クラスタリングの難易度が異なることに注意する必要がある．さらに図 4 に “ベルモンド” の顔画像のクラスの分布をヒストグラムで表した．クラスのバランスが悪いことが分かる．なおこの性質はどの漫画についても言える性質である．

また漫画においては “その他” に相当するクラスがある．通常のクラスはクラス内は同一人物である一方，“その他” のクラスは群衆の一人であったりクラス内でも異なる人物である場合がある．そのためクラスタリング時には除外して扱った．

4.2 評価方法

個別の漫画ごとのクラスタリングを評価の対象とする．クラスター数をキャラクター数としてクラスタリングを行ったときの正規化相互情報量（NMI）と精度で評価を行った．NMI, 精度はクラスタリングの評価に一般に用いられる指標であり順に説明する．説明のために文字の表記を定める．N をデータ数, データ i $(1 \leq i \leq N)$ に対して y_i をクラスター，c_i を正解のラベルとする．NMI は $Y = \{y_1, y_2, \cdots, y_N\}, C = \{c_1, c_2, \cdots, c_N\}$ と表すと，式 2 で定義される．

表 2: クラスタリングの評価

	NMI	精度
ベースライン	0.63	0.48
提案手法	**0.71**	**0.64**
提案手法（ページ条件なし）	0.67	0.58

$$\mathrm{NMI} = \frac{I(Y, C)}{[H(Y) + H(C)]/2} \tag{2}$$

$I(\cdot, \cdot)$ は相互情報量，$H(\cdot)$ は情報量である．また精度は式 3 で定義される．

$$(\text{精度}) = \frac{1}{N} \max_{mapping} \sum_{i=1}^{N} \delta_{c_i, mapping(y_i)} \tag{3}$$

mapping は排他的にクラスターにラベルを割り当てる関数であり精度が最大になるような *mapping* を使用する．また δ はクロネッカーのデルタである．

4.3 実装の詳細

分類学習時においては，200 epoch 行い，学習率は最初の 100 epoch は 10^{-3}，残りは 10^{-4} とした．ミニバッチのサイズは 64，weight decay は 10^{-4} とした．入力画像は 256x256 の画像にリサイズし，224x224 にランダムクロップし，ミラーリング，ガンマ補正を使用してデータ拡張を行った．

深層距離学習においては，100 epoch 行い，学習率は 10^{-3} を使用した．ミニバッチのサイズは 64 とし，ミニバッチ内での全てのペアについて学習を行った．データ拡張としては先述したランダムクロップとミラーリングを使用した．式 1 におけるマージン τ はパラメータ決定用データを用いてパラメータの決定を行い，1.4 とした．

4.4 結果

まず，テストデータの各漫画でクラスタリングを行ったときの，精度と NMI の平均値を比較することで提案手法の有効性を示す．表 2 はベースラインと提案手法，さらに提案手法の条件を変えた場合のクラスタリング結果を比較したものである．条件の変え方として，ページを考慮せず特徴量が近いものを正ペアとした場合との比較を行っている．ベースラインと提案手法を比較すると NMI は 0.08，精度は 0.16 向上している．特徴量が改善されていることが分かる．またページ条件なしと比較して提案手法が NMI，精度において上回っていることから漫画特有の情報であるページという情報を入れた効用があることが分かる．

次に各漫画に対して評価したときの NMI を図 5 に示す．いずれの漫画についても，ベースラインよりも提案手法の方が上回っていることが分かる．

なお，テストデータの各漫画において作成した正ペア/負ペアを，適合率を用いて評価したところ，それぞれ 0.84, 0.93 であった．提案した正ペア/負ペアは十分に正しいことが分かった．

最後に “天晴れ！ カッポーレ” に対して得られた特徴量を t-SNE を用いて可視化した．得られた可視化結果を図 6 に示す．特徴量がよりまとまり，クラスタリングしやすい特徴量になっていることが分かる．

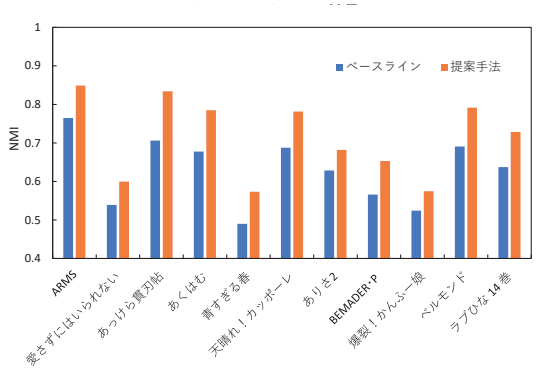
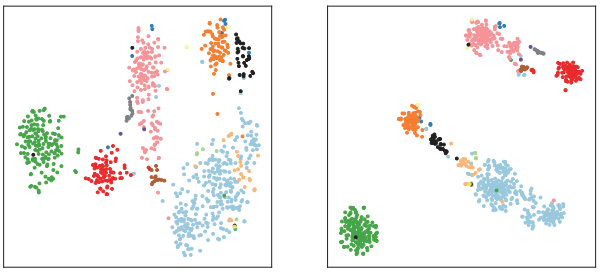


図 5: 各漫画におけるクラスタリングの結果の NMI での評価．いずれの漫画においても提案手法がベースラインよりも上回っている．



ベースライン　　提案手法

図 6: ”天晴れ! カッポーレ”における特徴量の可視化．各点の色がキャラクターに対応する．提案手法の方が特徴量がより集まっていることが分かる．例えば薄い水色のクラスと薄い橙色のクラスは，ベースラインでは区別することが難しいものの，提案手法により区別しやすくなっている．

5. まとめ

本研究では，コマとキャラクターの顔のバウンディングボックスが得られているという条件で，個別の漫画に対して漫画特有の正ペア/負ペアを導入して深層距離学習を行うことで特徴量を作成し，クラスタリングを行った．深層距離学習を行わない場合と比較して NMI が平均 0.08，精度が平均 0.16 向上した．

本手法を新しく与えられた漫画に適用するときには，実際にはコマと顔の検出を行う必要がある．そのため，顔分類の性能は検出の精度に依存する．そこでバウンディングボックスと顔の分類を同時に行うということも発展として考えている．

参考文献

[Bay 06] Bay, H., Tuytelaars, T., and Van Gool, L.: Surf: Speeded up robust features, *European Conference on Computer Vision*, pp. 404–417 (2006)

[Chu 17] Chu, W.-T. and Li, W.-W.: Manga FaceNet: Face Detection in Manga Based on Deep Neural Network, in *ACM International Conference on Multimedia Retrieval*, pp. 412–415 (2017)

[Fujimoto 16] Fujimoto, A., Ogawa, T., Yamamoto, K., Matsui, Y., Yamasaki, T., and Aizawa, K.: Manga109 Dataset and Creation of Metadata, in *International Workshop on coMics ANalysis, Processing and Understanding* (2016)

[Hadsell 06] Hadsell, R., Chopra, S., and LeCun, Y.: Dimensionality reduction by learning an invariant mapping, in *IEEE Conference on Computer Vision and Pattern Recognition*, Vol. 2, pp. 1735–1742 (2006)

[He 16] He, K., Zhang, X., Ren, S., and Sun, J.: Deep Residual Learning for Image Recognition, in *IEEE Conference on Computer Vision and Pattern Recognition* (2016)

[Levi 04] Levi, K. and Weiss, Y.: Learning object detection from a small number of examples: the importance of good features, in *IEEE Conference on Computer Vision and Pattern Recognition* (2004)

[Matsui 16] Matsui, Y., Ito, K., Aramaki, Y., Fujimoto, A., Ogawa, T., Yamasaki, T., and Aizawa, K.: Sketch-based manga retrieval using manga109 dataset, *Multimedia Tools and Applications* (2016)

[Narita 17] Narita, R., Tsubota, K., Yamasaki, T., and Aizawa, K.: Sketch-based Manga Retrieval using Deep Features, in *International Workshop on coMics ANalysis, Processing and Understanding* (2017)

[Russakovsky 15] Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A. C., and Fei-Fei, L.: ImageNet Large Scale Visual Recognition Challenge, *International Journal of Computer Vision*, Vol. 115, No. 3, pp. 211–252 (2015)

[Zhang 16] Zhang, Z., Luo, P., Loy, C. C., and Tang, X.: Joint face representation adaptation and clustering in videos, in *European Conference on Computer Vision*, pp. 236–251 (2016)

[小川 17] 小川 徹, 山﨑 俊彦, 相澤 清晴 : 漫画物体検出に向けた検出器の並列化, 情報科学技術フォーラム (2017)

[柳澤 17] 柳澤 秀彰, 渡辺 裕 : Deep Learning 特徴量を用いたマンガキャラクター顔画像の分類, 情報科学技術フォーラム (2017)

Oral presentation | Organized Session | [Organized Session] OS-10

[1K3-OS-10a] [Organized Session] OS-10

Tue. Jun 5, 2018 5:20 PM - 7:00 PM Room K (3F Azisai Mokuren)

[1K3-OS-10a-01] Support system of assigning label to acoustic event in pig farm by automatic extraction of acoustic event and showing both acoustic event and movie

○Misaki Mito[1], Takuji Kawagishi[1], Koichi Mizutani[1,2], Keiichi Zempo[1,2], Naoto Wakatsuki[1,2], Nobuhiro Takemae[3], Takehiko Saito[3] (1. Graduate School of Systems and Information Engineering, Univ. Tsukuba, 2. Faculty of Engineering, Information and Systems, Univ. Tsukuba, 3. National Institute of Animal Health, NARO)

5:20 PM - 5:40 PM

[1K3-OS-10a-02] Multi-spectroscopic sensing of lettuce for freshness measurement using machine learning

○Takaharu Kameoka[1], Akane Tsukahara[1], Shinichi Kameoka[1], Ryoei Ito[1], Atsushi Hashimoto[1] (1. Mie University)

5:40 PM - 6:00 PM

[1K3-OS-10a-03] Preliminary study for discriminating oil palm ripeness by using color chart

○Kaiko Minakata[1], Kazuki Kobayashi[1], Kunihisa Tashiro[1], Hiroyuki Wakiwaka[1], Hirokazu Nagata[2], Norhisam Misron[3], Nor Aziana Aliteh[3], Takuma Hasegawa[1], Masaki Futamata[1] (1. Graduate School Science and Technology, Shinshu university, 2. Grobal Education Center, Shinshu University, 3. Faculty of Engineering, Universiti Putra Malaysia)

6:00 PM - 6:20 PM

[1K3-OS-10a-04] A Light-Driven Artificial Neural Network Architecture for Deep Neural Network

○Takuya Otsuka[1], Shiori Konisho[1] (1. Nippon Telegraph and Telephone)

6:20 PM - 6:40 PM

[1K3-OS-10a-05] Evaluation of Data Augmentation to Image-Based Plant Disease Detection

○Kenichi Kobayashi[1], Junpei Tsuji[1], Masato Noto[1] (1. Kanagawa University)

6:40 PM - 7:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

豚舎内音響イベントの自動検出および対応動画像の自動提示による音響イベントのラベル割り当て支援

Support system of assigning label to acoustic event in pig farm by automatic extraction of acoustic event and showing both acoustic event and movie

味藤 未冴来[*1] Misaki Mito　川岸 卓司[*1] Takuji Kawagishi　水谷 孝一[*1, 2] Koichi Mizutani

善甫 啓一[*1, 2] Keiichi Zempo　若槻 尚斗[*1, 2] Naoto Wakatsuki　竹前 喜洋[*3] Nobuhiro Takemae　西藤 岳彦[*3] Takehiko Saito

[*1] 筑波大学　大学院システム情報工学研究科
Graduate School of Systems and Information Engineering, Univ. Tsukuba

[*2] 筑波大学　システム情報系
Faculty of Engineering, Information and Systems, Univ. Tsukuba

[*3] 農研機構　動物衛生研究部門
National Institute of Animal Health, NARO

Porcine respiratory disease gives enormous loss to farmers. The number of sneezing increases when swine are infected with the disease. However, it is not verified that increasing the number of sneezing was occurred by swine influenza. To verifying them, under controlled infecting condition, sounds and movies were recorded. In this paper, the purpose is developing the support system to efficient assigning labels to acoustic events. First, to extract acoustic events, recorded sounds was applied frequency filter and classified by threshold level based on the signal to noise ratio. After that, both the acoustic event and movie was shown at the same time automatically. As a result, 30000 samples of acoustic events were extracted among 14 days. By using this system, observer assigned sneezing label to 67 samples in 3000 samples. The maximum speed of assigning was 200 samples per hour. Therefore assigning labels was efficient by this support system.

1. はじめに

豚の呼吸器感染症は伝搬力が強く，感染により繁殖障害や食欲不振などを引き起こし，国内において年間 280 億円の被害をもたらすと試算されている[高木　15]。豚呼吸器感染症の感染症状の初期症状として，音響イベントであるくしゃみ回数の増加が報告されている[仙名　01]。一方でこの報告は豚呼吸器感染症のひとつである豚インフルエンザ特有の症状であるかはわかっていない。そこで筆者らは，図 1 に示すように(国研) 農研機構 動物衛生研究部門にて 14 日間の感染実験を行い，音信号・動画像の収録をし，感染の有無による音響イベントの観測を図った。しかしながら，連続収録した音信号から，くしゃみなどの音響イベントの検出は困難である。また，多数実施する場合，観測者への提示作業を効率化することが望ましい。

そこで本稿では，音信号から豚舎内音響イベントを自動検出し，動画像を用いて観測者に自動提示する。これにより，効率的に適切なラベル割り当てを行い，豚舎内音響イベントのラベル割り当ての支援を目的とする。

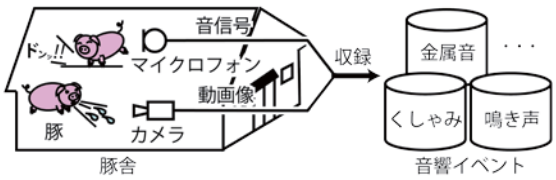


図 1　実験豚舎における収録機材・豚配置

連絡先：味藤未冴来，筑波大学　大学院システム情報工学研究科，〒305-8573　茨城県つくば市天王台 1－1－1，mizutani@iit.tsukuba.ac.jp

2. 豚舎内音響イベントの検出

2.1 実験および収録条件

2016 年 2 月 15 日から 3 月 1 日までの 14 日間，(国研) 農研機構 動物衛生研究部門 越境性感染症研究領域内の実験豚舎にて感染実験を行った。実験では，5 週齢の離乳豚に対し，豚呼吸器感染症のひとつである豚インフルエンザへ感染させ，音信号・動画像の収録を行った。音信号については，マイクロフォン(Panasonic, WM-61A)を用いて，動画像については，Web カメラ(BAFFALO, BSW20KM11)を用いて収録を行った。また，時刻情報について，音信号はファイル内プロパティに埋め込み，動画像は画面上部に文字情報として埋め込み，各ファイルは 1 時間ごとに保存した。

2.2 音響イベントの検出条件

提案する音響イベントの抽出フローを図 2 示す。豚くしゃみ音については，20 kHz 以上の高周波数帯に強度を持ち，継続時間は約 0.5 s 程度といわれている[川岸　14]。このため，検出する音響イベントは，低周波ノイズを除く 4 kHz から 40 kHz の周波数フィルタを適用した後も，暗騒音に対し SN 比 6 dB 以上の信号とする。なお，音響イベントの切り出し時間を 1.5 s とし，50%のオーバーラップで時間方向に走査し，0.5 - 1 s に最も強度を持つ音信号を抽出することで，処理負荷を軽くした。

3. 音響イベントと動画像を用いる提示

3.1 音響イベント対応する動画像の探索

音響イベントの時刻情報はファイル内のプロパティより取得できるが，動画像は直接取得できない。そこで動画像上部の時刻情報が保存されている領域を切り出し，OCR により時刻情報を取得した。取得した時刻情報を用いて，音響イベントに対応する動画像 2 つそれぞれの区間を切り出した。

3.2 音響イベントと動画像の提示・ラベル割り当て

図 3 示すようなインターエースで，音響イベントおよび動画像を同時に自動提示した。なお，わかりやすいように，音響イベントのスペクトログラムも同時に提示している。

4. 観測者による音響イベントのラベル割り当て

4.1 実施条件

2 節において検出した豚舎内音響イベント全体で，14 日間のうち約 3 万サンプルを検出した。構築した音響イベント提示環境を用いて，このうち約 3000 サンプルを観測者 2 名によってラベル割り当てした。

4.2 実施結果と考察

観測者によって，図 4 のような音響イベントのラベル割り当てがされ，判定した音響イベントからくしゃみ音は 67 サンプル観測された。加えて，ラベル割り当て作業は判定以外が自動化され，観測者は 1 時間当たり最大 200 サンプルもの多くのラベルを割り当てができた。一方で，図 4(a)のようなくしゃみ音金属製の餌箱をゆする音などの発生数は特に多く，これらの特徴を分析し，適切に判別する必要性が考えられる。

5. 結論

本稿では，音信号から豚舎内音響イベントを自動検出し，動画像を用いて観測者に自動提示する。これにより，効率的に適切なラベル割り当てを行い，豚舎内音響イベントのラベル割り当ての支援を目的とした。結果として，観測者は 3000 サンプルに対してラベル割り当てを行い，このうちくしゃみ音は 67 サンプル存在した。また，ラベル割り当ては，1 時間あたり最大 200 サンプルの速さであり，本支援システムが割り当て作業の効率化をもたらした。

今後の課題として，音響イベントの特徴を抽出・自動判別を行い，インフルエンザ特有の音響イベントの変化を明らかにしていくことなどが挙げられる。

謝辞

本研究は JSPS 科研費 16H05008 の助成を受けた。

参考文献

[川岸 14] 川岸卓司，松梨夏季，水谷孝一，若槻尚斗: 豚の咳・くしゃみ監視システムに関する研究，農業施設学会誌，Vol.45, No.1, pp.1-7, 農業施設学会, 2014.

[仙名 01] 仙名和浩: 呼吸器感染症の湿潤と咳・くしゃみ回数，All About Swine, Vol.19, pp.9-11, 日本 SPF 豚研究会，2001.

[高木 15] 高木道浩: 豚繁殖呼吸障害症候群：感染とワクチン，All About Swine, Vol.47, pp.2-9, 日本 SPF 豚研究会, 2015.

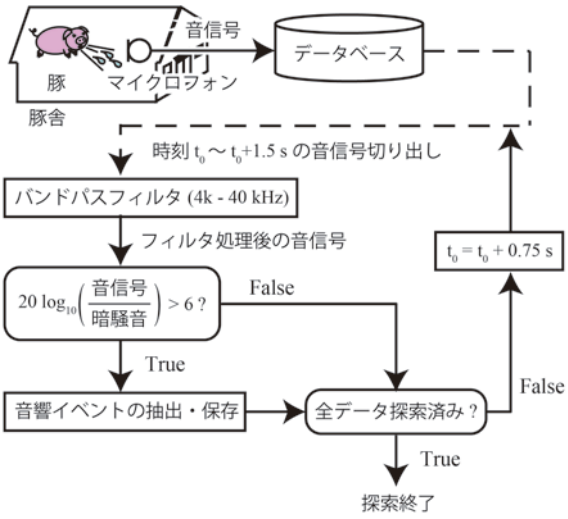


図 2 音響イベントの抽出フロー

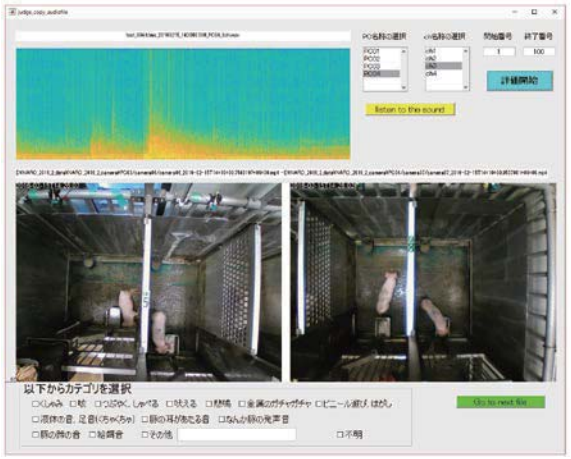


図 3 音響イベントと動画像の提示によるラベル割り当て環境

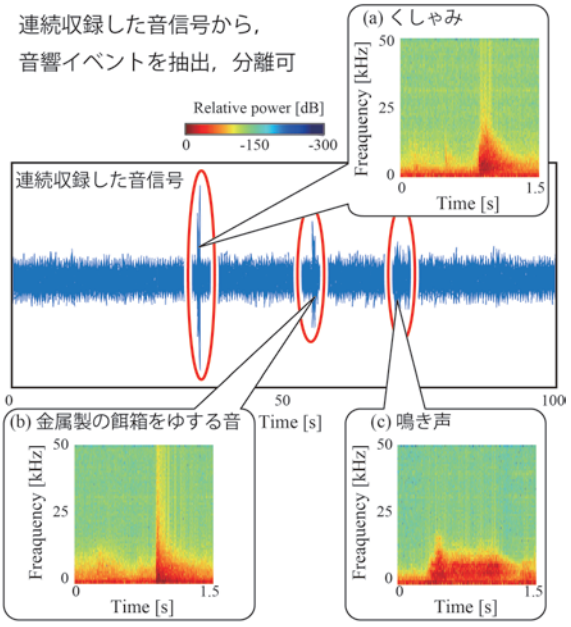


図 4 ラベル割り当てされた音響イベントの例

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

機械学習を用いた鮮度計測に向けたレタスのマルチ分光センシング

Multi-spectroscopic sensing of lettuce for freshness measurement using machine learning

亀岡 孝治　塚原茜　亀岡 慎一　伊藤 良栄　橋本 篤
Takaharu Kameoka　Akane Tsukahara　Shinichi Kameoka　Ryoei Ito　Atsushi Hashimoto

三重大学大学院生物資源学研究科
Graduate School of Bioresources, Mie University

Many conventional freshness (quality) measurement methods are separation analysis, and there are a number of problems such as extremely time-consuming measurement etc. in this analysis. Therefore, in this study, attention was focused on elements and organic matter, and tried to quantify the process of degradation of lettuce. Furthermore, from the surface color and moisture measurement, the relationship between freshness (deterioration) evaluation by appearance quality and objective evaluation is grasped and data set and evaluation method for freshness evaluation leading to machine learning in the future were studied. As a result, it became clear that there is a relationship between surface color and internal quality. It is suggested that freshness of lettuce can be quantified and predicted using only surface color information if accumulating experimental data and constructing a relationship between color change and internal quality using machine learning and depth learning.

1. はじめに

従来の鮮度・品質計測手法の多くは分離分析であり，計測に非常に時間が掛かる等の問題点が多数存在した．そこで，本研究では元素と有機物に着目し，レタスの劣化過程の定量を試みた．さらに表面色彩と水分計測から，外観品質による鮮度（劣化）評価と客観的評価の関係性を把握し，将来的に機械学習に繋がる鮮度評価のためのデータセットと評価方法を検討した．

2. 実験試料，実験装置および方法

2.1 実験試料

実験には，2017 年 12 月 5 日に淡路島で収穫されたレタス（ベルデ 7）24 個体を用いた．本研究では 10 個体使用し，残り実験条件の検討などのための予備実験に用いた．レタスの平均重量は 333.1g，標準偏差は 41.9g である．

2.2 実験装置および方法

レタス 8 個体を用い，2 種類の保蔵実験を行った．まず，レタス 1 個体の連続保蔵実験，2 つ目は毎日レタスを解体して結球内部の元素と有機物を計測する段ボール箱保蔵実験である．

(a) 連続保蔵実験

レタスの連続保蔵実験のための連続保蔵実験装置を試作した（図 2）．保蔵容器の両側部に撮影用高性能 LED ライト、上部に一眼レフレックスカメラ（Canon 社製 EOS Kiss X3）を取り付けた．保蔵容器の上部蓋に撮像用の透明ガラスを取り付け，側面と底面には照明光を拡散させるためのケント紙を貼り付けた．また容器内部に電子天秤を組み込み，天秤上の結球レタス中心部に照明が当たる位置に保蔵容器を設置した．また、全体を暗幕で覆い外部からの光を遮断した．保蔵容器内の温湿度はペルチェ素子，飽和塩法（$MgCl_2$）を用いて 25℃，33%に制御し，劣化を加速させる実験を行った．さらに電子天秤・一眼レフカメラ・温湿度計をラズベリーパイに接続し，自作したデータ取得プログラムを用いて自動計測した．画像撮像は 1 時間毎とし，撮像 15 分前に照明を点灯し 15 分後消灯するよう設定した．

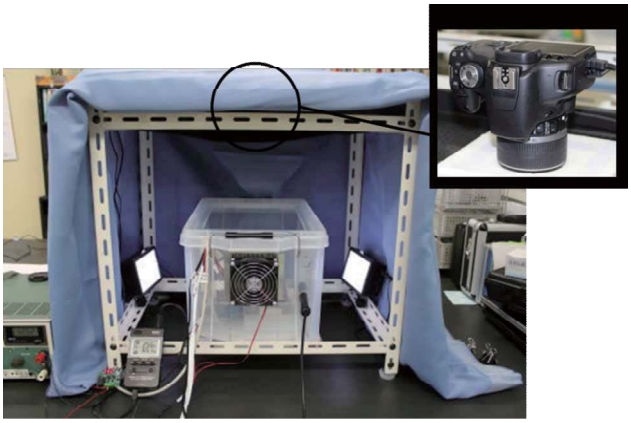


図 1　連続自動計測保蔵容器

(b) 段ボール箱保蔵によるレタスの解体実験

飽和塩法を用いて相対湿度を 33%に制御した段ボール箱 9 箱にレタスを 1 個体ずつ入れ，これらを 25℃設定にインキュベータに保存し，7 日間毎日1個体の解体実験を行った．蛍光 X 線分析装置（OLYMPUS 社製 DELTA Premium）を垂直に設置し，各葉 3 点で元素計測を行った（Kameoka 2017）．また、赤外分光分析には赤外分光光度計（PerkinElmer 社製 Supectrum two）と ATR アクセサリ（以下 FTIR/ATR 法）を用いレタス葉の中赤外分光スペクトル取得のための最適荷重の検討を行った．

3. 実験結果および考察

3.1 連続保蔵実験

レタスの水分変化は、保蔵開始から 7 時間までは恒率減少，7~78 時間で減率減少，78 時間以降では再び恒率減少的減少となったため，これをレタスの劣化特性曲線とした．

保蔵 6 日間 1 時間置きに撮像した合計 143 枚のレタス連続画像解析を OpenCV を用いてレタス表面画像の色彩変化を取得した．色相は減少傾向，彩度は増加してから減少傾向，明度は増加傾向であり，各時間における色彩ヒストグラムの標準偏差

連絡先：亀岡孝治，三重大学大学院生物資源学研究科，
〒514-8507 三重県津市栗真町屋町 1577，
Tel. 059-231-92468, E-mail: kameoka@mie-u.ac.jp

は保蔵時間が経過するにつれ減少し一定値へ収束する傾向が認められた．色相値では，保蔵開始から 25 時間と 123 時間で変化直線の傾きが変化した．彩度値は 88 時間まで増加，89~132 時間で減少，133~139 時間で一定値をとるという変化傾向が認められた．明度は，69 時間と 132 時間で変化直線の傾きが変化した．レタス表面の色彩変化傾向が変わる時間を把握することで，レタスの劣化段階を予測できる可能性が示された．

また，色相分布は正規分布で近似でき，平均値は減少しつつ分布の最大値が大きくなる傾向が認められた．彩度分布はγ分布で近似でき平均値が増加したのちに減少する傾向が認められた．これらの結果から，色相，彩度分布は各分布のパラメータを用いてレタスの劣化段階を推定できる可能性が示唆された．

3.2 段ボール箱保蔵によるレタスの解体実験

保蔵 6 日間の内部の葉の水分計測，元素計測，さらに有機物計測を行った．レタスの水分減少は主に外葉 1，2 枚と芯から始まり，内部水分は保蔵中ほぼ変化しないということが示された．

次にレタスの多量元素である K，Ca，P の変化傾向を確認した． レタス体内で元素の生成・損失が生じないことから保蔵に伴う各元素の増加は， レタス組織劣化に伴う元素のバランス変化，または，水分損失に伴う葉の収縮により元素が濃縮され，蛍光 X 線視野内に計測可能な元素数が増加することが原因であると考えられる． 図 2 に各葉 1 枚目～7 枚目の K，Ca，P の保蔵に伴う変化を示す．外葉 1，2 枚目で K，Ca は，水分が大きく変化した時間 3 日目と 4 日目の間で急激に増加した．P は Ca，K とは異なる挙動を示した．もし，レタス組織が変化せず，単に水分が減少するだけであれば，すべての元素は同じ傾向で増加すると考えられるが各元素は別々の変化傾向をとる．これは，レタス組織内で元素バランスが崩れてきており，レタスの何等かの劣化を示していると考えられる．

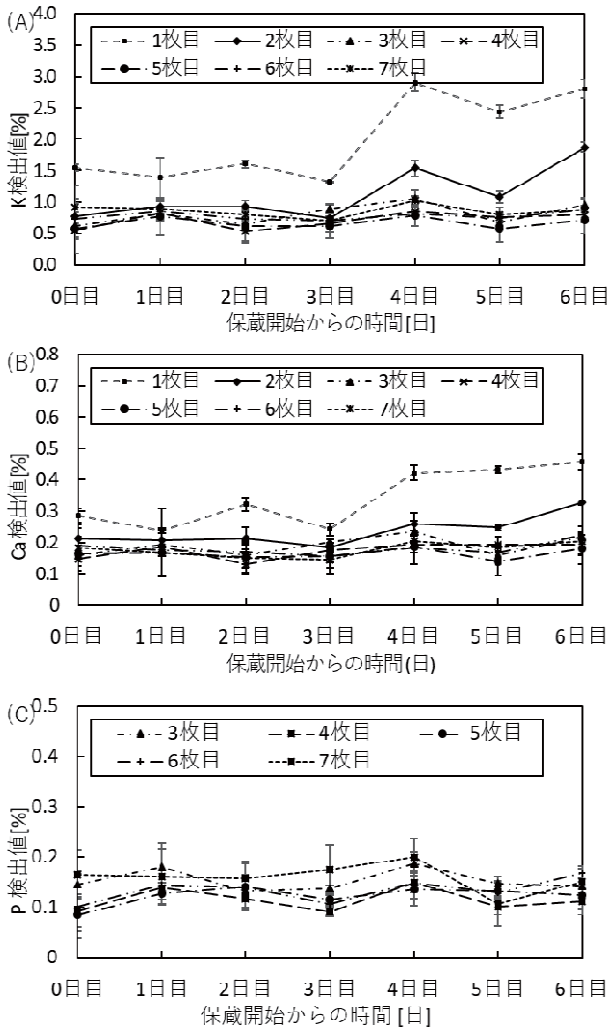


図 2　蛍光 X 線元素計測結果

(A)K　(B)Ca　(C)P

有機物の劣化をとらえるため， FT-IR/ATR 法を用いて赤外分光スペクトルを取得した．植物の葉表面の被覆層と細胞壁で数μm であり，ATR 法によるしみ込み深さも数μm であることから今回のスペクトル情報はこれらの情報であると考え、ワックス，セルロース，ペクチンの 3 成分に着目した．ワックスとセルロースとして波数 2924cm^{-1}、ペクチンとして波数 1736cm^{-1}、セルロースのみの波数として 1636cm^{-1} に着目した．しかし、6 各日間のばらつきが大きく劣化による特徴的な変化は確認できなかった．

4. おわりに

レタス結球の水分変化と色彩変化情報にダンボール実験で得られた，保蔵 1 日目から 7 日目までのレタスの内部情報を組み合わせることで，レタス結球の外部情報と内部情報を用いてレタス劣化過程を複合的に考察した．今回得られた水分変化曲線をベースに色彩変化，内部の多量元素として K，Ca，P のバランスの変化で大きな変化が認められた時間を総合的に表現したレタスの鮮度変化を図 3 に示した．

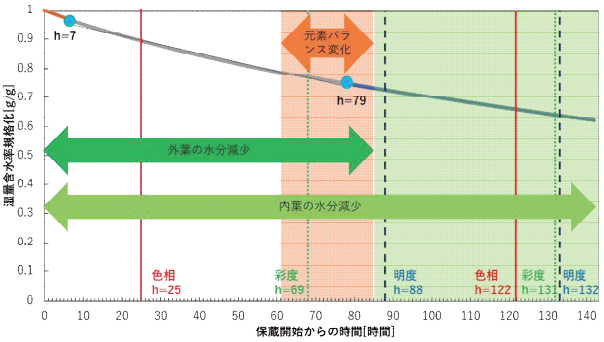


図 3　レタスの鮮度変化

このレタス表面色彩変化と外葉と内葉の水分変化、加えて外葉と内葉の元素バランスの変化を具体的に整理する。葉の劣化に伴い外葉と内葉の元素バランスの変化が生じると考えると、劣化は 61 時間から 79 時間で生じていると考えられる。そこで、61 時間より前に生じる大きな変化点として、25 時間での色相値の変化点があげられる．また，外葉水分変化が恒率になる 79 時間より前の 69 時間に彩度値の変化点が現れていることが分かる．このように、表面色彩から外葉の水分と品質の予測ができる可能性が示唆された．さらに， 第 2 段階目の変化 79 時間以降でも 5 点の色相，彩度，明度の変化点が認められたため，実験データを蓄積し機械学習・深層学習を用いて色彩の変化点と内部品質の関係性などの解析を行うことで、表面の色彩情報だけを用いてレタスの鮮度を定量・予測できる可能性が示された．

参考文献

[Kameoka 2017] Kameoka, S. et al.: A Wireless Sensor Network for Growth Environment Measurement and Multi-Band Optical Sensing to Diagnose Tree Vigor. Sensors, 2017.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

カラーチャートによるオイルパーム成熟度判別に向けた基礎検討

Preliminary study for discriminating oil palm ripeness by using color chart

皆方 快公[*1] 小林 一樹[*1] 田代 晋久[*1] 脇若 弘之[*1] 永田 浩一[*2]
Kaiko Minakata Kazuki Kobayashi Kunihisa Tashiro Hiroyuki Wakiwaka Hirokazu Nagata

Norhisam Misrom[*3] Nor Aziana Aliteh[*3] 長谷川 拓真[*1] 二俣 昌樹[*1]
Takuma Hasegawa Masaki Futamata

[*1] 信州大学 大学院 総合理工研究科
Graduate School of Science and Technology, Shinshu University

[*2] 信州大学グローバル教育推進センター
Grobal Education Center, Shinshu University

[*3] Faculty of Engineering, Universiti Putra Malaysia

The purpose of this study is to compare human vision and Color chart to discriminate oil palm ripeness. First of all, moisture content of oil palm is estimated by human vision. And R value of RGB is extracted from oil palm pictures. Then it is evaluated by using testing of statistical hypothesis whether moisture content that is estimated by human vision can be discriminated by Color chart or not. As a result, combination of unripe and ripe, under-ripe and ripe can be discriminated by using Tukey test. But combination of unripe and under-ripe cannot. It is concluded that Color chart is not comparable to human vision yet.

1. はじめに

オイルパームはギニアアブラヤシから採油される西アフリカ発祥の世界で最も生産されている油脂植物である. 現在, 総生産量のうちの 85 %がマレーシアとインドネシアで生産されている. これらの 2 国にとってオイルパーム産業は国の経済に大きな役割を担っている. それ故, 効率的に生産するために, オイルパームに関する研究が盛んに行われている.

オイルパームに関する研究の1つとして成熟度判別がある. 成熟度は主に油の抽出率に影響を与え, 生産量に影響を与える. 現在主流な成熟度の判別方法は,「落ちている実の数」と「実の表面の色」を目視することで判別する[MPOB 03]. そのため, 判別者ごとの感覚によって結果にばらつきが発生する問題が生じる. そこで, 人の目に代わって, カメラで撮影したオイルパームの写真の色から成熟度判別を行う方法がある. この方法を用いることで, 非破壊に成熟度の判別が可能となる. しかし, 天候や時間帯といった撮影環境に影響を受けやすいという欠点がある.

先行研究[Makky 16]では, 撮影環境を一定にするために, 房が入るほどの大きめの箱に LED を封入して 500 ルクスという一定光源下で RGB 値を抽出することで, オイルパームの成熟度の判別を行っていた. しかしこの方法では, 実験に用いる器具の総重量が 5 kg と決して手軽とは言えない重さであった.

筆者らは, オイルパームの成熟度判別にカラーチャートを用いる[島田 11]. カラーチャートを用いることで, 人の目による判別誤差を防ぐことが見込まれる。カラーチャートの利点は, たとえ一定光源下でなくとも, 同じ基準で RGB 値の抽出を行える. 水分量と成熟度に関係が存在するという報告[Siregar 76]から, 抽出した RGB 値から水分量を推定して成熟度の判別を行うことを提案する.

本報告では, カラーチャートを用いた成熟度判別法を評価するために, まず目視によって水分量範囲の推定を行った. そして, カラーチャートを用いて目視による水分量範囲を判別できるかを比較し, 評価したので報告する.

連絡先:田代晋久, 信州大学田代研究室,
〒380-8553, 長野県長野市若里 4-17-1,
Tel: 026-269-5194, Email: tashiro@shinshu-u.ac.jp

2. 基本原理

2.1 RGB 値

RGB 値とは, 赤(R), 緑(G), 青(B)を組み合わせて様々な色を表現することができる加法混合の一種である. 主に, ブラウン管や液晶ディスプレイなどに使用されている.

RGB はそれぞれ 0 ~ 255 の値を取り, 合計約 1670 万色の色を表現することができる. 例えば, (R, G, B) = (255, 255, 255)であれば白色, (R, G, B) = (0, 0, 0)であれば黒色となる.

本報告ではオイルパームが成熟とともに赤みを増していくことから, R 値(赤色の成分)に着目し, 抽出して評価を行った.

2.2 カラーチャート

図 1 にカラーチャートの構成図を示す. カラーチャートは画像から RGB 値を抽出する際に, 撮影環境による影響を補正するために用いられる.

図 1 よりカラーチャートは AR マーカと 12 色のカラーチップで構成されている. 各カラーチップは, AR マーカの中心から相対距離で管理されており, 写真撮影時に, AR マーカの位置と姿勢から各カラーチップの位置を自動的に把握してカラーチップの画素値を抽出する.

2.3 色補正[島田 11]

線形回帰分析により, 補正前画像が基準画像に近づくように基準画像のカラーチップと補正前のカラーチップから変換行列を求める. 補正後画像を求めるための式を式(1)に示す. C'は補正後の画素値, a は 3 行 4 列の回帰係数行列, C は補正前の画素値を表す. 補正画像の全画素に変換行列を適用することで色補正された画像を得る. 図 2 に前報[島田 11]で報告された補正例を示す. 図 2 より, (a)の補正前は画像全体が暗い. しかし, 補

正を行うことで(b)のようになり，(c)の基準画像に近い画像が得られている.

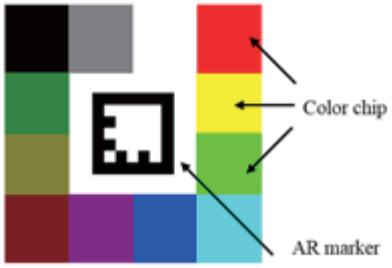


図 1: カラーチャートの構成図

$$\begin{bmatrix} C'_r \\ C'_g \\ C'_b \end{bmatrix} = \begin{bmatrix} a_1 & a_4 & a_7 & a_{10} \\ a_2 & a_5 & a_8 & a_{11} \\ a_3 & a_6 & a_9 & a_{12} \end{bmatrix} \begin{bmatrix} C_r \\ C_g \\ C_b \\ 1 \end{bmatrix} \quad (1)$$

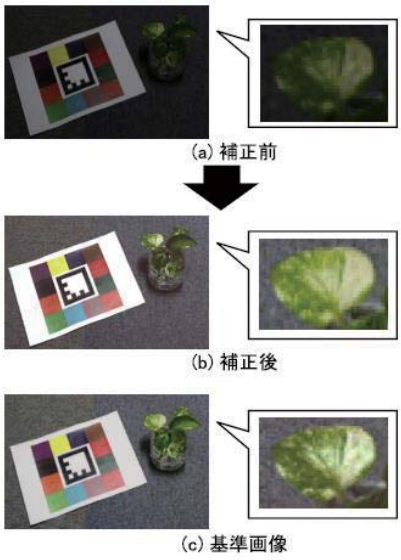


図 2: カラーチャートによる画像補正例[島田 11]

2.4 目視による成熟度の定義

本報告で用いたオイルパームの成熟度の定義を表 1 に示す. 実の成熟度は採取のしやすさと実の表面の色から定義を行った. 表 1 より,「未熟」は採取時に金槌が必要かつ青紫色の実,「成熟過程」は金槌が必要かつ赤紫色,「成熟」は手で採取が可能かつ橙色の実とした。図 3 に各成熟度のオイルパームの外観図を示す.

表 1: 本報告で用いた成熟度の定義

Stage of ripeness	The way how to take fruits	Oil palm color
Unripe	Hammer	Bluish purple
Under-ripe	Hammer	Reddish purple
Ripe	Hand	Orange

2.5 検定方法

「未熟-成熟過程」,「未熟-成熟」,「成熟過程-成熟」の条件間に有意差が存在するかを統計的に評価するために, 多重比較法の 1 つである Tukey の範囲検定を用いた.

多重比較法とは, 有意水準 α において, すべての組み合わせを同時に比較することができる検定方法である. 本報告では, 多重比較法の中でも最もよく利用される Tukey の範囲検定を用いた[石村 10]. Tukey の範囲検定を行うためには, 標本が正規分布に従うかつ分散が等しいかを確認する必要がある. 以下に検定の流れを示す.

① $\alpha = 1$ %で一元配置分散分析を行い, 各成熟度の組み合わせの母平均間に有意差を確認する. 有意確率 p を導出, $p < 0.01$ ならば「母平均間に有意差を認める」, $p > 0.01$ ならば「母平均間に有意差を認められない」とする.

② Tukey の範囲検定を用いて $\alpha = 1$%として, 各条件間に有意差が存在するかを確認する. 有意確率 p を導出, $p < 0.01$ ならば「成熟度間に有意差を認める」, $p > 0.01$ ならば「成熟度間に有意差を認められない」とする.



(a) 成熟　(b) 成熟過程　(c) 未熟

図 3: 成熟度別のオイルパームの外観図

3. 目視による水分量推定

3.1 実験方法

目視によるオイルパームの水分量範囲を不偏標準偏差 s を求めることで推定するために, オイルパームの房から〈2･4〉の定義に従って未熟 83 個, 成熟過程 68 個, 成熟 63 個の合計 214 個の実を採取した. 採取した後, 赤外線水分計(kett 社, FD-610)を用いて水分量 m [%]の測定を行った.

3.2 実験結果

図 4 に各成熟度の水分量 m [%]の確率密度関数 $p(x)$を示す. いずれの $p(x)$は正規分布に従う形となった. 表 2 に水分量の平均値 m_a [%]と不偏標準偏差 s を示す.「成熟」の s が最も小さいのでばらつきが小さい.「成熟過程」の s が最も大きいのでばらつきが大きい結果となった. 各成熟度の平均値に着目すると, 成熟 $m_r = 26$ %, 成熟過程 $m_m = 49$ %, 未熟 $m_u = 81$ %であり, 成熟した実ほど水分量の平均値が低い結果となった.

表 2: 各成熟度の水分量の平均値と不変標準偏差

Stage of ripeness	Average of moisture, m_a [%]	Sample standard deviation, s [%]
Unripe	81	6
Under-ripe	49	11
Ripe	26	5

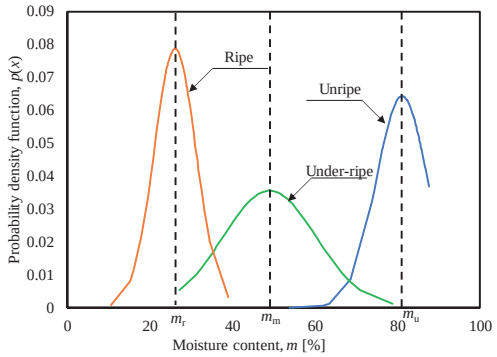


図 4: 各成熟度の水分量の確率密度関数

3.3 考察

ここで, 目視によるオイルパームの水分量範囲の推定を行う。まず各成熟度の水分量範囲が重ならなくなる不偏標準偏差 s を求める.

各成熟度の水分量範囲が重ならなくなる s を見つけるために s= 2.0, 1.9, 1.8…のように, s を 0.1 ずつ小さくしながら代入をして水分量範囲 m_a [%]を算出した. すると, s =1.4 で各水分量範囲が重ならなくなった. 表 3 に s =1.4 における水分量範囲 m_r[%]と調整した水分量範囲 m_{ra} [%]を示す. しかし, 表 3 より「未熟」の最小値は 72 %,「成熟過程」の最大値は 64 %となり, 連続ではない部分が現れた. そこで, 連続にするために 64 %と 72 %の中間値である 68 %を「成熟過程」と「未熟」の境界とした. 以上より, 2･4 節の基準に従って採取を行うと, 83.8 %の確率(s = 1.4)でオイルパームの水分量は 19 %~33 %(成熟), 33 % ~ 68 %(成熟過程), 68 % ~ 90 %(未熟)となることが推定された.

4 章では目視による水分量範囲をカラーチャートによって判別可能かを統計的に評価する.

表 3: 目視により推定された水分量範囲

Stage of ripeness	The range of moisture, m_r [%]	The adjusted range of moisture, m_{ra} [%]
Unripe	$72 < m < 90$	$68 < m < 90$
Under-ripe	$33 < m < 64$	$33 < m < 68$
Ripe	$19 < m < 33$	$19 < m < 33$

4. R 値による成熟度判別可能性評価

4.1 実験方法

カラーチャートによる方法を評価するために, オイルパームから R 値(赤色)の抽出を行い, 統計的処理を行った. カラーチャートからオイルパームの R 値を抽出するまでの手順を簡単に以下に示す.

(1) 図 5 にオイルパームから R 値の抽出するための実験模式図を示す. 図 5 のようにカラーチャートと共にオイルパームの写真を撮影

(2) 式(1)を用いて, 基準画像と同様の撮影環境になるように画像を補正

(3) 重線形回帰を用いた色抽出ソフトでオイルパームの上部の R 値の抽出

R 値の取得後, 赤外線水分計(kett 社, FD-610)を用いて水分量 m [%]を測定した. 水分計の設定は, 加熱温度 115 度, 加熱時間 60 分とした. 測定した水分量は 3 章で推定した水分量範囲, 68 ~ 90 %(未熟), 33 ~ 68 % (成熟過程), 19 ~ 33 % (成熟)に割り振り, 各成熟度間に有意差が認められるかを評価するために Tukey の範囲検定を用いた.

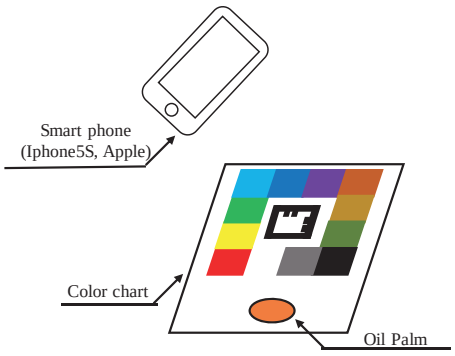


図 5: R 値を抽出するための撮影模式図.

4.2 実験結果

図 6 に各成熟度の R 値の箱ひげ図を示す.「成熟」は 8 ~ 129 で R 値のばらつきが最も大きい.「成熟過程」と「成熟」は 0 ~ 80 でほとんど同じ範囲であった. 各成熟度の R 値の平均値(図 9 中×印)に着目すると, 成熟は 55, 成熟過程 21, 未熟 26 で成熟しているものが最も R 値が高いという結果となった. 成熟したオイルパームは橙色であることから R 値が高いので, 予測通りの結果が得られた.

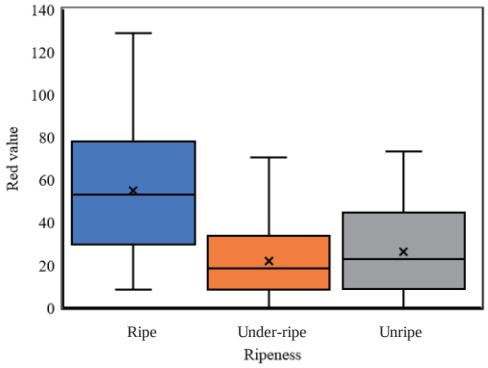


図 6 : 各成熟度の R 値の箱ひげ図

4.3 考察

成熟度間の R 値の平均値に有意差が存在するかを確認するために, Tukey の範囲検定を用いて 2･5 節の手順に従って多重比較検定を行う.

① α = 1 %として一元配置分散分析を行うと, 有意確率 $p = 2\times10^{-14}$($F(2, 175) = 37.931$, $p<.01$)であった. このことから, p が 0.01 より小さいので各成熟度の母平均間には有意差があることを確認した.

② α = 1 %として Tukey の範囲検定を行った時の有意確率と判別可能性を表 4 に示す. 表 4 より, 有意水準 α = 1 %の時, p が 0.01 を下回ったものは「成熟過程-成熟」,「未熟-成熟」であった. 一方, p が 0.01 を上回ったものは「成熟過程-未熟」であった.

以上より,「成熟過程-成熟」,「未熟-成熟」の 2 つの組み合わせでは有意差が認められ,「成熟過程-未熟」の間には有意差が認められなかった. このことから, R 値を用いることで,「成熟過程-成熟」,「未熟-成熟」は判別可能性があることが示唆された.

ここで目視による方法と比較する. R 値では「成熟過程-成熟」,「未熟-成熟」の 2 つの組み合わせの判別可能性が示唆された. しかし,「成熟過程-未熟」は有意差が示唆されなかった.すなわ

ち, 目視によって推定できた水分量範囲をカラーチャートのR値では推定することができなかったこととなる. このことから, カラーチャートのR値を用いる方法は, 現段階では, 目視に対して優位性がないことが言える.

そこで, 今後の検討として本報告では RGB 値の R 値にのみ着目したが, G 値と B 値にも着目して評価を行い, サポートベクターマシンを用いて判別精度に関する検討を行う.

表 4: 各成熟度間の *p* 値と採択仮説

Ripeness level	p-value	Possibility to distinguish
Unripe - Under ripe	0.452	×
Unripe – Ripe	< 0.01	○
Under ripe - Ripe	< 0.01	○

5. おわりに

本報告では, カラーチャートによる方法を評価するために目視による方法と比較を行った。以下に得られた結果を示す.

(1) 2･4 節の定義に従い採取を行うと, 83.8 %の確率(s = 1.4)で 19 %~33 %（成熟）, 33 % ~ 68 %（成熟過程）, 68 % ~ 90 %（未熟）となる.

(2) 目視によって推定した水分量が判別可能かを調べるために Tukey の範囲検定を行うと, 有意水準 1 %において,「成熟過程-成熟」,「未熟-成熟」の 2 つの組み合わせでは有意差が認められ,「成熟過程-未熟」の間には有意差が認められなかった.

(3) 目視によって推定できた水分量範囲をカラーチャートでは推定することができなかったことから, カラーチャートのR値による方法は, 現段階では, 目視に対して優位性がないことが言える.

謝辞

本研究の一部信州大学山下貴紀氏にも協力していただいた。ここに謝意を表します。

参考文献

[MPOB 03] MPOB : OIL PALM FRUIT GRADING MANUAL Second Edition, p4, 2003

[Makky 16] Muhammad Makky: A Portable Low-cost Non-destructive Ripeness Inspection for Oil Palm FFB, Agriculture and Agricultural Science Procedia, 9, pp230-240(2016)

[島田 11] 島田善一郎, 小林一樹, 斎藤保典: 農作物画像のための AR 技術を用いた自動色補正ビューアの開発, The25th Annual Conference of the Japanese Society for Artificial Intelligence, 2B1-OS13-3(2011)

[Siregar 76] Siregar, I.M., In Wastie, R.L., Earps. : Assessment of ripeness and crop control in oil palm. *Proc. of Malaysian Int. Aqric. Oil Palm Conf.*, Kuala Lumpur, PORIM, pp711-723.(1976)

[石村 10] 石村貞夫, 石村光資郎: すぐわかる統計処理の選び方, 東京図書, pp33-37(2010)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

外部光で動作するDNN向けニューロン素子の初期検討

A Light-Driven Artificial Neural Network Architecture for Deep Neural Network

大塚卓哉[*1]
Takuya Otsuka

小仁所志栞[*1]
Shiori Konisho

[*1] 日本電信電話株式会社NTT先端集積デバイス研究所
NTT Device Technology Labs, NTT Corporation

With the aim of making an IoT device more environmentally friendly, we attempted to redesign the physical layer of an IoT device architecture for a deep neural network. A method for making a deep neural network device for inference execution with a plastic optical fiber is proposed. The device comprises sum-of-product arithmetic units driven by light from an external light source and non-linear activation function units. These units are concatenated in line and form a layered network without optical amplifiers.

1. はじめに

深層学習を利用したAI機能があらゆる端末機器に搭載され，端末機器がネットワーク化されていくIoTの未来が予想されている．この種の予測の多くでは，末端に位置するIoTデバイスはデータ収集に専念し，クラウド上で実行されるAI処理の指示に従い動作することになっている．しかし，IoTデバイス自体が十分なAI機能を持つと，自ら判断し動作するIoTデバイスが増加すると考えられる．そして，やがて，撒いて放置，捨てられるIoTデバイスの需要が高まると我々は予測している．例えば，適当に撒かれたIoTデバイスが環境中の化学物質の状態をセンシングし，適切な判断の下に必要な物質を放出し環境を制御する，というシナリオが典型例である．そして，それらは役目を終えた後に分解して無くなってもらえれば回収コストも不要になり都合がよい．

上記のようなシナリオでは，土壌に撒かれるIoTデバイスであれば分解され土に返る，または，生体に貼られたり埋め込まれたりするものであればアレルギーを起こさない生体親和性の高い素材で作られ，消化，分解される等，デバイスの素材が適用環境に対し親和性が高いことが重要となる．微細化と高速化はIoTデバイスの重要な要素であるため，多くの研究は，適用環境への親和性が必ずしも高くないシリコン半導体技術の活用を前提としており，デバイスがどのような素材で構成されるべきかについて多く検討されていない．そこで我々は，IoTデバイスのAI機能の実装として現在最も高い認識精度が達成される深層ニューラルネットを様々な素材で作成する試みを進めている．

2. 提案手法の概要

自律的に動作するIoTデバイスに必要となる機能は，センシング，認識，アクチュエーションの3つに分類できる．我々の提案対象は”認識”機能であり，具体的には深層学習の推論処理を実行する演算素子の構成法である．

2.1 高分子ポリマー光導波路による光演算機

提案手法は，光導波路で演算ネットワークを構成し深層ニューラルネットの演算を光信号で実行する方式であり，その素材として高分子ポリマーを選択した．高分子ポリマー導波路による光演算機を選択した理由を2点記す．

(1) 適切な素材選択による適用環境への高い親和性

高分子ポリマーは，その分子組成により様々な物理特性を付与することが可能な素材であり，演算機を適用する環境で必要される特性に合わせて素材を選択できる．例えば，土壌や海洋に播いて捨てられる使い捨て演算機を実現する為に，特定の条件下で分解する高分子材料を用いることが出来る．あるいは，軟体構造ロボットの柔軟に変形する躯体に適用する為に伸縮性の高い高分子材料を用いることができる．

(2) 機能のダイレクトな光接続によるシステム簡素化

化学物質のセンシング手法として，特定の分子種の存在を判断するために分子が持つ固有の光吸収特性を利用したり，分子構造の変化に起因する光の屈折率変化を利用するものが少なくない．センシング部からの出力を光のまま認識処理部に入力し光で演算処理できれば，従来必要とされてきた光信号から電圧信号への変換処理が不要となる．その結果，光電変換に伴うエネルギー損失が無くなる上，変換処理ブロックそのものが不要となり，システム簡素化による経済性向上が期待できる．

また，アクチュエーション手法として，光で直接分子構造を変化させて標的分子を放出，あるいは，吸着する機構が，環境浄化システムやドラックデリバリーシステムの分野で検討されてきた．光で直接アクチュエーション機能を駆動させることが可能になると，従来μTAS等で利用されてきた電磁弁，あるいは，モータ等の駆動部とその制御機構が不要となり，システムが簡素化され経済性向上が期待される．

このように，センシング，認識，アクチュエーションの3機能が一貫して光で動作すると，システム全体が簡単化され低コスト化と省エネルギー化に繋がると期待される．

2.2 外部から光を取り込み動作するDNN（Deep Neural Network）演算機

提案手法では，外部から光を演算機に取り込んでそのまま光演算を実行する構造をとり，光が利用可能な限り動作を継続することができる．本稿ではDNNの一形態として推論を実行する全結合型DNNを取り上げる．全結合型DNNは，積和演算と非線形関数演算を多段に接続することで構築される．提案する演算機アーキテクチャは，取り込んだ光で直接駆動されるように設計された積和演算素子とその出力を非線形変換する非線形関数演算素子，そして，それら演算素子を増幅機構無しに多段に接続する機構から構成される．

連絡先：大塚卓哉，日本電信電話株式会社NTT先端集積デバイス研究所，〒243-0198 神奈川県厚木市森の里若宮3-1，takuya.otsuka.yt@hco.ntt.co.jp

2.3 関連研究

光演算機をつかった DNN の実装手法として，演算機を多段に接続するために受光機と発光機を組み合わせて配置した光増幅法を用いる研究[谷本 17]が報告されている．受光機で受けた光強度に応じて LED を発光させる方式であるため，光増幅処理に外部からの電力供給を必要とする．また，光集積デバイス化を進めた研究として，演算と増幅処理の両方を光で実行する事例[Yichen 17]も報告されている．この方式は，光で演算を実行する為にコヒーレントなレーザ光を光源として必要とし，光集積デバイスの駆動には十分大きな電力の投入が必要である．これらの手法は，既存の半導体プロセッサと比較して消費電力あたりの演算速度を向上させる事を目的としており，本稿で提案するアーキテクチャが目指す用途への適用は難しい．

本稿で提案する光演算素子の多段接続法は，次章で詳述するように，光制御－光スイッチを重要な構成要素として持つ．光で制御する光スイッチとしては非線形光学結晶を利用したものが良く知られているが，非線形光学効果を起こすために強力なレーザ光が必要となる．本稿が目指す用途に適用可能な光制御光スイッチとして，光熱変換による温度上昇で相転移する液晶分子を利用した光熱スイッチ[西山 07]がある．この光熱スイッチは，メチルレッド色素の光吸収特性を利用し，吸収帯に含まれる波長である第一の光を制御光とし，吸収帯から外れる波長である第二の光の進行方向を制御する．しかし，この光熱スイッチは制御光と制御される光の波長が異なり，単純に光演算素子を多段接続することができず，DNN を構成することはできない．

外部から取り込んだ自然光等で直接駆動される光演算 DNN アーキテクチャは我々の知る限り本提案が最初である．

3. DNN 演算機アーキテクチャ

図1に一般的な DNN モデルとその構成要素であるニューロン素子（ノード）の機能ブロックを示す．各ノードには、前段層の各ノードからの入力が重み（w）と乗算された値を合計する積和機能と、それに続く非線形演算機能がある．さらに，後段層の各ノードに出力するために，増幅機能と分岐機能がある．このノードが多段に接続されることで DNN を構成する．以下に光増幅機を用いずに DNN を構築可能なノードの積和演算機構とその多段接続機構，及び，非線形演算機構を順に記す．

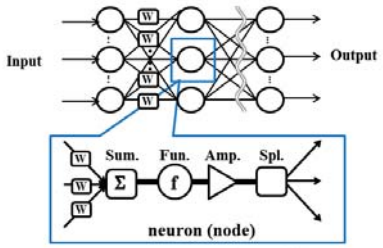


図1 ニューロン素子の機能

3.1 積和演算素子

提案する演算方式では，DNN を構成するノードへの入力値，出力値，そして，ノード間で渡される値が光の信号強度によって表現される．また，ノード間の重み(w)は光強度を減衰させるフィルタの減衰率によって表現される．従って，図1に示したノードにおける積和演算は，2入力の場合，図2(a)に示すような光導波路上のフィルタとカプラにより実現される．前段層の各ニューロンからの光入力の強度(X_0, X_1)が重み(W_0, W_1)を表現するフィルタで減衰され，それらを加算することで積和演算(X_0･W_0 ＋ X_1･W_1)が実行される．

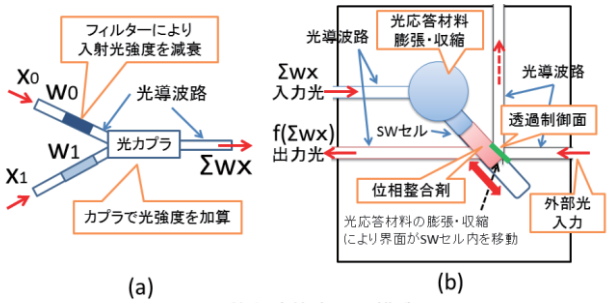


図2 積和演算素子の構造

3.2 光増幅機不要な演算機の多段接続（多層化）

光強度を指定された減衰率で減衰させる事で乗算を表現する方式では，入力光と比べて出力光が必然的に減衰する．故に，複数の積和演算機を多段に接続して多層化するためには，演算器と演算器の間に光を増幅させる仕組みが必要となる．提案手法では，外部から取り込んだ光をスイッチングすることで光導波路に導き，光増幅機を使わずに多段接続を実現する．

図2(b)に示すスイッチ機構は，ポリマー基板上に入力光，出力光，及び，外部光が導波する光導波路が形成され，液体が収まるスイッチ(SW)セルが切削加工されている．光に反応し膨張する光応答材料と，光導波路の材質と同じ屈折率を持つ位相整合剤が SW セルに封入されている．光応答材料は，光や熱によって分子構造が変化することで特異な特性を発揮する材料[Ueki 14] [Kusano 14]である．このスイッチ機構では，入力光の強度に依存して光応答材料が膨張し，それに伴って位相整合剤が SW セル内を移動する．位相整合剤が透過制御面の位置にある場合，導波路と位相整合剤の屈折率が合っているため，外部光は透過制御面を直進して出力光側の導波路へ進み出力光となる．位相整合剤が透過制御面から外れている場合，導波路とセル空間の屈折率差により外部光は透過制御面で反射され出力光とはならない．この動作原理は熱毛管現象を利用した光スイッチ[下川 00]の構造から着想を得たものである．この光スイッチ機構により，入力光よりも大きな強度の外部光を出力光として取り込むことで光増幅させた事と同じ効果を持つ事に注意する．

図2(b)の光スイッチをノードが持つことにより，次層のノードに十分な強度の光を出力することができ，多段接続が可能になる．光スイッチを図3(a)に示すように接続すると図3(b)に示す多層ネットワークと等価な演算が実現できることがわかる．図3(a)及び(b)において，入力(x_0, x_1)は重み(w^1_{01}, w^1_{11})と積和演算された後，N^1_1（第1層のノード 1）に相当するスイッチ SW^1_1 の入力光となる．入力光の強度により位相整合剤の界面が移動し，外部

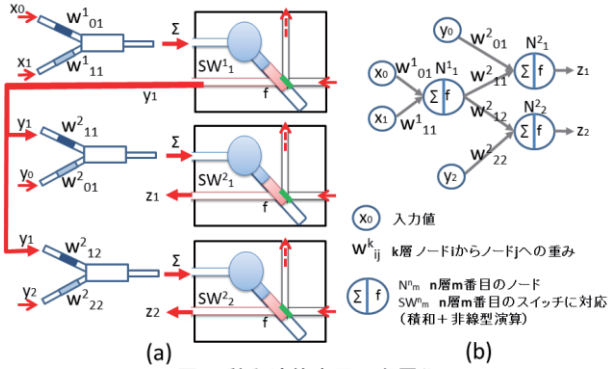


図3 積和演算素子の多層化

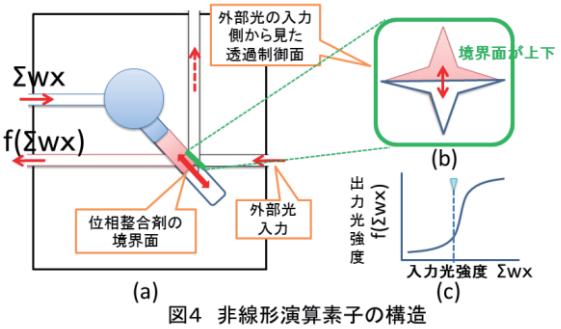


図4 非線形演算素子の構造

光から後述する非線型演算 f に従った光量だけが出力光側の導波路に取り込まれ，N^1_1の出力 y_1となる．y_1は第 2 層のノードである N^2_1と N^2_2 の入力となる．N^2_1 への入力(y_0, y_1)は，重み(w^2_{01}, w^2_{11})と積和演算された後スイッチ SW^2_1 の入力光となり，同様の動作によりスイッチ SW^2_1 すなわち，N^2_1 の出力 z_1となる．同様に N^2_2の出力は z_2となり，この手続きを繰り返すことで光増幅機を使わずに任意段数の多層化が実現できることがわかる．

3.3 非線型演算素子

非線型演算は DNN の重要な要素であるが，提案手法では極めて簡単な方式で実現する．図4(a)に示すように外部光が入力される導波路側から見た透過制御面に適当な形状の開口窓を加工することで任意の非線型関数 f を実現できる．例えば，図4(b)のように 十字星型の開口部とすると，入力光強度に対する光応答材料の膨張量が比例する条件下で，図4(c)のような入力光強度に対して出力光強度が非線型となる関数を実現できる．

4. 評価実験

入手性と加工容易性を優先した簡易実験系を作成し，提案する光スイッチの実現可能性を評価した．ポリメチルメタクリレート樹脂（PMMA）の基板を切削しプラスチックオプティカルファイバ（POF）を埋め込み，POF に対して 45 度の角度でスイッチセル（SW セル）となる空間を切削形成（図5(a)）した．POF の径と SW セルの幅を共に 250 μ m とし，両者が交差する箇所が透過

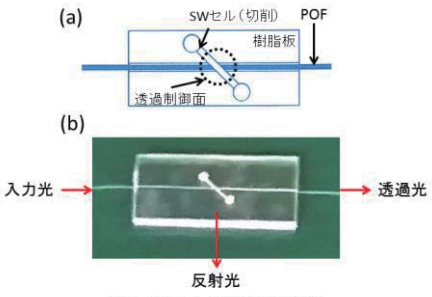


図5 光スイッチ評価実験系

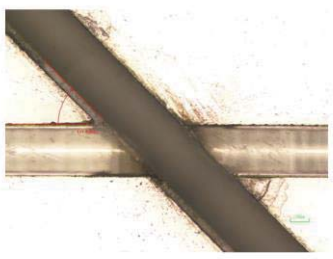


図6 光スイッチの透過制御面

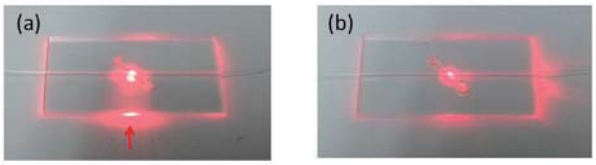


図7 透過/反射 制御実験

制御面である．加工部位の顕微鏡写真を図6に示す．POF のコア材料と同じ屈折率を持つシリコンオイルを位相整合剤として選択し SW セルに充填，あるいは，抜き出すことで光スイッチ動作を模擬した．

図5(b)に示すように図面左側から波長 633nm の赤色光を入射し，透過制御面で透過，および，反射される光の強度を測定した．位相整合剤が透過制御面にないと図7(a)から見て取れるように図面下側へ赤色光が反射される．また，位相整合剤が透過制御面にある時は図7(b)のように反射光はわずかで，ほぼ透過することがわかる．このスイッチの挿入損失は，透過側における光強度計測で，2.4dB（透過条件），および，16.5dB（反射条件）であり，スイッチとしての消光比は 14.1dB であった．

5. まとめ

本稿では，外部光を取り込んで直接駆動する積和演算素子と非線型演算素子の構造を提案し，光増幅器を使わずにニューロン素子を多層化して DNN を構成する方法を示した．また，ニューロンの多層化に重要な要素となる光スイッチ構造の初期評価を実施した．簡易な構成の実験系でも比較的大きな消光比（約 14dB）を得ることが確認された．

参考文献

[Kusano 14]Daichi Kusano, Ryota Ohshima, Nobuhiko Hosono, Kenro Totani, Toshiyuki Watanabe. :Photochemical reaction in azobenzene-containing rigid poly(amide acid) networks, Polymer 55, pp. 5648-5655, 2014.

[西山 07] 西山達，保坂佳正，大谷幸利，梅田倫弘.: 液晶位相格子を用いた光制御－光熱スイッチの開発，IEEJ Trans. EIS, Vol.127, No.6, pp. 966-967, 2007.

[下川 00] 下川房男，佐藤誠，牧原光宏，稲垣秀一郎，西田安秀.: 熱毛管型光導波路スイッチの開発，精密工学会誌，Vol. 66, No. 8, pp. 1173-1176, 2000.

[谷本 17] 谷本桂理，雨宮嘉照，田部井哲夫，横山新.: フォトクロミック材料を用いた光ニューラルネットワークの研究，応用物理学会講演会第 64 回，2017.

[Ueki 14]Takeshi Ueki, Stimuli-responsive polymers in ionic liquids, Polymer Journal 46, 646–655, 2014.

[Yichen 17] Yichen Shen, Nicholas C. Harris, Scott Skirlo, Mihika Prabhu, Tom Baehr-Jones, Michael Hochberg, Xin Sun, Shijie Zhao, Hugo Larochelle, Dirk Englund, and Marin Soljacic.: Deep learning with coherent nanophotonic circuits, *Nature Photonics*, **11**,441-446, 2017.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

農作物病害画像診断に向けたData Augmentationの評価

Evaluation of Data Augmentation to Image-Based Plant Disease Detection

小林 賢一　辻 順平　能登 正人
Kenichi Kobayashi　Junpei Tsuji　Masato Noto

神奈川大学大学院工学研究科電気電子情報工学専攻
Graduate School of Electrical, Electronics and Information Engineering, Kanagawa University

In this paper, we discuss about the evaluation of data augmentation to improve the accuracy for detecting plant diseases. Recently, researches on image-based plant disease detection using deep learning have been conducted. The researches require a huge number of training data, however, it is difficult to obtain so much data. Therefore, the authors focus an application of data augmentation to image-based plant disease detection. In many cases, it is known that data augmentation is effective, however, in some cases performance might be worse. As the condition that the performance of data augmentation deteriorates is not clear, the further researches are required. The authors propose to apply Frechet Inception Distance (FID) to the evaluation of data augmentation. In this study, we investigate the correlation between FID score and performance of data augmentation.

1. はじめに

近年，Deep Learning を用いた農作物病害の画像診断が提案されている [Mohanty 16]．農作物病害診断を行うためには大量のデータ取得が課題の一つであり，容易に解決できる問題ではない．そこで我々は少量の農作物画像データに対し，学習用データに変形や加工したものを合わせることで精度の向上を目指す Data Augmentation (DA) を試みてきた．これまでの実験により多くの条件で精度が向上したが，精度が低下する手法やパラメータの設定も確認している．DA を実用し正答率を向上させるためにはこの原因を明らかにする必要がある．一般的に深層学習では，検証用データの集合に類似したデータが学習用データの集合に存在するほど正答率が向上することが考えられる．これより我々は学習用データと検証用データの集合間の距離を測定し，距離が近くなれば正答率が向上する良い学習用データであり，その逆は正答率を低下させる悪い学習用データであると考えた（図 1）．この相関関係が明らかになれば，DA で拡張した学習用データと検証用データの距離が良し悪しの判断が可能な指標になると考えられる．我々は二つの画像データ集合の距離を測定することが可能である Frechet Inception Distance (FID)[Heusel 17] を用いて測定できると考えた．

本研究の目的は，農作物画像データセットの場合における FID の距離と正答率の相関関係を明らかにすることである．

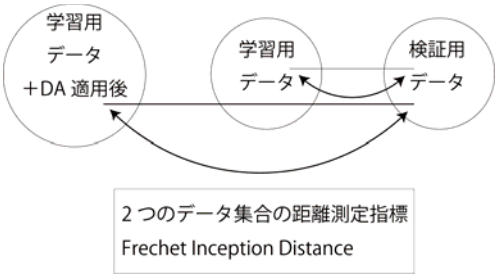


図 1: 本研究の位置づけの概要図

2. FID による DA の評価の検討

DA を適用した学習用データの集合と検証用データ間の距離を FID により算出し，データセットを用いて学習・検証した正答率の二つの相関関係の分析を行う．

本研究のデータセットは “apple leaf scab”, “apple leaf black rot”, “apple leaf cedar rust”, “apple leaf healthy” のキーワードでインターネット検索し取得された画像群を元に，Mohanty らによってラベリングされたデータセットの二種類を用いる．データセットのクラスは，健康状態（49 枚），scab 病（102 枚），black rot 病（38 枚），ceder rust 病（46 枚）の 4 クラスとなっている（図 7）．本研究では，ホールドアウト検証を用いて，データセットから 50%をランダムに選択したものを学習用データとし，残りを検証用データに分けている．

本研究で用いる DA の手法は，回転・水平方向移動・垂直方向移動・シアー変換・Cutout の 5 種類である．各 DA 手法ごとに変化の度合いが小さいものから大きいものまでの 5 段階を設ける．回転は 20，40，60，80，100 度の 5 種類とする．水平方向移動・垂直方向移動・シアー変換は Keras 上のパラメータ値を 0.2，0.4，0.6，0.8，1.0 と設定する．Cutout 手法は Cutout を発生させる確率である p を 0.1，0.2，0.3，0.4，0.5 とする．各 DA 手法の 5 段階それぞれにおいて DA を適用し学習用データを 2 倍へ拡張している．

各 DA 手法の 5 段階それぞれの段階でホールドアウト検証を 5 試行行う．以上により作成した学習用データと検証用データのそれぞれで畳み込みニューラルネットワーク（本研究では Inception v3 を使用）により学習・検証を行い正答率を算出する．また，全ての学習用データと検証用データで両データ間の FID の値を算出する．さらに各 DA 手法の 5 段階における正答率と FID の相関係数をそれぞれ求め分析を行う．

連絡先: 小林賢一，神奈川大学大学院工学研究科電気電子情報工学専攻　能登研究室，〒 221-8686 神奈川県横浜市神奈川区六角橋 3-27-1，電話：045-481-5661，r201770101do@jindai.jp

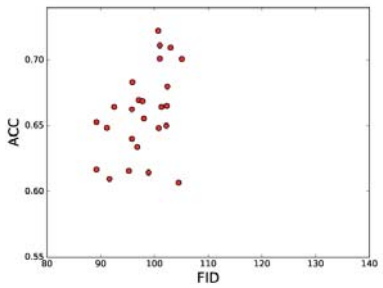


図 2: 回転の FID と正答率

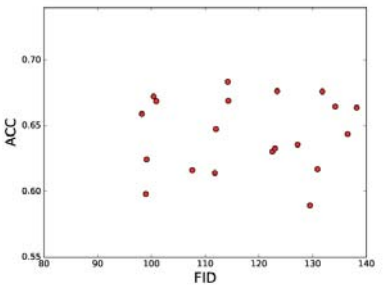


図 3: 垂直方向移動の FID と正答率

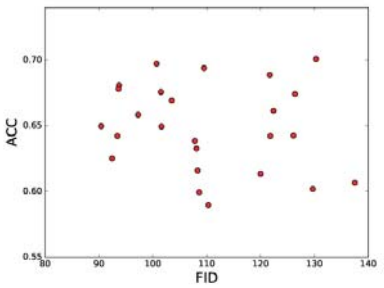


図 4: 水平方向移動の FID と正答率

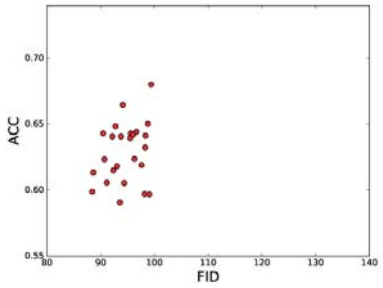


図 5: Cutout の FID と正答率

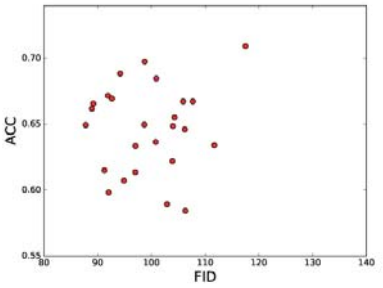


図 6: シアー変換の FID と正答率



図 7: 参考画像：scab 病

3. 結果と考察

各 DA 手法ごとの FID と正答率の相関係数を表 1 に示す．また，各 DA 手法の正答率（縦軸：ACC）と FID（横軸：FID）の 25 個を図 2（回転），図 3（垂直方向移動），図 4（水平方向移動），図 5（Cutout），図 6（シアー変換）にそれぞれ示す．

結果より，回転においては相関係数が 0.434 であり正の相関があることがわかる．したがって回転においては，FID（距離）が大きくなるにつれて正答率が向上することが分かった．しかしながら，他の全ての手法では相関係数が小さくほとんど相関関係がみられない．FID はすべての DA 手法で DA の変化の度合いの強弱に従い，FID 値も大小していることから，FID は DA の変化の度合いの強弱を評価することはできていることが言える．しかしながら，FID で算出した学習用データと検証データ間の距離と正答率の相関関係はなく，正答率の良し悪しを評価する指標を見つけることは容易ではないことが分かる．

また，DA の変化の度合いのレンジをより大局的なレンジに設定した実験を行うことで，DA により変化した学習データの良し悪しを評価することが可能であると考えられる．

表 1: 各 DA 手法の相関係数

	相関係数
回転	0.434
垂直方向移動	−0.248
水平方向移動	−0.167
シアー変換	0.091
Cutout	0.278

4. おわりに

一般的に検証用データの集合に類似したデータが学習用データの集合に存在するほど正答率が向上することが考えられる．このような仮定のもと我々は学習用データと検証用データの集合間の距離を測定し，距離が近くなれば正答率が向上する良い場合であり，その逆は正答率を低下させる悪い場合であると考えた．そこで本研究では，FID の距離と正答率の相関関係を明らかにし，DA で拡張した学習用データと検証用データの距離から良し悪しの判断が可能な指標を目指し，二つの画像データ集合の距離を測定する FID で，DA 適用後の学習用データと検証用データ間の距離を算出し，FID 値と学習・検証した正答率の二つの相関関係の分析を行った．結果は回転手法は FID と正答率に正の相関関係があるが，その他の手法では相関係数が小さくほとんど相関関係がみられなかった．結論として，FID で測定した学習用データと検証用データの距離と正答率には相関関係を見つけることは難しく，より学習用データと検証用データの距離と正答率の相関関係がある距離の測定手法を検討する必要があることがわかった．

参考文献

[Heusel 17] Heusel, M., Ramsauer, H., Unterthiner, T., Nessler, B., and Hochreiter, S.: GANs Trained by a Two Time-Scale Update Rule Converge to a Local Nash Equilibrium, in *Advances in Neural Information Processing Systems 30*, pp. 6626–6637 (2017)

[Mohanty 16] Mohanty, S.-P., Hughes, D.-P., and Salathe, M.: Using Deep Learning for Image-Based Plant Disease Detection, *Frontiers in Plant Science*, Vol. 7, pp. 1–10 (2016)

[1L1] [General Session] 12. HI / Education Aid

座長:笠井 俊信（岡山大学大学院）

Tue. Jun 5, 2018 1:20 PM - 3:00 PM Room L (3F Sapphire Hall Asuka)

[1L1-01] Engineering Experiment Environment Combining Knowledge-Constructive Jigsaw Method and IoT

○Takafumi Noguchi[1] （1. National Institute of Technology, Kushiro College）

1:20 PM - 1:40 PM

[1L1-02] Effect of Educational-Support Robot Based on Cognitive Apprenticeship Theory

○Kenya Miyauchi[1], Jimenez Felix[1], Tomohiro Yoshikawa[1], Takeshi Furuhashi[1] （1. Nagoya university）

1:40 PM - 2:00 PM

[1L1-03] Development of a Simulation System for Changing Decision Character during Playing Japanese Poem Card Game

○Chiharu Tokushima[1], Masato Soga[1] （1. Wakayama University）

2:00 PM - 2:20 PM

[1L1-04] Character Strokes Detection and Scoring for Increasing Children's Calligraphy Training time

○Yui Kakino[1], Makoto Kawano[1], Takuro Yonezawa[1], Jin Nakazawa[1] （1. Keio University）

2:20 PM - 2:40 PM

[1L1-05] Analysis of NIE Worksheets and Article Estimation Method for Web News Recommendation to Elementary School Teachers

○Shinya Seki[1], Kazuaki Ando[1] （1. Kagawa University）

2:40 PM - 3:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

知識構成型ジグソー法とIoTを組み合わせた工学実験環境

Engineering Experiment Environment Combining Knowledge-Constructive Jigsaw Method and IoT

野口　孝文[*1]
Takafumi Noguchi

[*1] 釧路高専
National Institute of Technology, Kushiro College

We have practiced mechatronics education using LEGO. Until now, we have prepared individual learning environments where each student can solve tasks by trial and error. However, since individual learning has no information exchange between learners, many students ended up solving the minimum task. Therefore, in this research, we realized a system that can easily integrate devices created by individual learning in cooperative learning by converting devices manufactured by LEGO into IoT. In this learning environment, learners not only can integrate real world equipment, but also can easily control the other equipment depending on the state of the equipment. Learners were able to seamlessly participate in cooperative learning after concentrating on individual learning.

1. はじめに

工学教育では，教育効果を考慮してカリキュラムに実験や実習の時間を多く取り入れている．工学実験は設備と場所の制約から，数人のグループで行うことが多い．グループによる実験は，協調学習の観点から学生同士の対話により実験内容に関する知識が深まることが期待できる一方，一部の学生が主導して十分な知識交換がないままに終了してしまうこともある．

本研究では，授業として行われる協調学習を工学実験に適用し，全体の作業を分割しはじめに分担した自身の作業内容を理解した後に共同作業に移行することで，他者との情報交換を活発にするという協調学習法について提案する．本協調学習の考え方には，知識構成型ジグソー法を用いる．ジグソー法は，生徒に課題を提示し，課題解決の手がかりの知識を与えて，その部品を組み合わせることによって答えを作り上げるという活動を中心にした授業デザインの手法である[Aronson 96]．

三宅等は，ジグソー法から知識構成型ジグソー法を開発し，多くの授業においてこれを利用実践している[三宅 02, 16]．協調学習では，学習者同士の考えを外化し，それを複数の視点から吟味する．そしてそれを修正や改定する過程で学習や理解が深まる．そのため三宅等の知識構成型ジグソー法では，各学習者に異なる視点を持たせる工夫を行っている．エキスパート活動と呼ぶ活動で，同じ資料を読み合う活動によって十分理解した後に，グループの構成を変更して異なる知識を持った学習者の集まりを作り，ジグソー活動と呼ぶ活動で先に学習した内容を発表したり意見を交換したりして理解を深めていく．ジグソー活動では，エキスパート活動で学んだ内容を他の学習者に分かるように発表する必要があるため，発表者自身が十分理解しなければならない．また，他の発表者の内容は自身と異なるため，ディスカッションが進むという．

しかしエキスパート活動もグループで活動するため，協調学習にそのまま適用しても，消極的な学生も現れると思われる．知識構成型ジグソー法では，エキスパート活動で学生の意識を高める工夫が，その後の協調学習を円滑に進める鍵になる．

本研究では，LEGOを用いた工学実験において複数の学習者が協同で課題に取り組みながらも，一つの課題を小さな課題に切り分けることができ，再びそれらを統合することができる学習環境を開発した．本学習環境は，学習者が割り当てられた課題に専念した後に，その学習成果を生かして協調作業に参加することを支援する．

本論文の 2 章では統合を可能にするシステムについて述べ，また，これまで我々が行ってきたプログラミング教育について述べる．3章では，IoT化の技術を用いて統合を実現する方法について述べる．4 章は本システムを用いた実践例を示し，5 章でまとめを述べる．

2. 個別学習環境

2.1 IntelligentPad システム

我々は，IntelligentPad を用いて様々な学習支援システムを開発してきた．提案のシステムにおいてもLEGOの制御にIntelligentPadを用いている．図1は，学習支援システムの様子である．IntelligentPad は，パッドと呼ばれるオブジェクトをダイナミックに組み合わせたり，変更したりできるシステムである．パッドは，ディスプレイ上に可視化され，マウスによる直接操作でパッドを自由に組み合わせることができる．パッド同士の結合は，標準化されたスロットの結合によって行い，様々な合成パッドを作ること

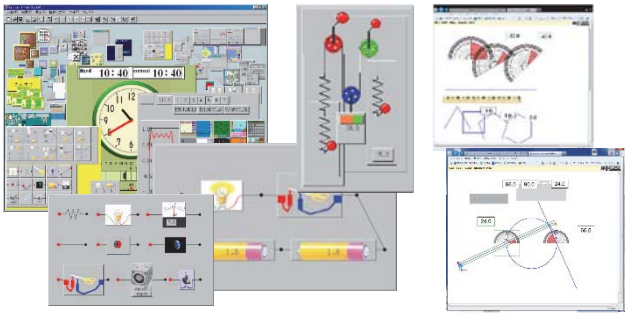


図 1 IntelligentPad system

連絡先:野口孝文，釧路高専，〒084-0916 釧路市大楽毛西 2-32-1，0154-57-7315，noguchi@kushiro-ct.ac.jp

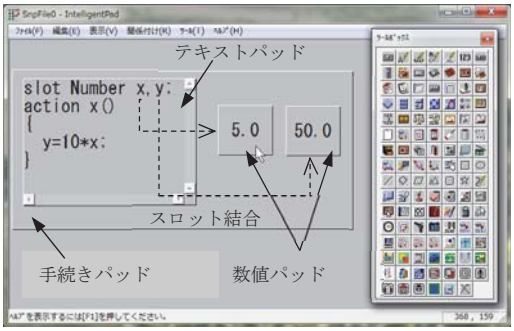


図 2　手続きパッドを用いたプログラム

ができる[野口 95].

我々は，学習者にプログラミングに興味を持たせながらも多様な学習者に対応するために，入出力機能やイメージの表示等の機能を部品（パッド）で与えるとともに，C 言語によるスクリプトの記述ができるパッド(手続きパッド)を用いたプログラミング教育を行っている．図 2 は，手続きパッドを用いたプログラムの例である．

2.2　コンピュータに直接接続された機器の制御

我々は，コンピュータ外部にある機器とコンピュータ上のプログラム部品とを組み合わせた学習環境を実現してきた[野口 15]．図 3 は，開発してきた学生実験のシステムである．LEGO（NXT）と通信する機能（NXT コントローラ）をパッド化し，制御機能もパッドの組み合わせで作成している．このシステムでは，多様なレベルの学習者に対応するために，通信機能や表示機能を部品化することで，学習者が制御プログラム作成に集中できるようにしている．

制御プログラムは，上述の手続きパッドを用いている．NXT コントローラが手続きパッドの上に貼付され，手続きパッドとスロット結合している．図 3 は，お茶運びロボットとその制御プログラムの作成の様子である．NXT1 台に限定しているため，本システムを用いた実験の計画や実施は，容易である．

しかし，本システムでは，複数の NXT を含む機器を統合する場合には，NXT のポート番号を指定したり，プログラムを統合したりと操作が煩雑になるため，複数の学習者が協同して作業を進めると行った使い方に対応できていなかった．次章では，協調学習への対応について述べる．

3.　個別学習から協調学習

3.1　個別学習と機器同士の連携

Wi-Fi 接続が可能になった EV3 のシステムは，2 章で示した NXT を用いたシステムと同様に，学習者が一人で取り組む課題を用意することができる．これまでと同様に LEGO で

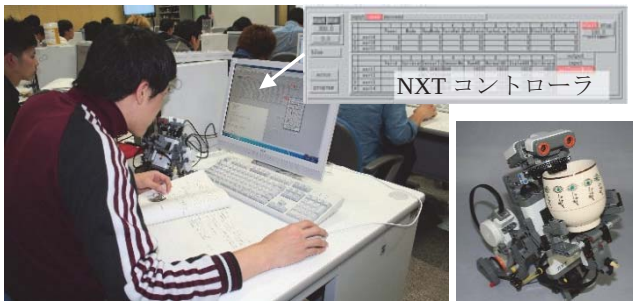
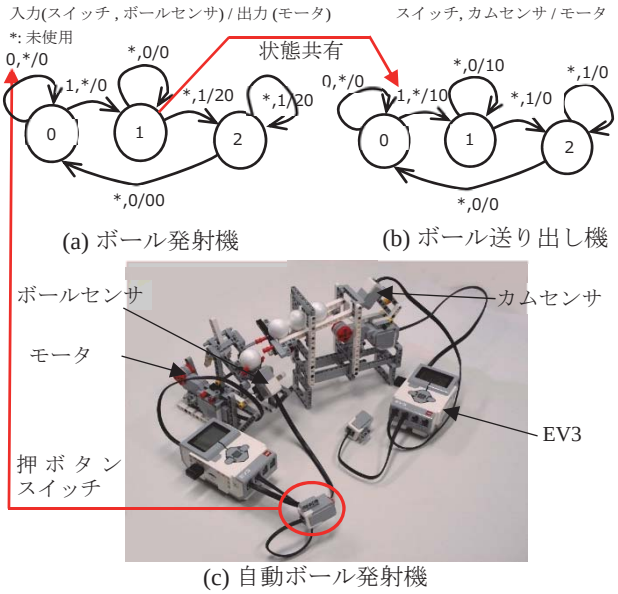


図3 LEGOで製作したロボットの制御



(c) 自動ボール発射機

図 4 状態の共有による装置の連携

ロボットを組み立て，手続きパッドに記述したプログラムを試行錯誤で動作確認しながら完成させることができる．

さらに本システムは，ロボットの制御プログラム開発において，状態遷移図を用いている．そのため，2 つのロボット同士を連携させるときにも，プログラムの変更は最小限で連携を行うことができる．また EV3 を制御するシステムは，IntelligentPad でできているため，LEGO コントローラを同じウインドウに共存させることができる．そして，スロットデータを介して，パッド同士を連携させることもできる．それらの様子を図 4 に示す．

図 4 は，ボールの供給装置とボール発射装置を個別に製作し統合したものである．これらの装置の動作の仕組みを説明する．それぞれの装置は，EV3 とモータ，押ボタンスイッチ等からできている．プログラムは，前述の手続きパッドを用い，(a)と(b)に示した状態遷移図に基づいて作成している．それぞれの装置は，押ボタンスイッチを押すとボールの供給や，ボールの発射を行うことができる．(c)は 2 つの装置を連携したところを示している．2 つの装置を連携したプログラムは，個別に製作した 2 つのプログラムを並べ，発射装置の状態をボール供給装置の制御プログラムにスロットを介して送り，その値を入力「押ボタンスイッチの ON」信号の代わりに用いることで，プログラムをほとんど変更することなく実現することができる．そのことについては，次節で述べる．

3.2　プログラムの統合

図 4 に示した 2 つの装置について，コンピュータ上でのプログラムの統合の様子を図 5 に示す．2 つのプログラムの統合は，状態遷移図に対応した一方の状態を他方に伝えることで実現できる．本システムでは，スロットの結合でを実現している．

2 つのプログラムの統合は，前節でも述べたように状態遷移図に対応した一方の状態を他方に伝えることで実現できる．図 5 は，ボール供給機側の EV3 コントローラパッドを制御しているプログラムである．図 5 は制御プログラムの一部で，さらにプログラム同士の連携のために変更してある．図 5 のプログラムの 1 行目と 2 行目は，スロットを宣言している．スロットは変数と同様に値を保持する機能

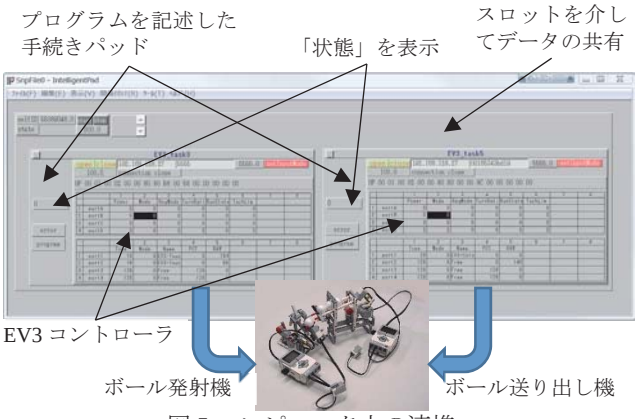


図 5 コンピュータ上の連携

がある．また他のパッドを結合することでイベントの授受することができる．7 行目から始まる関数は，ボール供給機の EV3 からの入力イベントによって起動するアクション関数である．9 行目から 12 行目は，EV3 に接続されたセンサの値を取り出すプログラムである．取り出した値は，スロット「data0」に入力され，単独の装置を制御しているときには，15 行目から 17 行目に示すように，状態に応じた処理を行う関数に値を渡している．なお，スロット「state」は，状態遷移図に対応した自身の状態を保持している．

スロット「st1」は，ボール発射機の状態が接続されている．その値が 1（発射機は発射待ち状態でボールが空の状態）のときは，スロット「data1」に値1を，それ以外のときには 0 を設定している．これは，ボール供給機を単独で動作させたときの押しボタンスイッチの値に対応している．15 行目と 17 行目ではこれを，ボール供給機の EV3 に接続されたセンサの値の代わりに用いている．プログラムの 3 行目から 6 行目は，関数のプロトタイプ宣言で，15 行目から17行目でそれらの関数を呼び出している．これらの関数は，状態遷移図の状態に対応していて，EV3 および他のプログラムの状態によって，EV3 に値を出力したり状態を遷移させたりする機能が定義されている．このように本システムでは，数行のプログラムの変更で，複数のプログラム同士の連携を実現している

3.3 個別学習から協調学習へ

1 章でも述べたように，我々は初心者のプログラミング教育であることを考慮して，学習者の興味を引く課題として，LEGO を用いたロボットの制御を取り入れてきた．またプログラムとロボットの動作の関係を分かりやすくするため，プログラムを変更すると即座に反映する様に NXT と PC をケーブルで接続している．EV3 では，ケーブルの代わりに Wi-Fi を用いている

そして学習の課題をロボットの製作と制御にすることによって，これまで個別の学習で行ってきた課題を統合した課題を作ることができるようになった．

```
1  slot Dictionary input, output;
2  slot String state, st1;
3  Void state_0(Number);
4  Void state_1(Number);
5  Void state_2(Number);
6  Void outData(Number);
7  action input()
8  {
9     Dictionary port_in;
10    Number data0,data1;
11    port_in=getDictionary(input,"port1");
12    data0=getNumber(port_in,"PCT");
13    if(st1 =="1") data1=1;
14    else data1=0;
15    if(state=="0") state_0(data1);
16    else if(state=="1") state_1(data0);
17    else if(state=="2") state_2(data0);
18}
```

図 6 プログラム同士の連携

4. 評価実験

4.1 実験の流れ

本システムを用いて実験を行った．実験に参加した学生は，釧路高専の機械工学科 3 年生 1 名，電子工学科 5 年生 1 名，電気工学科 5 年生 4 名合計 6 名のいずれも男子である．実施時期は，機械工学科と電子工学科の学生 2 名が休日の午後の 1 日で実施し，電気工学科の学生 4 名は 2 名とは異なる休日の午後の時間 1 日に加えて授業の空き時間で実施した．機械工学科と電子工学科の学生は IntelligentPad の使用経験はないが，電気工学科の学生はいずれも IntelligentPad の使用経験がある．本実験では，6 名が同じ内容で実験を行った．

学生は初めに，LEGO の制御法，状態遷移図およびプログラムについて理解するために，構造の簡単な信号機の製作を行った．このときの信号機の制御プログラムは，完成したプログラムを与えている．学生は，プログラムを見ながら状態遷移図を完成させ，両者の対応関係を理解した．その後，信号機の動作を変更する課題が与えられ，状態遷移図とプログラムを変更し動作を確認した．

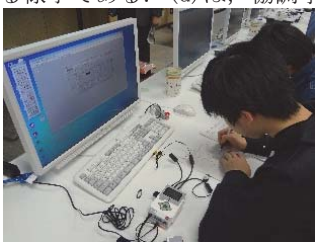
一通りの操作ができるようになったところで，3.1 節に示した「ボール供給機」と「ボール発射機」の製作を課題として与えた．これらの装置を統合した「自動ボール供給式ボール発射機」に関して，学生には 3.1 節で示した装置を実際に動作させて見せている．それぞれの学生は 2 つの課題の内いずれかを選択し，完成したところでペアになった学生と協同で「自動ボール供給式ボール発射機」の完成を目指す．また，完成の条件として，3 個のボールを連続して打ち出せることとした．課題に取り組むにあたりどちらの課題を選択するか，誰とペアになるかは，初めに学生同士で決めさせた．

4.2 個別学習と協調学習の様子

信号機の製作や状態遷移図とプログラムとの対応関係は，IntelligentPad を用いたことのない学生も特に問題なく理解し，作業を進めることができた．またプログラミングの経験については，次節のアンケート結果にも示すとおり，多くは卒業研究等で現在プログラミングを行っている学生であるが，まったく未経験の学生も 1 名いた．実験の様子を図 7 に示す．

図 7 の (a) は信号機のプログラムとその動作を確かめ，状態遷移図を作成している様子である．(b) は，全体の課題が与えられ，担当を決めそれぞれの課題に取り組んでいる様子である．次節のアンケート結果でも述べるが，最も時間の掛かったのが LEGO の作品の製作である．学生間の差も大きく，一方の装置が完成しているが，他方ができていないために一方が待たされることがあった．(c) は個別の装置ができあがり，プログラムを作成して動作を確かめてい

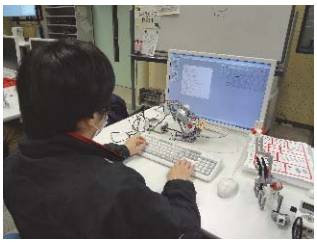
る様子である．(d)は，協調学習で2台の装置を接続し動作



(a) 信号機の製作



(b) 分割した課題への取り組み

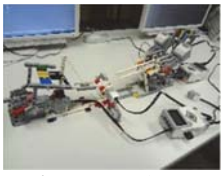


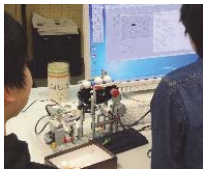
(c) 個別にプログラム作成



(d) 協調学習







(e) 完成した課題作品

図 7 実習の様子

を確かめている様子である．LEGO の接続ばかりでなくタイミングや状態数などプログラムの変更も必要になる．(e)は，統合し完成した課題作品である．それぞれ，性能差はあるが，3 個のボールを連続して打ち出すことができた．

4.3 実習に要した時間とアンケート結果

4.2 節で示した課題の製作が終了した後，アンケートを実施した．その結果を表 1 に示す．

プログラミングに関しては，まったく経験していない学生もいたがLEGOの制御は全員ができていた．アンケート結果でも「状態遷移図をプログラムに対応させることは簡単だった」の質問に対し，「あまり思わない」が 1 名いたが，「LEGO の装置を制御するプログラムは簡単だった」の質問に対しては「強くそう思う」2名または「そう思う」4名と全員が肯定的に回答している．

表 1　アンケート結果

質問項目	回　答
プログラムの経験年数	3 年以上 4 名，3 年以下 1 名，0 年 1 名
使用言語	C#: 3 名，C: 1 名，その他 1 名
状態遷移図をプログラムに対応させることは簡単だった．	強くそう思う 3 名，そう思う 2 名，あまり思わない 1 名
LEGO の装置を制御するプログラムは簡単だった．	強くそう思う 2 名，そう思う 4 名
LEGO で装置を組み立てるのは簡単だった．	強くそう思う 1 名，そう思う 1 名，あまり思わない 2 名，まったくそう思わない 2 名
組み合わせた装置は，考えたとおりに動作した．	強くそう思う 1 名，そう思う 2 名，あまり思わない 3 名
LEGO で作った装置をプログラムで制御することは楽しい．	強くそう思う 5 名，そう思う 1 名
今回の実習を体験して，協同すればもっと複雑な作品ができると思った．	強くそう思う 5 名，そう思う 1 名
担当した装置について，自分で考えて装置を作り始めてから，完成までに掛かった時間	12.5 時間 2 名，12 時間 1 名，7 時間 1 名，3 時間 1 名，1 時間 1 名
統合した装置について，統合開始から完成までに掛かった時間	3.5 時間 2 名，3 時間 2 名，1 時間 2 名

LEGO の課題製作では，「LEGO で装置を組み立てるのは簡単だった」に対し 4 名が否定的な回答をしている．最終的にできあがった作品についても「組み合わせた装置は，考えたとおりに動作した」に対し 3 名の学生が「あまり思わない」と回答している．一方，「LEGO で作った装置をプログラムで制御することは楽しい」という質問に対し，「強くそう思う」5名，「そう思う」1名と全員が肯定的に回答しており，達成感は強く感じている．

また，「今回の実習を体験して，協同すればもっと複雑な作品ができると思った」に対しても，「強くそう思う」5名，「そう思う」1名と全員が肯定的に回答しており，本システムは，協調学習への動機づけや各学生が協調作業に貢献しているという意識向上への効果もあるといえる．

以上をまとめると，アンケート結果の個別学習で苦労したが課題を達成しているという回答からは，個別の課題はそれぞれ適度な難易度の独立した課題になっていることが分かる．アンケート結果の全員が達成感を感じているという回答からは，個別の課題の統合ができ協調学習ができていることが分かる．アンケート結果のさらに複雑なシステムも作ることができると感じているという回答からは，課題の統合が容易に実現できていることが分かる．

5. おわりに

本研究では，個別学習と協調学習を組み合わせた，両者の利点を合わせ持った学習支援を提案した．本提案の特徴は，協調学習における課題を複数の小課題に分けて，学生それぞれが異なる 1 つの小課題に取り組んだ後その結果を統合することで，それぞれの学生が統合とディスカッションに必要な知識を予め学習することにある．これは，小さな課題に取り組むことが知識構成型ジグソー法のエキスパート活動に対応し，そこで学習者間で異なる基本的な知識を得て，その後ジグソー活動に対応して個別学習の成果を持ち寄りグループで 1 つの課題に取り組むという方法である．提案したシステムは実世界にある IoT 化された機器とコンピュータ上の教材を学習者自身が組み合わせたり編集したりできるサイバーフィジカルな学習環境である．

謝辞

本研究の一部は，科学研究費基盤研究(C)(一般)(16K01150)を受け推進している．

参考文献

[Aronson 96] Elliot Aronson, Shelley Patnoe: The Jigsaw Classroom: Building Cooperation in the Classroom, Scott Foresman & Co, 1996.

[三宅 02] 三宅なほみ，三宅芳雄，白水始:学習科学と認知科学，Cognitive Studies, Vol. 9, No. 3, pp. 328-337, 2002.

[三宅 16] 三宅なほみ，東京大学 CoREF，河合塾: 協調学習とは，北大路書房，2016.

[野口 95] 野口孝文，田中譲:コンストラクションセットを持つマイクロワールド，情報処理学会論文誌，Vol. 36, No. 1, pp. 152-166, 1995.

[野口 15] 野口孝文，千田和範，稲守栄:初心者から上級者までシームレスにプログラミングを学ぶことができる持続可能な学習環境の構築，教育システム情報学会論文誌，vol. 32, No.1, pp.59-70, 2015.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

認知的徒弟制理論による教育支援ロボットが及ぼす効果

Effect of Educational-Support Robot Based on Cognitive Apprenticeship Theory

宮内　建弥 *1　ジメネスフェリックス *1　吉川　大弘 *1　古橋　武 *1
Kenya MiyauchiI　Felix Jimenez　Tomohiro Yoshikawa　Takeshi Furuhashi

*1名古屋大学大学院工学研究科
Graduate School of Engineering Nagoya University

Recently, educational-support robots, which support learning attract many people's attentions. In previous research the robot teaches how to solve some questions only. However, it is difficult for learners to improve their applied skill and inquiring mind, because it cannot prompt learners to deliberate. Thus, this study develops a robot which support based on cognitive apprenticeship. The previous study reported that teaching based on cognitive apprenticeship can prompt learners to deliberate in pedagogy. Therefore, learner who was taught based on cognitive apprenticeship can be improved the applied skills and inquiring mind. In this paper, we investigates learning effect and impression effect of learners for the robot which support based on cognitive apprenticeship.

1.　はじめに

近年，教育現場においてサポートを行う，教育支援ロボットに対する注目度が高まっている [1][2]. 教育支援ロボットには，教師のように学習者へ教示を行う「教師型ロボット」[3] が存在する．従来研究において，ロボットは学習者に対して問題の解き方や学習方法を教示のみを行う [4]．しかしながら，学習者がロボットから教示を受けるだけでは，学習者は問題に対して熟考することが難しい．そのため，学習者は問題に対する応用力や，学習に対する探求心の向上を促せない可能性がある．教育学の分野において，認知的徒弟制理論に基づき，教師が学習者に対して教示を行うことで，学習者の応用力や探求心の向上を促せると報告されている [5][6]. 認知的徒弟制理論は，6 段階の支援方法により構成され，学習者の学習状況に合わせて，支援方法を変える教育理論である．教師型ロボットにおいても，認知的徒弟制理論に基づき，学習支援を行うことで，学習者の応用力や探求心の向上を促すことができると考える．そこで，本研究では，学習者が問題を解きながら学習する状況下において，認知的徒弟制理論に基づいて学習支援を行う教師型ロボットを開発する．本稿では，認知的徒弟制理論に基づいて，ロボットが学習支援を行うことで，学習者に及ぼす学習効果および印象について検討する．

2.　認知的徒弟制理論

認知的徒弟制理論は，下記の 6 段階で構成されている．
(1) Modeling : 指導者は，学習者に問題の解き方を教示する．
(2) Coaching : 指導者は，教示した問題の解き方を学習者が実践できるようなヒントを提供する．
(3)Scaffolding and Fading : 指導者は，学習者が自身の能力だけで問題を解くように促す．また，指導者は，学習者が困っている場合には，Coaching と同じヒントを提供する．
(4)Articulation : 指導者は，学習者に問題を解くまでの思考過程を説明するように促す．
(5)Reflection : 指導者は，他の解き方を教示し，学習者に，自身の問題を解くまでの思考過程を検討するように促す．

連絡先: 名古屋大学大学院工学研究科，〒 464-0814 愛知県名古屋市千種区不老町，miyauchi@cmplx.cse.nagoya-u.ac.jp



図 1: Sota

(6)Exploration : 指導者は，学習者に新たな学習内容へ挑戦することを促す．
これら 6 段階の支援を切り替えることで，問題に対する応用力が身に付くことができると示唆されている．また同時に，自分の力で問題を解くことの楽しさを実感することで，探求心の向上につながる可能性があると示唆されている．

3.　ロボットの学習支援モデル

本ロボットが行う学習支援方法は，認知的徒弟制理論の (1) から (3) 段階目の学習支援である．具体的には，1 問目の問題については，ロボットは Modeling による学習支援を行う．この段階では，ロボットは，学習者に問題の解き方を教示する．類似問題の 2 問目については，ロボットは Coaching による学習支援を行う．この段階では，Modeling の段階で教示した問題の解き方を学習者が実践できるようなアドバイスを提供する．3 問目以降では，ロボットは，Scaffolding and Fading による学習支援を行う．この段階では，ロボットは基本的に学習者を見守り，学習者がヒントを要求した場合のみ，問題の解き方に関するヒントを提供する．段階の切り替えについては，問題を正解したら次の段階に移り，間違えた場合は前の段階に戻るという形で切り替えを行う．



図 2: 画面インターフェース



図 3: 画面インターフェース 2

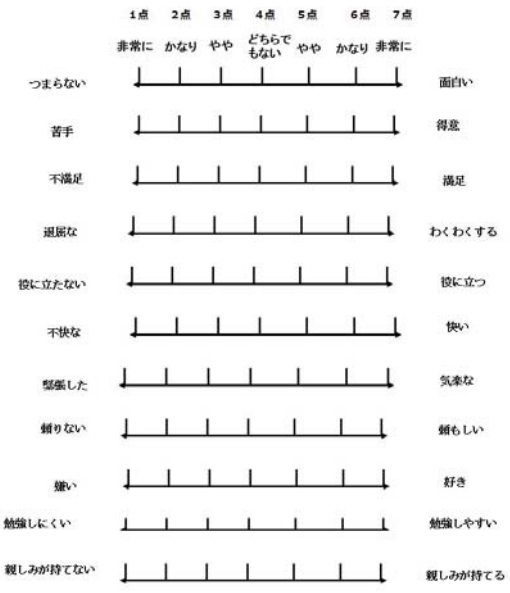


図 4: アンケート項目

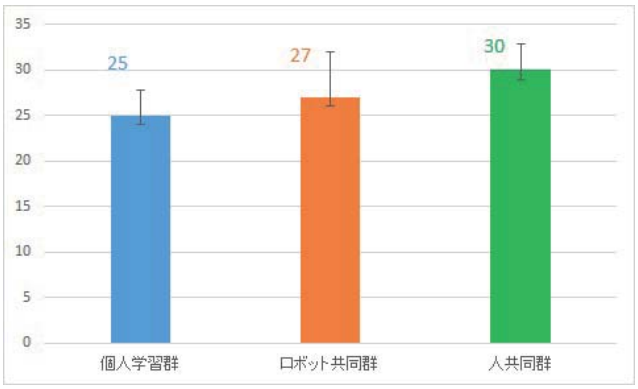


図 5: 向上点の平均

4. 実験

4.1 方法

実験には，ロボット Sota(図 1) と画面インターフェース (図 2) を用いた．Sota は，発話や身体動作が可能であり，首の自由度が 3，両腕の自由度が 4，胴体の自由度が 1 であり，合計 8 の自由度を持つ．これにより，多様な身体動作が可能なロボットである．画面インターフェースは，開始のボタンを押すと 1 段階目の Modeling にあたる内容を表示し，その後，問題が表示され，正解・不正解によって Coaching や Scaffolding and Fading にあたる内容を表示する．この画面インターフェースに合わせてロボットを遠隔操作し，学習支援を行う．実験には，ロボットと共に学習を行う群「ロボット共同群」，画面インターフェースを用いて，個人で学習を行う群「個人学習群」，ロボットと同じ学習支援を行う人間と共に学習を行う群「人共同群」の比較実験を実施する．個人学習で用いる画面インターフェース 2(図 3) は，他群で与えられる情報に差がないようにするため，「テクニック」，「アドバイス」，「ヒント」の 3 つのボタンを用意した．テクニックボタンを押すと Modeling にあたる内容を，アドバイスボタンを押すと Coaching にあたる内容を，ヒントボタンを押すと Scaffolding and Fading にあたる内容を表示する．これらのボタンは学習者が任意で押すことができる．学習科目は，TOEIC の文法問題を 60 問用意し，理系大学院生 12 名を被験者とした．1 群 4 名とし，それぞれの群で学習してもらった．被験者には，実験に用いる学習問題で構成されている事前テストを実施し，群ごとの学習能力が均一になるように群へ振り分けた．学習時間は約 30 分であり，学習後，被験者にはアンケートを実施した．また，数日空けてから被験者には事後テストを実施した．事後テストは事前テストと同じ問題である．さらに事前・事後テストの問題と異なる類似問題で作成した応用力テストも実施した．

4.2 評価基準

本実験では，学習効果の向上として，事後テストの点数から事前テストの点数を引いた向上点を学習効果の評価基準とした．また応用力テストの点数を応用力が身についたかの評価基準とした．そのほかに，各群における学習の印象について，印象の定量的評価方法である SD 法 [7][8] に基づくアンケートで評価した．SD 法によるアンケート (図 4) では，最左側の「非常に」を 1 点として，右側に 1 つ移動するにつれて 1 点ずつ加点し，1〜7 の評点で数値化した．アンケートは「面白い/つまらない」，「得意/苦手」，「満足/不満足」などの 11 項目と自由記述を設けた．

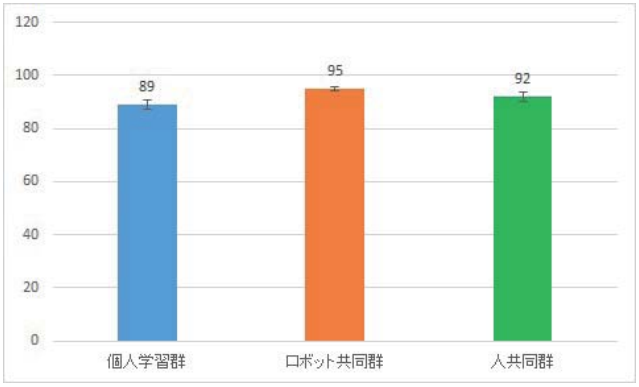


図 6: 応用力テストの点数の平均

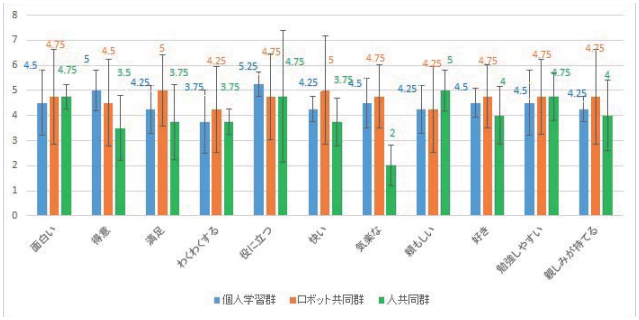


図 7: アンケート結果

4.3 結果

図 5 に各群における向上点の平均点を示す．図 6 に各群における応用力テストの点数の平均点を示す．図 7 には SD 法によるアンケートの各項目における評価値の平均点を示す．図 5 の結果から，向上点において，人共同群が，他群に比べて高いことがわかる．図 6 の結果から，ロボット共同群の応用力テストは他群に比べて高いことがわかった．図 7 からは，「役に立つ」，「得意」の項目は個人学習群が，「頼もしい」の項目は人間共同群が，「満足」，「わくわくする」，「快い」，「気楽な」，「好き」，「親しみが持てる」の項目はロボット共同群が高い結果となった．しかしながら，向上点，応用力テストの点数，SD 法の各項目における評価点において，統計的な有意差は認められなかった．

5. 考察

図 5，図 6 の結果から，認知的徒弟制理論に基づき，教示を行う学習支援は，認知的徒弟制理論に基づかない学習支援に比べ，学習者の学習効果や応用力を向上させる可能性がある．図 7 の結果から，「満足」，「わくわくする」，「快い」，「気楽な」，「好き」，「親しみが持てる」の項目における評価点は，ロボット共同群が他群に比べ高い．そのため，ロボットとの学習は，同じ学習支援を行う人間との学習や個人学習と比べて，楽しく学習することができる可能性があると考える．「頼もしさ」の項目では，人共同群がロボット共同群を上回っており，「気楽な」の項目に関しては，ロボット共同群は人共同群に比べて高い．そのため，同じ学習支援を行う状況では，人間に比べるとロボット方が，頼もしさには欠けるが，より緊張感を生み出すことがなく，リラックスして学習できる可能性があると考える．

6. おわりに

本稿では，認知的徒弟制理論に基づき，ロボットが学習支援を行ったことで，学習者に及ぼす学習効果および印象を検討した．学習効果については，認知的徒弟制理論に基づき学習支援を行うことは，学習効果を向上させる可能性があると示唆した．また印象については，ロボットと同じ学習支援をする人間と比べると，ロボットによる学習支援は，気楽で楽しく学習ができる傾向があることがわかった．今後は，被験者を中学生など年齢の低い被験者を対象にして，認知的徒弟制理論に基づきロボットが学習支援を行うことでの学習者に及ぼす学習効果についてさらに検討をしていく．

7. 謝辞

本研究は，文部科学省科学研究費 (若手研究 (B), No.17K12766) の補助を得て遂行された．

参考文献

[1] N.Miyake, H.Ishiguro “Toward a Collaboratively Creative Society through Human-Robot Symbiosis” Journal of the Robotics Society of Japan, Vol.29, No.29, pp868-870, 2011

[2] M, Shiomi, T, Kanda, I. Howly, K. Hayashio and N, Hagita, “Can a social Robot Stimulate Science Curiosity in Classrooms?”, International Journal of Social Robotics, Vol.7, No.5, pp641-652, 2015

[3] O.H. Kwon, S.Y. Koo, Y.G. Kim and D.S. Kwon“Telepresence robot system for English tutoring” , IEEE Workshop on Advanced Robotics and its Social Impacts,2010

[4] H .Eonghye, J. Miheon, J. Vicki and H. Jo“Comparative Study on the Educational Use of Home Robots for Children”, Journal of Information Processing Systems, Vol.4, No.4, December 2008

[5] A. Collins , J. S. Brown and S. Newman , “Cognitive apprenticeship :teaching the craft of reading, writing and mathematics”, Essays in Honor of Robert Glaser, Ebaum,HiLLsdale NJ,1989

[6] S. Lajoie and A. Lesgod “Apprenticeship training in the workplace :computer coached practice environment as a new from oh apprenticeship” Machine Mediated Learning,No.3,pp,7-28,1989

[7] Osgood, C. E, Suci, G.J. & Tannenbaum, P.H. “The Measurement of Meaning”, Univ. of Illinois Press. Urbana. 1957

[8] M. Inoue, T, Kobayashi “The research domain and scale construction of adjective-pairs in a semantic differential method in japan”, Japanese Association of Educational Psychology, Vol.33, pp253-260, 1985

競技かるたにおける決まり字変化シミュレーションシステムの構築

Development of a Simulation Support System for Changing Decision Character during Playing Japanese Poem Card Game

徳島 智春
Chiharu Tokushima

曽我 真人
Masato Soga

和歌山大学 システム工学部
Faculty of System Engineering, Wakayama University

Japanese Poem Card Game is a game in which a reader reads upper sentence of a poem and players get the card with lower sentence of the poem. One hundred poems from Japanese traditional poem set called “Hyakunin-isshu” are used for the game. A game is played with two players, and a player who got more cards than the other player wins the game. Therefore, players try to get the card as early as possible to win the game. Players need to remember lower sentence of the poem, when a reader begins to read upper sentence of the poem. Since some beginning characters of upper sentences are the same, players need to listen to decision character which decides unique card with lower sentence. The decision character changes during a game, because the number of cards with lower sentences which correspond with the same beginning characters of upper sentences decreases. Since it is difficult for a learner to simulate the change of decision character in mind, we propose and developed a support system which simulates the change of decision character. We verified the effect of the system by an evaluation experiment.

1. はじめに

競技かるたとは，百人一首を用いた競技であり，小学生から高齢者まで年齢を問わず楽しめる競技の一つである．その歴史は江戸時代まで遡り，一般的には，古典的な伝統文化であると捉えられることが多い．しかし，競技かるたの本質としては，高度な瞬発力，記憶力，精神力，集中力など，あらゆる分野の技術が求められる激しいスポーツである．競技かるたを行う上で重要な事項は，身体能力，集中力，記憶力，耳の良さ，札の配置，決まり字などが挙げられる．本研究では「決まり字」に着目して研究を行った．

2. 競技かるたについて

2.1 百人一首

百人一首とは，百人の歌人の和歌を一人一首ずつ選んで作った歌集のことで，一般的に百人一首とは藤原定家が選んだとされる小倉百人一首のことを指す．

現在では鑑賞のほかにも，古文の教材や，かるたなどの用途に使われている．

2.2 競技かるた

競技かるたとは，百人一首を用いた競技で，読手が百人一首の上の句を読み，競技者が下の句だけが書かれた札をとるという競技である．昨今，百人一首や競技かるたを題材とした漫画や映画が取り上げられ，世間の関心が大変高まっている．日本国内だけでなく，国外の方々でも興味を持つ人が多くなっている．

連絡先：徳島 智春（とくしま ちはる），和歌山大学，〒640-8510 和歌山市栄谷 930 和歌山大学システム工学部 曽我研究室，073-457-8457，s195042@center.wakayama-u.ac.jp

2.3 決まり字

下競技かるたでは素早く札をとるための戦略として，決まり字というものが大変重要になっている．決まり字とは，競技かるたにおける上の句のここまで文字が読まれると下の句の取る札が確定する文字のことである．

決まり字は，札が読まれる度に変化していく．たとえば，決まり字が“う”から始まる札は，二字決まりである“うか”と“うら”の 2 枚しか無いので，どちらか一方が読まれると残った札は決まり字が“う”の一字決まりとなる．

また，同じ文字から始まる札をお互いに友札と呼ぶ．そして，“う”から始まる札に関しては，友札が“うか”と“うら”の二枚あるので，これを二枚札と呼ぶ．二枚札は決まり字の変化パターンが 2!＝2 通りある．さらに，二枚札は“う”から始まる札，“つ”から始まる札，“し”から始まる札，“も”から始まる札，“ゆ”から始まる札の5組あるので，全部で2×5＝10通りある．同様に考えて，三枚札は 3!=6通りあり，4組存在するので6×4＝24 通りある．四枚札は 4!＝24 通りあり，4組存在するので 24×4＝96 通りある．このように，二枚札であれば理屈はまだ単純であるが，三枚札，四枚札と増えていくと次第に難解になっていく．

図1は本システムで用いた札のデザインである．下の句（黒字）だけが書かれた一般的な取り札の上に，赤字で決まり字を載せたデザインになっている．



図1 取り札デザイン

次に示す図2～図5は，”は”から始まる四枚札である“はなさ”“はなの”“はるす”“はるの” を例として決まり字の変化を示した木構造である．

この木構造は，まず初めに取った札をルートに示しており，そのあと，友札の中でどれが出ると，決まり字がどのように変化するかを示したものである．図2を用いて解説すると，まず“はなさ”の札が出たと仮定する．その時点で“はなの”の札は決まり字が“はな”になる．“はるす”と“はるの”は変化しない．次に，“はるの”の札が出たとすると，“はなの”が変化した“はな”は決まり字が“はな”のままであるが，“はるす”の札は決まり字が“はる”に変化する．次に，“はるす”が変化した“はる”が出たとすると，残りの“はなの”が変化した“はな”は決まり字が“は”の一字決まりとなる．

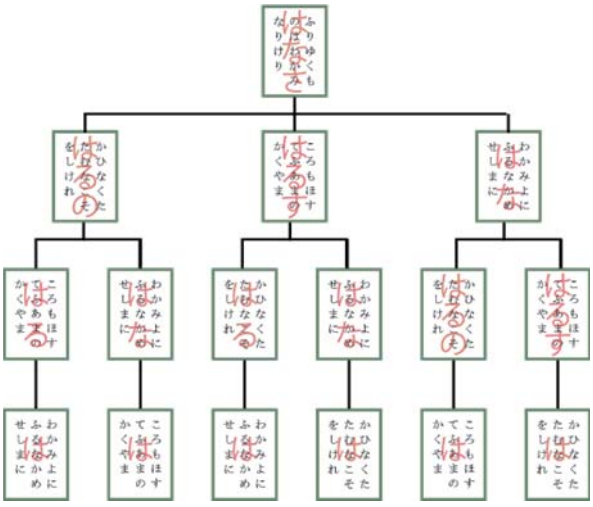


図2 決まり字変化パターン1

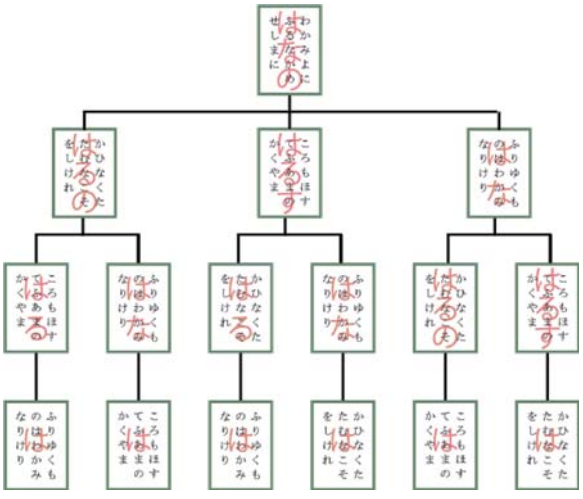


図3 決まり字変化パターン2

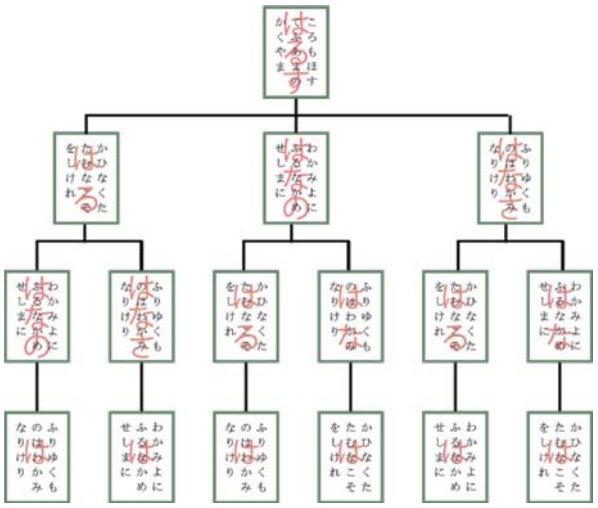


図4 決まり字変化パターン3

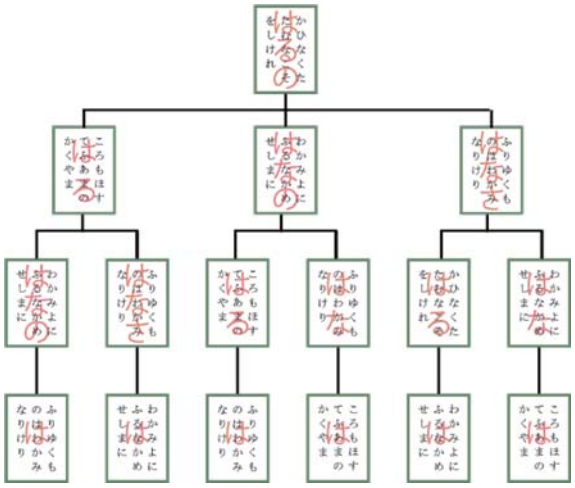


図5 決まり字変化パターン4

また，最も友札が多いのは“あ”から始まる札であり，友札が16 組存在し，これを競技中に配置とともに記憶していくことは初学者にとっては非常に厳しい課題である．これは競技かるた初学者にとって一つの壁となっており，上級競技者でもその場面でのすべての決まり字を把握するのは困難を極める．

3. 研究概要

3.1 従来の学習方法

従来の決まり字の学習方法として，図 1 のような，実際の札の上に決まり字が書かれた札を使って，競技を行いながら学んでいく方法がある．しかし，これは決まり字変化には対応しておらず，結局は自分の脳内で逐次決まり字変化をシミュレーションしていく必要がある．

3.2 研究背景

初心者向けの，競技を行いながら決まり字の学習を行う実際の札はあるが，競技進行による決まり字の変化には対応できないという点に着目し，決まり字変化をよりわかりやすく可視化して，リアルタイムで学習できないかと考えた．

3.3 関連研究

(1)は，札を決まり字の種類によって区別し，可視化することで，盤面を見たときにひと目で札の分布がわかり，同じ種類の札が固まっているのか，分散しているということが判断できるように設計されたインタラクティブコンテンツの研究である．また，実際の札を利用することにより，結果を踏まえた後の並び替えが容易であり，リアルタイムに分布の表示が変化するため，常に盤面上の結果を把握することが可能である．

この研究は自陣の札の配置を可視化しているものであるが，それに対して筆者らの研究は，決まり字の変化を可視化するものであり，目的が異なる．

3.4 研究目的

競技かるたにおける決まり字変化の学習を可視化し，効率的に学習を行うことができるようにする．システム使用者がより早く札を取れるように，決まり字変化の観点から支援する．このようなシステムの構築，評価実験を行う．

4. システム概要

4.1 システムの流れ

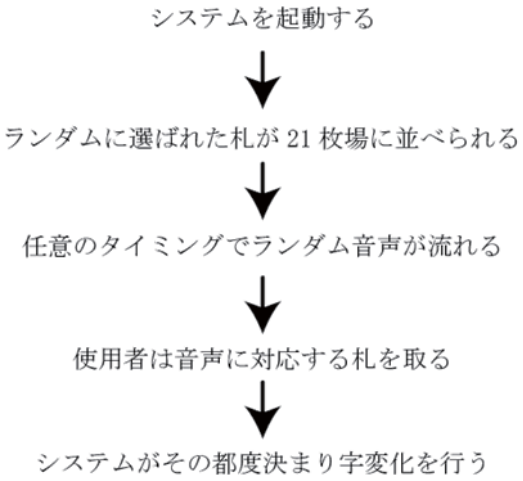


図 6 システムの流れ

4.2 システム画面

システム画面を以下に示す．図7は，起動時の画面であり，図8は決まり字が変化するときの画面である．

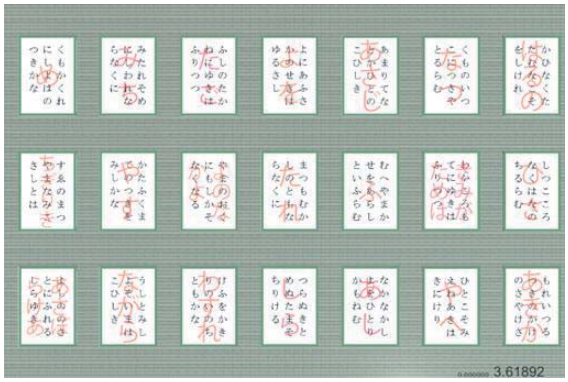


図 7 システム画面

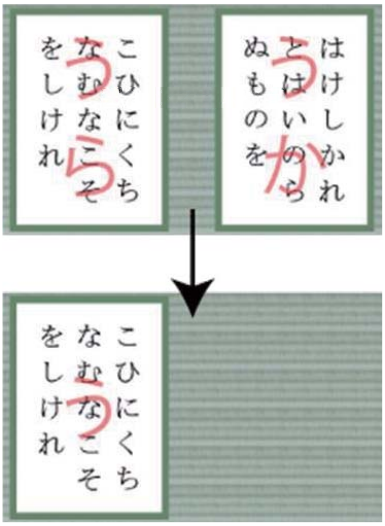


図8 決まり字変化

4.3 使用ソフトウェア

・OS

本システムはすべて PC 上で動作する．OS は Windows を想定しているが，アプリケーションを書き出す時点で設定を変えれば，Mac や Linux にも対応可能である．

・Unity

Unity とは，ユニティ・テクノロジーズが開発したゲーム開発プラットフォームである．使用した言語は C#である．

・Adobe Illustrator

Adobe Illustrator は，アドビシステムズが販売するベクターイメージ編集ソフトウェア（ドローソフト）である．取り札を制作するのに使用した．

5. 実験と評価

5.1 実験目的

決まり字変化機能を搭載していないシステムと本システムを比較し，本システムの有用性を評価する．

5.2 実験概要

本実験では大学生 10 名を学習者として実験を行った．学習者 10 名を実験群，統制群の 2 群に 5 名ずつ分けて実験を行った．統制群では，決まり字変化機能を搭載していないシステ

ムによる学習を，実験群では本システムを用いた学習を行った．学習者にはシステムによる学習の前後に，決まり字が書かれていない札を使用したシステムを用いて，テストを行った．テストでは，音声が読み上げられる瞬間から札を取る瞬間までの時間を札獲得時間と呼び，それを計測する．事前テストと事後テストの札獲得時間の差分を向上値として，向上値を両群間で比較する．

5.3 実験対象

本システムは初学者向けであるため，実験対象は初学者限定とする．

5.4 実験の流れ

実験の流れを図9に示す．

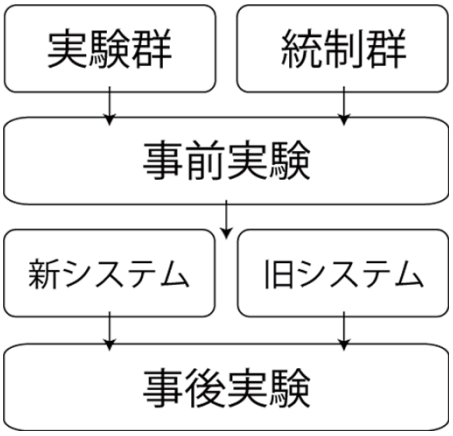


図9 実験の流れ

最初に両群ともに事前テストを実施した．次に実験群は本システムを用いた学習，統制群では決まり字変化機能を搭載していないシステムを用いた学習を 約 30 分間行った．学習の後に学習の効果を測定するために事後テストを行った．

5.5 実験結果

図 10 は実験群を，図 11 は統制群の事前テストと事後テストの結果を折れ線グラフで示したものである．縦軸は，札獲得時間を表す．

また，図 12 は実験群と統制群の向上値の平均をグラフにしたものである．

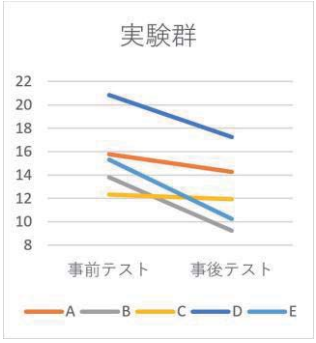


図 10 実験群グラフ

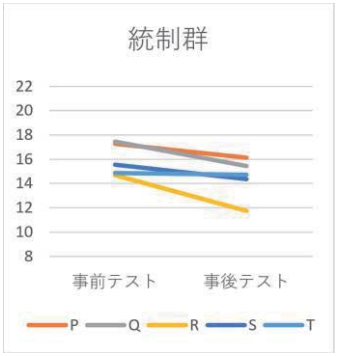


図 11 統制群グラフ

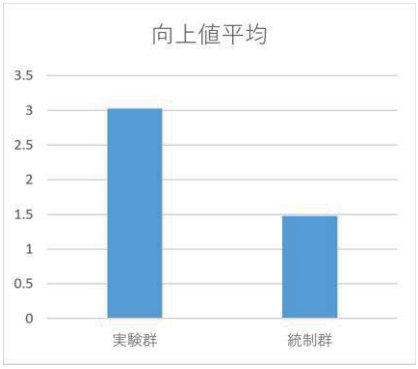


図 12 向上値平均グラフ

6. おわりに

本研究では，数ある競技かるたの戦略のうち，決まり字変化という戦略に着目し，競技かるた初学者が決まり字変化をよりスムーズに学べるシステムを考案した．本システムでは，ランダムに流される音声に対応した，ランダムに並べられた決まり字が書かれた札をクリックすると札を取ることができる．これらの一般的な競技かるたを楽しむ機能に加え，全決まり字変化パターンを分岐により制御した．

今後の課題として，競技かるたにおいて多数の戦略が存在するので，それらの機能も付加していくと，総合的に競技かるたを学べる学習支援環境に発展させることができると考えられる．

参 考 文 献

(1) 都丸幸浩,藤岡優,安本匡佑,羽田久一,太田高志.競技かるたの札の配置を行うインタラクティブコンテンツ.情報処理学会第 75 回全国大会(2013)

(2) 谷口直子.(2004). 小倉百人一首競技かるたの普及過程

(3) かるた一病息災 百人一首一覧

(4) 百人一首の風景 決まり字一覧

(5) 全日本かるた協会 競技規程細則
(http://www.karuta.or.jp/kitei/kyougi_saisoku.pdf)

(6) 一般社団法人 全日本かるた協会
(http://www.karuta.or.jp/)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

小学生の書道基本姿勢定着に向けた点画検出および採点手法

Character Strokes Detection and Scoring for Increasing Children's Calligraphy Training time

柿野 優衣 *1 Yui Kakino　河野 慎 *2 Makoto Kawano　米澤 拓郎 *2 Takuro Yonezawa　中澤 仁 *1 Jin Nakazawa

*1慶應義塾大学環境情報学部
Faculty of Environment and Information Studies, Keio University

*2慶應義塾大学大学院政策・メディア研究科
Graduate School of Media and Governance, Keio University

In order to encourage elementary school students unfamiliar with Japanese calligraphy to have an assertive attitude towards acquiring basic calligraphy skills, it is imperative to have an application that provides an environment which allows them to practice calligraphy regardless of the time and place. Due to the fact that this application requires an evaluation system that does not need a calligraphy teacher's assistance, this research proposes a method of automatically evaluating a work of calligraphy. All detected strokes within one sheet will be regarded as an object detection problem, therefore, the entire work's evaluation will depend on the detected strokes. Strokes are a fundamental technique in calligraphy, and are a vital component in creating a work of calligraphy.

1. はじめに

書道に対して基本姿勢を身につけることは書作品の向上において重要である．書道基本技術である点画を意識して筆を動かすことは文字の構成を整え，作品全体を美しくする．特に習い始めは，点画の練習において筆の角度，圧力などからの線質の変化を学ぶことで基本を身につけるため，練習量の増加に伴ない書道技術が向上していく．ゆえに初めて書道に触れる小学生からこれらを行っていくことは，書作品の向上において重要であるといえる．小学生は，小学校の授業内や教室に通うなどして指導者がいる下で練習を行う．しかし，書道指導者は複数の小学生に対し１人であることが多い．そのため小学生の希望時間に沿った練習を行うことは困難であり，限られた時間内での練習量になってしまう．

この問題の解決策として小学生が希望時間に練習環境を得られるスマートフォンアプリの導入が挙げられる．例えばスタディサプリ *1 ではスマートフォン上で予備校の授業を受けることが可能となっており，小・中学校導入による成果も報告されている [株式 17]．書道練習に同様なアプリケーションを導入するには，書道作品の評価を自動で行えることが重要だと考える．そこで本研究では画像認識技術を用いて小学生の書作品に含まれる点画を検出し，作品の点数化を行う手法を提案する．図 1 に全体の流れを示す．まず点画検出には物体検出手法の Single Shot MultiBox Detector（SSD） [Liu 16] を採用する．データセットには書道教室に通う小学生１－６年生の実際の書作品を用いて，５種類の点画検出を行う．さらに，５種類の点画を美しさに関する２種類のラベルを用いて評価し，１０種類の点画検出も行う．実験では学習に用いるデータセット数の増加に伴う平均適合率（AP）の全カテゴリの平均（mAP）を用いた精度比較および，書作品の点数化について定性的に検証する．実験の結果，データセット数が増加するにつれて，点画検出の精度の向上および点数に関する妥当性を確認することができ，提案手法の有効性を示した．

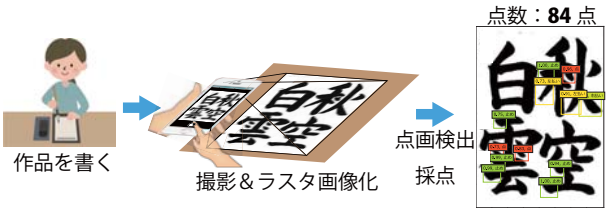


図 1: 全体の流れ．1．作品を書く．2．書作品をカメラやスキャナなどで画像化する．3．５種類の点画およびそれぞれの美しさを検出し，その結果にもとづいて点数を算出する．

2. 書道作品における点画検出

小学校の授業では伝統的な言語文化に親しむことを目的として１，２年生では硬筆，３年生からは毛筆を学び始める．小学生学習指導要領解説，国語編に「点画の書き方や文字の形に注意しながら，筆順に従って丁寧に書くこと」[gak 17] とある．基本技術である点画を意識して書くことは文字を構成し書作品を美しくする上で重要なためである．また，点画の筆の運びを練習することは筆をうまく扱うことにつながり，線筆の上達を促す．線筆は書道作品にとって重要な要素であり，点画を練習することは線筆の向上にも役立つ．これより，点画を意識した筆の運びが基礎を身につける上で大切であり，点画の美しさが書作品を評価すると考える．そのため点画評価を用いて作品の点数化を行う．

書作品内の様々な箇所に現れる点画を検出及び採点をする必要がある．そこで本研究では，点画検出を物体検出問題として取り組む．カメラやスキャナなどを使用して画像化された書作品が入力として与えられた時，その画像に含まれる点画を検出する．本稿で点画の種類を図 2 に示す．本研究では全８種類の点画のうち書作品構成で重要な点画である点，止めの始筆，そして左払い，右払い，跳ねの終筆の５つを対象とする．

連絡先: 柿野優衣，慶應義塾大学環境情報学部
〒 252-0882 神奈川県藤沢市遠藤 5322 デルタ棟 S213，
yuui@ht.sfc.keio.ac.jp

*1 https://studysapuri.jp

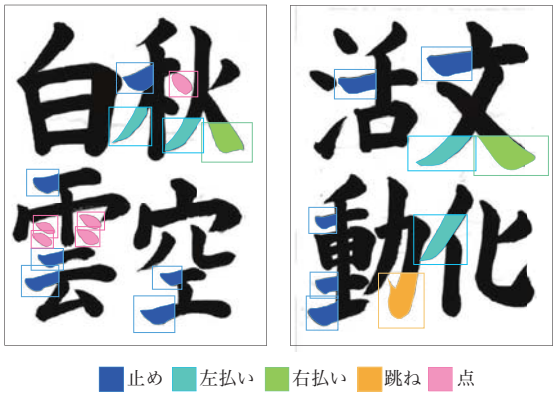


図 2: データセット例．小学生楷書作品を対象とする．止め，左払い，右払い，跳ね，点の５種類の点画を示す．図に示すように点画を四角で囲みアノテーションを作成する．

3. 提案手法

本章では，書作品における点画の検出手法と採点手法について説明する．

3.1 点画検出

本研究では，点画の検出問題を物体検出問題とみなし，深層学習を用いた物体検出技術を用いる．物体検出技術では，Faster R-CNN [Girshick 15] や YOLO [Redmon 16a, Redmon 16b] なども挙げられるが，本研究では検出速度でなく検出精度に重点を置くため，single shot multibox detector（SSD）[Liu 16] を採用する．SSD は，ニューラルネットワークの構造に VGG16[Simonyan 14] を採用しており，非常に高い精度での物体検出が可能である．VGG16 によって抽出された特徴マップを 6 種類のスケールに畳み込み，それぞれのスケールでの枠線に関する出力をする．出力では，あらかじめ定義されている枠線の初期値からのオフセットと，検出対象となる各点画に対する確信度を算出する．この 6 種類のスケールを用意することで，様々な大きさの枠線に対応することができ，点のように小さな点画から，払いのような大きい点画まで対応することが可能である．SSD に図 2 で示している点，止めの始筆，そして左払い，右払い，跳ねの終筆の５種類を学習させる．学習では，バッチサイズは 1，最適化アルゴリズムには Adam [Kingma 14] を利用し，学習率は 0.0003 とした．

3.2 採点手法

点画の評価は，美しさを定量的に図ることは難しいと考えることから，数段階の評価で美しさを判断するのではなく美しいか美しくないかの２段階で評価を行う．５種類の各点画に対し「美しい」「美しくない」の２種類のラベル付けをさらに行う.「美しい点」「美しくない跳ね」などの合計１０種類の物体検出問題とする．作品の点数は検出された点画の合計に対し「美しい点画」と検出された点画の割合を１００倍することで算出する．

$$score = \frac{N_{\text{美しい点画}}}{\sum N_{\text{検出された点画}}} \times 100 \quad (1)$$

図 5 に，実際に実験結果から点数を算出する様子を示す．

4. 実験

実験では，はじめに SSD による点画の検出が可能であるか mAP を用いて検証する．その際に学習に用いるデータ数を変化させ，検出精度の変化を観察する．次に．各点画の評価を含めた 10 種類に拡張し，検出精度の検証と書作品の点数化の定性的な評価を行う．

表 1: データセットアノテーション数

点画種類	美しい	美しくない	合計
点	148	65	213
跳ね	18	80	98
左払い	56	164	220
右払い	146	88	234
止め	403	260	663

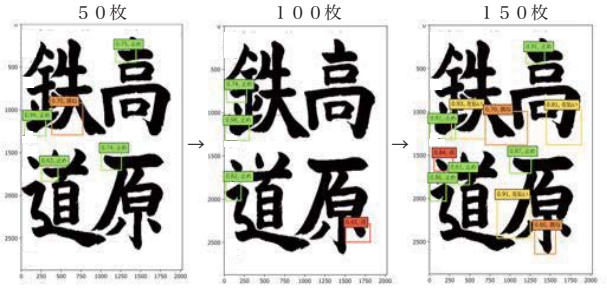


図 3: 点画検出数変移．データセット数が５０枚，１００枚時の検出総数と比較して１５０枚での検出総数が増加している．

4.1 データセット

本研究では，書道教室に通う小学３年生から６年生の楷書作品，合計 180 枚をスキャナを利用し画像にしたものをデータセットとして用いる．アノテーション作成は図 2 に示すように行う．全作品にアノテーションした結果を表 1 に示す．点画評価の際のラベル付けは書道師範取得者が行う．表 1 には「美しい点画」「美しくない点画」のアノテーション個数を示す．

4.2 結果・考察

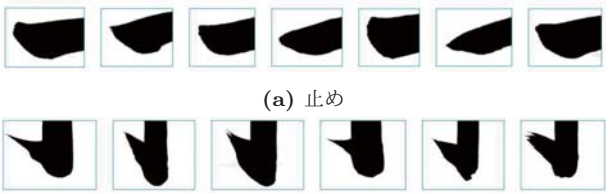
実験の結果を表 2 に示す．データセット数が増加するにつれて mAP を比較すると精度が向上することがわかった．これは，図 3 に示すようにデータセットが５０枚，１００枚時点での点画の検出総数に対し，１５０枚での結果の方が検出総数が多いことからもわかる．このことからデータセット数を増やすことでモデルの精度が向上する可能性を持つことが考えられる．次に表 2 に示すデータセット数１５０枚での学習結果に着目し，各点画で mAP の値を比較すると,「止め」はアノテーション個数が最も多かったに対し AP の値は「点」についで２番目に低い．一方で,「跳ね」のアノテーション個数は全体と比較して少ないが，AP の値は最も優れていることがわかる．これより，点画の形によって検出のしやすさが異なることがわかった．これは点画それぞれの特徴が要因であると考える．図 4a には「止め」の始筆の例，図 4b「跳ね」の終筆の例を示す.「止め」の始筆は「跳ね」の終筆に比べ特徴が少なく形が多様であるのに対し,「跳ね」は輪郭が特徴的であることが他の点画に比べ AP が最も高い要因ではないかと考察する．

図 7 に点画の誤検出例を示す．１つの「右払い」に対し，２つの「右払い」が検出されている．このように１つの点画に対して複数の点画が検出されるような誤検出があった．これは Non-Maximum Suppression 適用時における IoU の閾値が適していないことが考えられる．

図 5 に検出結果の例を示し，各点画の AP と mAP を表 3 に示す．図 5 の作品の場合，検出された検出された運筆数が

表 2: データセット数増加に伴う mAP の変化

データ数	mAP	点	跳ね	左払い	右払い	止め
50 枚	27.1	9.1	4.5	34.2	31.9	55.7
100 枚	49.9	34.7	57.9	44.1	45.1	67.9
150 枚	62.2	45.5	72.0	68.4	59.5	65.9



(a) 止め

(b) 跳ね

図 4: 点画の例

１０個に対し美しいと判断された運筆が４個であるため作品の点数は４０点である．表 2 の各点画の AP を見ると１５０枚のデータセットで学習した際の値と比較して，ラベル付けを行なった各点画の AP が低いことがわかる．これはデータセットを「美しい点画」「美しくない点画」に分類したことで表 2 に示す通りデータセットが減ってしまったことが原因であると考えられる．また，上記に述べたように一つの点画に複数の点画が検出されることで，この検出された点画が「美しい点画」であった場合，作品の点数が高くなってしまうという問題が生じた．

図 6 に評価のラベル付けを行なった点画の検出結果の成功例と失敗例を示す．表内が青く示されているものはラベルと検出結果が一致したもので，桃色のものはラベルと検出結果が異なったものである．表内の左払いに着目すると左払いを書く筆の運びの途中に線がかすれていなものを美しいと判断しているのではないかと考える．次に止めに着目すると，始筆の筆を置いて下に向かって反りながら筆を運ぶことでできる線を美しいと判断していると推測する．美しい止めが美しくないと判断される要因として始筆から山なりに筆を運んでいることが挙げられる．書作品点数化を師範者が定性的に評価を行なった結果，書作品に対する点数は妥当であるものが多いことがわかった．

一方で本研究では 1 人の師範者にがラベル付け，定性的評価を行なったため主観的な点数化であることが考えられる．そのため今後の課題として，複数人の師範者を評価に取り入れることでより書作品点数化に客観性を持たせる必要がある．今後アプリケーションを実装する際，書作品の取得にはカメラを用いることが想定される．提案手法で用いている深層学習には同一の物体であっても撮影状況によって異なる結果を出力してしまうドメインバイアスが報告されている [Ganin 16]．ゆえに本提案手法がカメラで撮影した書作品の点画を正しく検出できるか検証する必要があり，今後の課題としてあげられる．

5. 関連研究

書作品の評価． 本研究と同様に Chin-Chuan Han らの研究では書道作品の点数化を行なっている [Han 08]．彼らの研究では主に文字の中心，大きさ，手本の線との差異で点数をつけている．文字の中心や大きさは基本的な技術を身につけた後の評価対象となるため，書道の基本技術である点画をもとに点数化をすることは初心者に対し有用であると考える．また久保田ら

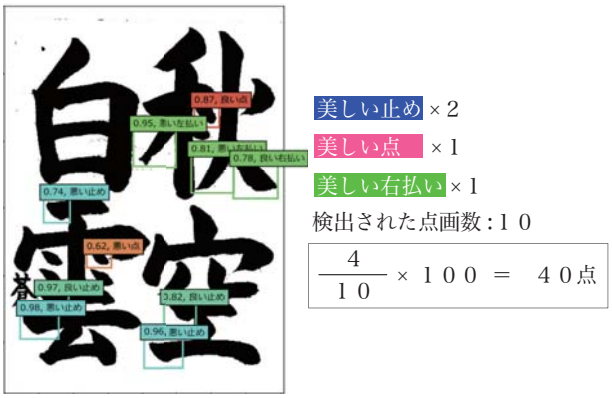


図 5: 作品点数化．点画を評価し採点手法に基づいて作品の点数を算出する．美しいと判断された点画は全部で 4 個であり，検出された点画は全部で 10 個である．したがって，この書作品の点数は $\frac{4}{10} \times 100 = 40$ 点となる．

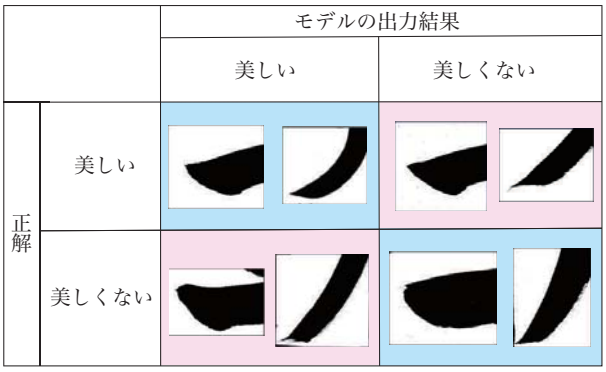


図 6: 評価後の点画検出の成功例・失敗例．青色は検出の成功例，桃色は失敗例となっている．これらの結果から，左払いを書く筆の運びの途中に線がかすれていなものを美しいと判断し，止めにおいては，始筆の筆を置いて下に向かって反りながら筆を運ぶことでできる線を美しいと判断している．

のように，ユーザに字を書く技術が向上していると錯覚させ，練習への意欲を向上させる研究もある [久保田 16]．

深層学習による物体検出． 本研究では，物体検出手法として，SSD [Liu 16] を用いたが，SSD と同様に物体検出するアルゴリズムとしては，YOLO [Redmon 16a, Redmon 16b] や Faster R-CNN [Girshick 15] などが挙げられる．これらの手法は，SSD と比較しても性能は十分に高い．したがって，今後これらの手法でも点画の検出および評価を行い，検証していく必要があるといえる．また，今回は点画を四角の枠線で囲み，物体検出タスクとして取り組んだ．しかし，点画を四角で囲む範囲は，アノテーションする人によって異なってしまうため，実験における検出精度に影響があると考えられる．そこで，He らの研究 [He 17] のようなインスタンス分割手法の適用も有用であると考える．点画の始筆から終筆までを一つのインスタンスとみなして検出することで，より正確な点画の検出および評価が可能になると考えられる．

アプリによる行動支援． 本研究では，書道練習をアプリケーションで行うことを想定している．同じように，スマートフォンのアプリケーションを用いて，教育を行おうとしている研究は数多く存在する．Kang らは，外国語を学ぶ子どもに本を積極的に読ませるためにアプリケーションを実装している [Kang 16]．同様に Gonzalez らは物理を学ぶためのアプリケーションを提案しており [González 17]，Briz-Ponce らは医学部

表 3: 評価した点画の検出結果

点画種類	美しい	美しくない
点	34.4	1.8
跳ね	100	50.9
左払い	16.3	33.4
右払い	28.7	18.1
止め	37.3	46.3

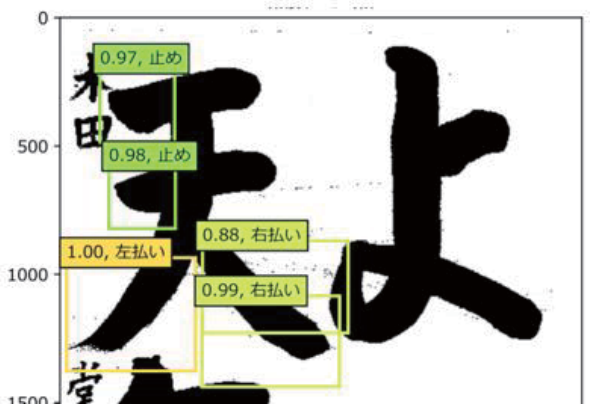


図 7: 作品誤検出．1 つの右払いに対し，2 つの右払いが検出されている．これは，重複した枠線を取り除く NMS の閾値が高かったためと考えられる．

の学生や先生に対して様々な健康に関する知識を提供するアプリケーションを実装している [Briz-Ponce 16]．このように，スマートフォンのアプリケーションを用いて，子どもや大人の教育を試みる研究は数多くあり，本研究での書道アプリケーションも有効であることが考えられる．

6. まとめ

本研究では，小学生の書道基本姿勢定着に向けたアプリケーションの実現のため，書作品の点数化を行った．その際に物体検出問題とみなし，物体検出手法の SSD を適用した．実験の結果．書作品に含まれる点画の検出が可能であることを確認した．また，データセット数の増加により mAP が向上したことで，今後データセットを増加させることでより正確な点画検出が可能であることを示した．また，「美しい点画」「美しくない点画」のラベルづけを行い提案した採点手法により，書作品の評価を物体検出を通して行えることの可能性について述べた．今後，提案手法を組み込んだアプリケーションを実現させることで小学生の書道技術の向上させ，書道の発展に貢献していきたい．

参考文献

[Briz-Ponce 16] Briz-Ponce, L., Juanes-Méndez, J. A., and García-Peñalvo, F. J.: Exploring Mobile Learning Apps for Medical Students and Health Care Professionals, in *Proceedings of the Fourth International Conference on Technological Ecosystems for Enhancing Multiculturality*, TEEM '16, pp. 461–465, New York, NY, USA (2016), ACM

[gak 17] 小学校学習指導要領解説 国語編, 文部科学省 (2017)

[Ganin 16] Ganin, Y., Ustinova, E., Ajakan, H., Germain, P., Larochelle, H., Laviolette, F., Marchand, M., and Lempitsky, V.: Domain-adversarial training of neural networks, *The Journal of Machine Learning Research*, Vol. 17, No. 1, pp. 2096–2030 (2016)

[Girshick 15] Girshick, R.: Fast r-cnn, *arXiv preprint arXiv:1504.08083* (2015)

[González 17] González, M. Á., González, M. Á., Martín, M. E., Llamas, C., Martínez, Ó., Vegas, J., Herguedas, M., and Hernández, C.: Teaching and learning physics with smartphones, in *Blended Learning: Concepts, Methodologies, Tools, and Applications*, pp. 866–885, IGI Global (2017)

[Han 08] Han, C.-C., Chou, C.-H., and Wu, C.-S.: An interactive grading and learning system for chinese calligraphy, *Machine Vision and Applications*, Vol. 19, No. 1, pp. 43–55 (2008)

[He 17] He, K., Gkioxari, G., Dollár, P., and Girshick, R.: Mask r-cnn, in *Computer Vision (ICCV), 2017 IEEE International Conference on*, pp. 2980–2988IEEE (2017)

[Kang 16] Kang, D. and Yoon, K.: A Study on Developing the Interface of Mobile E-learning Application for Children's Foreign Language Education, in *Proceedings of the International Working Conference on Advanced Visual Interfaces*, pp. 320–321ACM (2016)

[Kingma 14] Kingma, D. P. and Ba, J.: Adam: A method for stochastic optimization, *arXiv preprint arXiv:1412.6980* (2014)

[Liu 16] Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., and Berg, A. C.: Ssd: Single shot multibox detector, in *European conference on computer vision*, pp. 21–37Springer (2016)

[Redmon 16a] Redmon, J., Divvala, S., Girshick, R., and Farhadi, A.: You only look once: Unified, real-time object detection, in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 779–788 (2016)

[Redmon 16b] Redmon, J. and Farhadi, A.: YOLO9000: better, faster, stronger, *arXiv preprint*, Vol. 1612, (2016)

[Simonyan 14] Simonyan, K. and Zisserman, A.: Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv:1409.1556* (2014)

[株式 17] 株式会社リクルートマーケティングパートナーズ：スタディサプリを活用した東京都渋谷区立小・中学校でのアダプティブラーニング実証実験結果のご報告, プレスリリース (2017)

[久保田 16] 久保田 夏美, 新納 真次郎, 中村 聡史, 鈴木 正明：Mojivator: 手書き文字の融合により書きたくなる練習システム, in *Workshop on Interactive Systems and Software* (2016)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

小学校教師に対する Web ニュース推薦に向けた NIE ワークシートの分析と NIE 教材に適した記事判定法の検討

Analysis of NIE Worksheets and Article Estimation Method for Web News Recommendation to Elementary School Teachers

関 伸也[*1] Shinya Seki
安藤 一秋[*2] Kazuaki Ando

[*1] 香川大学大学院工学研究科 Graduate school of Engineering, Kagawa University
[*2] 香川大学工学部 Faculty of Engineering, Kagawa University

In elementary schools, NIE (Newspaper in Education), which uses newspaper as teaching materials in classes, is being implemented. However, teachers' loads are increasing by adjusting time in general classes, selecting suitable articles and preparing support materials. The purpose of this study is to construct a Web news recommendation system for elementary school teachers. This paper analyzes articles in NIE worksheets based on categories and readability, and examines an estimation method of Web news suitable for NIE in elementary schools.

1. はじめに

NIE（Newspaper in Education）は，新聞を教材として活用する取り組みのことであり，小学校や中学校を中心に，幅広い教育機関で実施されている[NIE 17]. 各地域の NIE 推進協議会は，NIE 実践報告書[報告書 17]を毎年発行している. 小学校での実践報告によると，地元や周辺地域に関する記事を用いて，地域学習として NIE を実践している例が多い. また，新聞記事を選ぶ・読む・内容について話し合うなどの活動を通じて，児童の読解力・語彙力・表現力・思考力や社会への興味関心が向上したと述べられている. さらに，物事を多角的にとらえる力・根拠を示しながら自分の考えを述べる力・情報を調べて整理する力の育成に効果があることも確認されている.

小学校での NIE では，各新聞社が発行している紙媒体の新聞や Web ニュースを使用している. しかし，これらの記事は児童を対象として書かれていないため，児童が学習していない漢字や，理解することが困難な表現などが使われており，児童にとって難解な文章であることが多い. そのため，日々発行される膨大な記事の中から，児童自身が自分の興味や課題に適した記事を探し出すことが難しいという実践課題がある. また，教師にとっては，NIE に適した記事を探すことや，記事に関する教材研究を行う必要があることで，教材準備の負担が増加するといった問題がある. したがって，記事の推薦や難解な言葉の言い換えなど，児童に対する支援と，NIE に活用しやすい記事や関連・補足資料の検索・選択など，教師に対する支援が必要になる. そのため，新聞記事に関する読解支援[河村 17]や児童に対する記事推薦[田中 16]などの研究が行われている. また，NIE の補助教材として，NIE ワークシートを Web 公開することで，授業実践を補助している地域紙はあるが，数が少ない.

本研究では，NIE を実践する教師向けの支援に注目し，NIE に活用しやすい Web ニュース記事を地域学習の教材集として推薦するシステムの構築を目的とする. NIE 教材としての価値が高い記事を推薦することで，教師が記事を探す負担を軽減し，NIE を継続的に実践する補助になると考える.

本稿では，NIE ワークシートを分析し，NIE 教材に適した記事を判定する手法について初期検討する.

連絡先：関伸也，香川大学大学院工学研究科，安藤研究室，
〒761-0396 香川県高松市林町 2217-20，
s14t242@stmail.eng.kagawa-u.ac.jp

2. NIE ワークシート

NIE ワークシートとは，NIE を推進するための支援サービスの 1 つである. 一部の新聞社は，NIE 実施の補助教材として独自にワークシートを作成し，Web 上で公開している.

NIE ワークシートは，図 1 のように記事の切り抜きを貼り付けて使用するものと，図 2 のように記事が付随しているものに大別できる. また，記事内容に関する読解問題も付随した NIE ワークシートを公開している新聞社もある.



図 1. 貼付型ワークシート※1

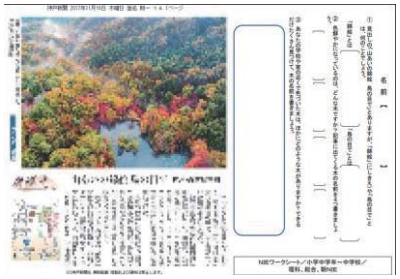


図 2.記事付随型ワークシート※2

日本新聞協会に所属している 104 社[日本新聞協会 17]の Web サイトを調査した結果，15 社で NIE ワークシートが公開されていた. また，表 1 に示すように，15 社中 11 社は，新たなワークシートを継続公開している. 11 社の内，「朝日新聞社」，「河北新報社」，「神戸新聞社」，「南日本新聞社」の 4 社は，NIE の経験が豊富な教員の意見も踏まえてワークシートに採用する記事を決定しているため，この 4 社の NIE ワークシートに採用された記事は，NIE 教材として質が保証された記事と考えられる.

しかし，地域学習で NIE ワークシートを利用することを考えると，NIE ワークシートを公開している地域紙は 14 社しかない. したがって，既存の NIE ワークシートのみで地域学習としての NIE 教材が充足できない. そこで，様々な地域の Web ニュースから地域学習に適した記事を推薦できれば，この問題を解決できると考える.

※1http://www8.kobe-np.co.jp/nie/2014/08/post-249.html
※2http://www8.kobe-np.co.jp/nie/2017/11/17/171116nisikie.pdf

表 1. NIE ワークシートの公開状況

新聞社名	公開数	教師の協力	現在の更新	新聞社名	公開数	教師の協力	現在の更新
朝日新聞社	1746	確認済	有	中日新聞社	48	不明	有
神戸新聞社	281	確認済	有	岩手日報社	33	不明	有
南日本新聞社	223	確認済	有	佐賀新聞社	17	不明	有
河北新報社	156	確認済	有	山陽新聞社	107	確認済	無
徳島新聞社	7043	不明	有	山梨日日新聞社	27	不明	無
静岡新聞社	560	不明	有	愛媛新聞社	15	不明	無
大分合同新聞社	230	不明	有	沖縄タイムス社	15	不明	無
琉球新報社	120	不明	有				

3. NIE ワークシートの記事分析

NIE 教材に適した記事の判定法を検討するため，ワークシートに選択された記事の特徴を分析する．本稿では，選択記事のカテゴリの傾向と，記事の読解難易度を分析の観点とする．

分析対象は，現在もワークシートを更新している地域紙の中で，記事選択に教員の意見が取り入れられており，ワークシートの公開数が最も多い，神戸新聞社のワークシートの記事とする．

3.1 記事カテゴリに基づく分析

神戸新聞社の NIE ワークシートの記事 181 件（2015 年 7 月～2017 年 11 月公開）のカテゴリを分析し，NIE 教材に適した記事カテゴリについて考察する．

(1) 新聞社カテゴリの傾向分析

神戸新聞社の NIE ワークシートの記事には，カテゴリが付与されていないが，Web ニュースはカテゴリが付与されている．神戸新聞社の Web ニュースは，“全国海外”，”地域”，“兵庫県内”，“連載・特集”のいずれかのカテゴリに分類され，それらのカテゴリ内でさらに 10 種以上の詳細カテゴリに分類されている．そこで，NIE ワークシートの記事が Web ニュースとして公開されている記事のみを最初の分析対象とする．

NIE ワークシートに掲載されている 181 記事に対し，新聞社カテゴリを調査した結果，表 2 に示すように，181 記事中 57 記事のカテゴリが取得できた．そして，57 記事のうち，地元に関する記事と考えられ，記事数が最も多い「兵庫県内」カテゴリの 41 記事について詳細カテゴリを調べた結果，表 3 に示すように，「社会」カテゴリが最も多いことを確認した．

表 2. カテゴリ内訳

カテゴリ	記事数
兵庫県内	41
地域	11
全国海外	2
連載・特集	3
計	57

表 3. 詳細カテゴリ内訳

詳細カテゴリ	記事数
社会	26
社説	7
スポーツ	3
文化	2
総合	2
経済	1
計	41

(2) 人手カテゴリの傾向分析

「社会」カテゴリでは粒度が荒く，NIE ワークシートに採用される記事の傾向がつかめない．そこで，「社会」カテゴリが付与されている 26 記事に対し，人手で，より詳細なカテゴリを付与し，傾向を分析する．

「社会」カテゴリの 26 記事に対して，人手でカテゴリを付与した結果，表 4 に示すように，「生物」や「文化」カテゴリが多いことが確認できた．さらに，181 記事すべてに対して，人手でカテゴリを付与した結果，表 5 に示すように，NIE ワークシートの記事には，「生物」や「文化」の人手カテゴリが付与された記事が選ばれていることが確認できた．以上より，地元に関する記事の中でも，生物の生態に加え，祭り・伝統行事などの文化に関する記事が地域学習としての NIE 教材によく用いられていると考えられる．

表 4. 人手カテゴリ内訳（「社会」記事）

人手カテゴリ	記事数
生物	7
文化	6
農林水産業	4
自然	3
歴史	3
観光	1
経済	1
社会	1
計	26

表 5. 人手カテゴリと記事概要（上位 10 カテゴリ）

人手カテゴリ	記事数	記事概要
生物	29	地元に生息している生物などの生態に関する記事
文化	27	正月やお盆などの行事や地元の祭り、伝統工芸に関する記事
科学技術	21	宇宙開発やAI，医療などに関する記事
社会	13	今年の漢字など日本社会全体に関係のある記事
農林水産業	12	地元で作られている作物やその出荷状況に関する記事
歴史	12	はにわや化石の出土など、歴史的発見に関する記事
自然	11	景観地や桜などの自然に関する記事
スポーツ	11	スポーツ選手の記録樹立などに関する記事
学生生活	10	学生の取り組みや生活実態調査に関する記事
人物	10	スポーツ選手などへのインタビューをまとめた記事

3.2 読解難易度に基づく分析

NIE ワークシートの対象学年と，記事の読解難易度の傾向を分析し，NIE 教材に適した記事の判定に，読解難易度が活用できるか考察する．

分析は，前述の分析で利用した 181 記事から社説や連載記事を除いた 146 記事と，神戸新聞社の Web ニュースサイト[神戸新聞社 18]から収集した 673 記事のリーダビリティスコアを比較することで行う．

(1) リーダビリティスコア

記事文章の読解難易度を表す指標として，以下のリーダビリティスコア R[李 16]を用いる．スコアの算出には，形態素解析機 MeCab※3 と形態素解析辞書 UniDic※4 を用いる．なお，R の値は，難解な文章ほど低くなる．

$$R = (L \times -0.056 + C \times -0.126 + J \times -0.042 + V \times -0.145 + P \times -0.044) + 11.724 \quad (1)$$

L：平均文長（総形態素数÷文数）
C：漢語率（漢語形態素数÷総形態素数×100）
J：和語率（和語形態素数÷総形態素数×100）
V：動詞率（動詞形態素数÷総形態素数×100）
P：助詞率（助詞形態素数÷総形態素数×100）

(2) リーダビリティスコアの傾向分析

神戸新聞社の NIE ワークシートの対象学年は，8 つのパターンが存在する．このうち，記事数が少ないものを除いた 4 パターンについて，リーダビリティスコアを計測する．

計測結果を表 6 に示す．表 6 から，対象学年が高い，つまり，読解力の高い学年を対象としたワークシートの記事ほど，リーダビリティスコアが低くなっていることがわかる．したがって，児童の読解力に適した記事を判定するために，リーダビリティスコアが寄与する可能性があると考えられる．

※3 http://taku910.github.io/mecab/
※4 https://ja.osdn.net/projects/unidic/

表 6. 対象学年ごとのリーダビリティスコアの傾向

対象学年	記事数	リーダビリティスコア	
		平均	分散
小学低学年～小学校高学年	29	2.96565	0.23674
小学高学年～中学	38	2.62653	0.36023
小学高学年～高校	35	2.23461	0.34533
中学～高校	23	1.86765	0.20528
Webニュース記事	673	2.20321	0.72885

4. 記事判定法の初期検討

NIE 教材に適した記事の判定法の初期検討として，読解難易度に注目し，2 値分類で高い性能を持つ SVM（Support Vector Machine）を用いて，記事の判定実験を行う．

実験には，OCR を用いて記事本文の抽出を行った NIE ワークシートの記事 146 記事と，神戸新聞社の Web ニュースサイトから収集した記事 98 記事に NIE 教材に適している（正例），NIE 教材に適していない（負例）のラベルを人手で付与した計 244 記事（正例 122 記事，負例 122 記事）を用いる．

10 分割交差検証における，precision，recall，f-measure，accuracy の平均値で判定性能を評価する．本研究では，判定の正確さとして，precision と accuracy を重視して評価する．

4.1 判定に用いる素性

本稿では，以下の素性を組み合わせることで，NIE 教材に適した記事の判定に有効な素性の組み合わせを検討する．なお，各素性は，平均 0，分散 1 になるように標準化して利用する．

(1) ベース素性

ベース素性には，記事本文の名詞・動詞・形容詞を利用し，素性値には，TF（Term Frequency）を用いる．

(2) 読解難易度素性

記事文章の読解難易度を表す素性として，式（1）によって算出されるリーダビリティスコアを用いる．

(3) 習得漢字率素性

記事本文中の漢字のうち，小学生が習得していると考えられる漢字の割合を素性に用いる．習得状況は，文部科学省の学年別漢字配当表[文部科学省 18]に漢字が存在しているかで判断する．小学校 1 年から小学校 6 年までの 6 学年ごとに割合を算出し，素性とする．

4.2 実験結果

素性の組み合わせを変えて，10 分割交差検証による，記事判定実験を行った結果を表 7 に示す．表 7 の precision と accuracy より，すべての素性を組み合わせた場合の判定性能が最も高いことがわかる．

読解難易度素性に関しては，ベース素性のみと比較した場合，正例の precision が 0.2 ポイント，負例の precision が 0.8 ポイント，accuracy が 0.4 ポイントと，わずかに向上していることから，NIE 教材に適した記事の判定に影響する素性であることが確認できた．

習得漢字率素性に関しては，ベース素性に追加した場合は，記事判定性能が低下しているが，読解難易度素性と組み合わせた場合は，記事判定性能が向上していることがわかる．これは，読解難易度素性のリーダビリティスコアの算出では，記事文章を構成する形態素の品詞や語種といった情報しか用いておらず，文字そのものの難易度は考慮されていない．しかし，習得漢字率素性によって，文字の難易度を示す指標が加わることで，小学生の語彙力を考慮できるようになったことが影響していると考えられる．

今後は，帯[帯 18]などの読解難易度を算出する他の方法とも比較を行い，さらに読解難易度素性を検討する必要がある．文章の複雑さを表す指標として，記事本文の係り受けを解析し，解析木の深さや葉ノードの数などを素性に利用し，妥当性を検証する予定である．さらに，記事のカテゴリを素性に活用することや，地元に関する記事内容を表す素性として，記事本文中の地名の有無や，その地名の粒度などが記事判定に与える影響なども確認する．

表 7. 記事判定の実験結果

素性	正例			負例			accuracy
	precision	recall	f-measure	precision	recall	f-measure	
(1)	0.815	0.786	0.795	0.791	0.815	0.798	0.800
(1)+(2)	0.817	0.794	0.800	0.799	0.818	0.803	0.804
(1)+(3)	0.809	0.801	0.801	0.796	0.798	0.793	0.800
(1)+(2)+(3)	0.822	0.809	0.810	0.812	0.816	0.808	0.812

5. おわりに

本稿では，NIE 教材に適した記事を推薦する手法を検討するため，NIE ワークシートを分析し，NIE 教材に適した記事を判定する手法の初期検討を行った．

NIE ワークシートの分析から，地元の生物の生態や伝統行事に関する記事が，地域学習の NIE 教材として，よく用いられる記事であることを確認した．また，低学年向けの記事は，リーダビリティスコアが高くなる傾向を確認した．

次に，NIE 教材に適した記事を判定する手法の初期検討として，SVM による記事判定実験を行った．実験の結果，読解難易度素性と習得漢字率素性を用いることで，正例記事の precision が 0.7 ポイント向上することを確認した．

今後は，他の読解難易度を計測する指標や，記事文章の複雑さ，地名情報の有無，地名の粒度などについて，記事判定の素性としての有用性を検証する．そして，NIE 教材に適した記事を推薦する手法を検討する．

参考文献

[NIE 17] 教育に新聞を（http://nie.jp）：日本新聞協会．（アクセス日：2017 年 7 月 26 日）

[報告書 17] NIE 実験報告書（http://nie.jp/report/panflet）：日本新聞協会．（アクセス日：2017 年 7 月 26 日）

[河村 17] 河村宗一郎，安藤一秋，“小学生を対象とした Web ニュース読解支援システムのための重要語抽出手法の検討”，JSAI2017 大会論文集，1J1-5，2017.

[田中 16] Shoya Tanaka, Kazuaki Ando, “Web News Recommendation for Elementary School Children using Degree of SNS Users’ Attention and Popular Search Queries among Children”, ACIS International Journal of Computer & Information Science, Vol.17, No.1, pp.17-23, 2016.

[日本新聞協会 17] 会員者一覧（http://www.pressnet.or.jp/member）：日本新聞協会．（アクセス日：2017 年 7 月 26 日）

[李 16] 李在鎬，“日本語教育のための文書難易度に関する研究”，早稲田日本語教育学，第 21 号，pp.1-16，2016.

[神戸新聞社 18] 神戸新聞 NEXT（https://www.kobe-np.co.jp/）：神戸新聞社．（アクセス日：2018 年 3 月 4 日）

[文部科学省 18] 学年別漢字配当表（http://www.mext.go.jp/b_menu/shingi/chukyo/chukyo3/011/siryo/attach/1400158.htm）：文部科学省．（アクセス日：2018 年 3 月 4 日）

[帯 18] 日本語テキストの難易度を計測する（http://kotoba.nuee.nagoya-u.ac.jp/sc/obi3/）：佐藤・松崎研究室．（アクセス日：2018 年 3 月 4 日）

Oral presentation | General Session | [General Session] 12. HI / Education Aid

[1L2] [General Session] 12. HI / Education Aid

座長:野口 孝文（釧路高専）

Tue. Jun 5, 2018 3:20 PM - 5:00 PM Room L (3F Sapphire Hall Asuka)

[1L2-01] Investigation of a Training Environment for Student Teacher using Atmosphere Generation Model in a Virtual Classroom

○Masato Fukuda[1], Huang Hsuan Hung[3,4,2], Kazuhiro Kuwabara[2] （1. Graduate School of Information Science and Engineering Ritsumeikan University, 2. College of Information Science and Engineering Ritsumeikan University, 3. Center for Advanced Intelligence Project RIKEN, 4. Department of Intelligence Science and Technology, Graduate School of Informatics, Kyoto University）

3:20 PM - 3:40 PM

[1L2-02] Item Responce Theory for dynamic assesment

○Emiko Tsutsumi[1], Masaki Uto[2], Maomi Ueno[2] （1. Faculty of Informatics and Engineering, The University of Electro-Communications, 2. Graduate school of Informatics and Engineering, The University of Electro-Communications）

3:40 PM - 4:00 PM

[1L2-03] Automatic Classification of Description Problem Answers in Business Education

○Kenta Sasaki[1], Kenichi Suzuki[1], Kentaro Inui[2] （1. The Graduate School of Management, GLOBIS University, 2. Tohoku University）

4:00 PM - 4:20 PM

[1L2-04] Competency-oriented Learning by Teaching is as effective as Mastery Learning provided by Cognitive Tutor

○Noboru Matsuda[1] （1. Texas A&M University）

4:20 PM - 4:40 PM

[1L2-05] A Study on Japanese Listening Training Support System by Using Anime

○Junjie Shan[1], Yoko Nishihara[1], Ryosuke Yamanishi[1] （1. Ritsumeikan University）

4:40 PM - 5:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

仮想学級の雰囲気表現を用いた教員志望者の指導訓練環境の検討

Investigation of a Training Environment for Student Teacher using Atmosphere Generation Model in a Virtual Classroom

福田 匡人 *1　黄 宏軒 *2*3*4　桑原 和宏 *3
Masato Fukuda　Hung-Hsuan Huang　Kazuhiro Kuwabara

*1立命館大学大学院情報理工学研究科
College of Information Science and Engineering，Ritsumeikan University

*2理化学研究所革新知能統合研究センター
Center for Advanced Intelligence Project，RIKEN

*3立命館大学情報理工学部
Graduate School of Information Science and Engineering，Ritsumeikan University

*4京都大学大学院情報学研究科 知能情報学専攻
Department of Intelligence Science and Technology,Graduate School of Informatics, Kyoto University

The training program of high school teachers in Japan lacks the chance to practice teaching skills and the admission of classes. As a new way of training and learning platform, we are running a project to develop a virtual school environment. This paper proposes a design of training system for the student teachers. This system is composed of a virtual classroom which has 30 virtual students. Each virtual student is controlled by an autonomous agent, the agents react to the trainee's teaching performance in two ways. One is a reflective behavior, the other is emotional behavior which decided by the atmosphere generation model.

1. はじめに

新任教員が多様化する学校問題に対応するには，多くの指導経験を積むことが求められる．しかし，多様な学校問題に対応する実践的指導力やコミュニケーション能力を養成するカリキュラムは存在するが，実際の教育現場において指導力を養う機会は少ない．本研究は，実際の授業現場で活用できる指導力の養成を目的とし，生徒としての CG キャラクタとのインタラクションを通して指導訓練が可能な，マルチエージェントシステムの開発を目指す．

我々はこれまでにも，新任教員の即戦力育成に着目し，教育問題体験システムを開発していた [黄 15]．実際の教室のような仮想環境を構築し，利用者 (以降，授業者と呼ぶ) が仮想生徒とのインタラクションを通した指導訓練を可能とした．予備実験ではシステムによる指導訓練環境の有用性は示された．一方で，システムに存在する仮想生徒の言動は全て我々の固定観念により構築されており，根拠に基づくものではない．実際の授業現場に近い環境で指導訓練を行うためには，仮想生徒は根拠に基づく行動モデルのもとで制御されなければならない．

行動モデルの設計には，教育現場における教諭と生徒の言動の関係際を把握する必要がある．そこで我々は，教諭経験者の協力のもと実施した実験結果に基づき，仮想生徒が感情変化に応じて自律的に振る舞い，学級の雰囲気を生成する雰囲気モデルを構築した [福田 17]．これにより，仮想生徒は情動変化に応じて，自律的に振る舞いを決定し，授業者の授業に応じてリアルタイムに反応する．本稿は仮想学級の雰囲気モデルを活用した，指導訓練システムの検討を行う．

連絡先: 黄 宏軒, 〒 606-8501, 京都市左京区吉田本町 京都大学大学院情報学研究科 知能情報学専攻, hhhuang@acm.org

2. 関連研究

会話エージェントの研究により，我々が日常的に使用するモダリティを使用し人間とコンピュータとの間で情動的なインタラクションが可能となった．会話エージェントは実際に，教育支援システムにも活用されている．TeachLivE[Barmaki 15] は仮想学級を用いた，指導訓練システムである．授業者はディスプレイに表示された仮想学級に対して指導を行う．その指導に応じて，操作者は外部から仮想生徒を操作し，授業のフィードバックを行う．このシステムにおいて個々の仮想生徒はプリセットされたアニメーションもしくは，モーションキャプチャデバイスを使用してリアルタイムに振る舞いが与えられる．しかし教育文化の差からクラスの仮想生徒は 6 人しかいなく，多数の仮想生徒を一度に操作することは考えられていない．アメリカと日本では学級規模，授業形式が異なることから，1 クラス当たりの生徒が多い日本の授業環境では教諭は数多くの学生を一人一人注視する余裕はなく，教壇に立ち学級全体を俯瞰的にしか把握できない．実践的な指導力を養う場を提供するには，多数の仮想生徒を同時に扱い，生徒の反応を忠実に再現することが求められる．

パブリックスピーキングの領域では，マルチエージェントを効率的に制御し，人間に印象変化を体感させる研究が行われている．Kang，Brinkman らは，気分，態度，性格をパラメータとする行動モデルを持つ仮想の聴衆を用いた，パブリックスピーキングの訓練システムを構築した [Kang 13]．このシステムには，12 人の仮想の聴衆が教室に存在する．話者の言動に応じてパラメータを調整することによって，仮想の聴衆は異なる態度を示す振る舞いを生成することができる．このように，CG エージェント集団により構成される仮想の聴衆の振る舞いの変化が雰囲気を表出し，訓練者にフィードバックを与えることは示されている [Chollet 15]．一方で，それら振る舞いの変化が生成する雰囲気は一般化されていない．ここで我々は，

多数の仮想生徒を同時に扱う手法として雰囲気に着目し，授業に応じて，仮想生徒が自律的に雰囲気を表出可能な雰囲気モデルを構築した [福田 17]．この雰囲気モデルは仮想生徒の内心の感情状態をパラメータとすることで，仮想生徒の振る舞い及び仮想学級の雰囲気表現を可能とする．本稿では，この雰囲気モデルを活用した仮想学級による指導訓練システムの設計を検討する．

3. 仮想学級による指導訓練システム

仮想学級による指導訓練システムの目的は，仮想生徒とのインタラクションを通して，指導に関する何らかの気づきを授業者に与えることである．

授業者は，スクリーンに投影された仮想学級に対して指導を行う．指導の様子を Kinect を用いてリアルタイミングにセンシングし，授業者の行動認識を行う．認識結果に基づき，仮想生徒の振る舞いを変化させることで，その言動に対するフィードバックを行う．実際にシステムを用いて授業を行う授業者と，その授業に反応し振る舞いを示す仮想学級の様子を図 1 に示す．



図 1: システムの使用例

システムのアーキテクチャを図 2 に示す．システムは仮想学級，行動認識部，感情決定部，行動決定部の 4 つから構成される．行動認識部は，授業者の行動を言語情報と非言語情報から推定し，その行動の意図性を抽出する．意図性とは，授業者がどの程度，仮想生徒の言動を変化させようとしているかを示す指標である．行動決定部の結果に基づき，その授業者の言動が仮想生徒の感情状態に及ぼす影響度を感情決定部で決定する．結果は行動決定部によって利用され，適切な振る舞いを生成するために利用される．最終的に，仮想学級が振る舞いを通して指導のフィードバックを行う．以下， 順を追って説明する．

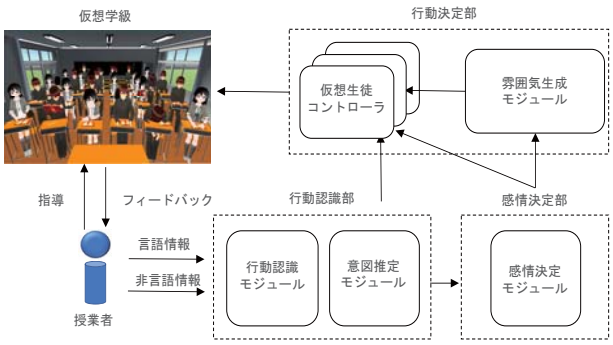


図 2: システムのアーキテクチャ

3.1 仮想学級

ゲーム開発ツールである Unity3D を用いて構築した仮想学級内に，生徒としての CG キャラクタを 30 人配置する．実際の授業と同様，教壇から生徒を見下ろすアングルでスクリーンに表示し，利用者はスクリーンに投影された仮想学級に対して指導を行う．

3.2 授業者の行動認識

実際の授業現場では，授業者が自身の指導を評価するには，生徒の言動を観察し理解度を推定する以外の手段はない．なかでも非言語情報は教諭と生徒のより良いコミュニケーションを成立させる重要な役割である．特に，教諭のジェスチャが生徒の学習と理解に影響を与えることは示されている．よって，教諭がより良い指導を行うためには，効率的に指導を進める非言語的な手がかりを認知することに加えて，生徒の非言語行動を認識しなければならない．また生徒のリアクションを起こそうと働きかける指導は，生徒の感情状態に影響する [Bambaeeroo 17]．以上を踏まえ，行動認識部では (1) 教諭は具体的に何の動作をしているのか，(2) その意図性の程度はどれくらいかを判断する．本システムでは，授業中の教諭の非言語行動を Microsoft 社の Kinect を用いてセンシングし，Visual Gesture Builder (VGB) を用いてジェスチャの認識を行う．VGB は機械学習によってジェスチャの特徴を学習し認識する Kinect ツールの 1 つである．ジェスチャの認識結果に加え，音律情報，注視対象から，その行動の意図性を決定する．意図性の程度に応じて，仮想学級がどのように振る舞いを変化させるべきか決定される．

3.3 仮想生徒の制御

認知科学，心理学の研究では，感情が人間の意志決定に重要な役割を果たしていると考えられている．例えば，心の意識概念モデルである MaC(Mind and Consciousness) モデル [牛田 00] では，感覚入力部で受け取った外部入力に対し，行動決定が反射生成部を介してなされる反射，もしくは感情生成部を介して行動決定が行われる熟考のプロセスを経て，行動が実行される．つまり，授業者の言動に対して，個々のエージェントが人間らしい反応を示すには，(1) 感情状態の変化により生じる振る舞い，(2) 反射的に行う振る舞いの 2 つを表現することが求められる．感情状態の変化により生じる振る舞いの実現には，感情でパラメータ化した雰囲気モデルを活用する．これにより授業者の授業の様子に応じて，仮想学級は自律的に雰囲気を表現する．一方で，学級全体の注意を集める瞬間的な言動や大きな音への反応など，人間が本質的に反射行動を示す振る舞いも再現する必要がある．反射行動は感情決定部を介さずに，行動が決定される．仮想生徒が反射的に振舞うべきか，情動的に反応すべきかは，授業者の言動をもとに決定される．

4. 終わりに

本稿では仮想学級の雰囲気表現を活用した指導訓練システムの検討を行った．現在のシステムでは，仮想生徒が表現できる振る舞いは，授業現場で発起する一般的な振る舞いに限定されている．印象を容易に与える振る舞いに限らずで，授業者の位置に追随し，仮想生徒の頭部を注視対象に向けるなど，ジェスチャーや姿勢以外のモダリティの検討が求められる．今後は各モジュールの精度を向上させ，実際にシステムを用いた評価実験を行う．

参考文献

[黄 15] 黄宏軒, 伊田侑起, 山口耕平, 川越恭二: 仮想学級を用いた教員志望者の練習環境の検討，第 29 回人工知能学会全国大会 (2015).

[福田 17] 福田 匡人, 黄 宏軒, 大田 直樹, 桑原 和宏: 実験結果に基づく仮想学級雰囲気生成モデルの提案, HAI シンポジウム 2017 (2017).

[Barmaki 15] R. Barmaki , C. E. Hughes:Providing real-time feedback for student teachers in a virtual rehearsal environment. International Conference on Multimodal Interaction, pages 531(2015).

[Chollet 15] M. Chollet, T. Wortwein, L.P. Morency, A.Shapiro, S. Scherer: Exploring feedback strategies to improve public speaking: an interactive virtual audience framework. In Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing, pages 1143-1154 (2015).

[Kang 13] N. Kang, W.-P. Brinkman, M. B. van Riemsdijk, M. A. Neerincx: An expressive virtual audience with flexible behavioral styles. IEEE Transactions on Affective Computing, 4(4):326 - 340 (2013).

[牛田 00] 牛田博英, 平山祐司, 中嶋宏 : デジタルペット -心を持った機械達 -, 情報処理学会誌, Vol.41, No.2, pp.127-136 (2000).

[Bambaeeroo 17] F Bambaeeroo, N SHOKRPOUR. :The impact of the teachers’ non-verbal communication on success in teaching. Journal of advances in medical education and professionalism, 5(2), 51 (2017).

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

ダイナミックアセスメントのための隠れマルコフIRTモデル

Hidden Markov IRT model for dynamic assesment

堤瑛美子 *1　宇都雅輝 *2　植野真臣 *2
Emiko Tsutsumi　Masaki Uto　Maomi Ueno

*1電気通信大学情報理工学部
Faculty of Informatics and Engineering, The University of Electro-Communications

*2電気通信大学大学院情報理工学研究科
Graduate school of Informatics and Engineering, The University of Electro-Communications

To scaffold a learner efficiently, a teacher should predict the optimal degree of assistance to support the learner's development. Previous researches have proposed a dynamic assessment method to predict a learner's performances with a certain assistance by using Item response Theory (IRT). However, conventional IRT model does not take the learner's ability changes during learning into the model, therefore the IRT model might pause over-assistance or lack of help. To solve this problem, we propose a new IRT model that incorporate the learner's ability changes according to a Hidden Markov process. This proposed model has two new parameters: the degree of the ability changes and the number of tasks that the learner's ability value continues. This results show that the proposed model improves the prediction accuracy of the ability.

1. はじめに

近年, 教育の現場では, 教師は学習者に教えすぎても, 教えなさすぎても学習者の十分な発達は望めないという問題が注目されており, 学習者それぞれに適応した支援が必要であると考えられている．ヴィゴツキーの「最近説発達領域」(ZPD;Zone of Proximal Development)Vygotsky [Vygotsky 62][Vygotsky 78] や Bruner,J の「足場がけ」[Bruner 96] の考え方に従えば，教師の重要な役割は，学習者の能力に応じて適度な支援を行い，学習者の発達を促すことである．そのためには，教師は学習者の能力を評価し，適切な支援を推定しなければならない．しかし，従来，学習者の能力評価や支援の度合いは教師の経験や勘によるものであり，学習者ごとに正確な支援を行うことは非常に困難であった．Brown や Ferrara(1985)[Brown 85],Collins ら (1989)[Collins 89] は，学習者の能力を客観的に評価するために，学習者の支援に段階的なヒントを用いることで，課題を達成するまでに利用したヒント数から学習者を評価するダイナミックアセスメントの手法を開発した．しかし，彼らのダイナミックアセスメントは，課題ごとの異なる特性が考慮されていないため，能力評価としての信頼性が低いという問題があった．

そこで, Ueno and Miyazawa (2017)[Ueno 17] は，課題ごとの特性を能力評価に反映させ, 学習者の能力とヒントごとの学習者のパフォーマンスを予測するための項目反応理論 (IRT:Item Response Theory) を提案した．この研究によって，学習者に適応的に支援を与えるシステムが実現し，学習者の課題への予測成功確率が 0.5 になるように支援することが最適であることが示された. 結果より，ヒント提示後の学習者の課題正答確率を精度高く予測することが重要であることがわかる．

しかし，従来の IRT モデルは，能力の変化の度合いが考慮されていないために，正確な能力測定値が推定されていない可能性が高い．信頼性の高い能力推定を行うためには，学習過程で学習者の真の能力値が変化することを考慮し，推定に用いるデータをある時点以前で忘却させる必要がある．しかし，データを忘却させることで，能力推定に用いられるデータ数が少なくなり，過学習が起こって，過大評価または過小評価されやすいというトレードオフの問題が生じてしまう．このトレードオフを解消するためには，学習者の能力変化の度合いと，ある時点での能力値が継続する時間 (課題数) を考慮したモデルが必要である．

本研究では，学習者のヒント提示後のパフォーマンスの予測精度を向上させるために，学習者の能力が学習過程において変化するプロセスを項目反応理論に組み込んだ新しいモデルを提案する．このモデルは，ある時点での能力値が影響する時間 (課題数) を表すウィンドウサイズと学習者の能力の変動の程度を反映する変動パラメータを持ち，これらの最適値がデータから推定されるために，トレードオフの問題を解決し，学習者の真の能力変化を反映できると期待される．

連絡先: 堤瑛美子，電気通信大学情報理工学部，〒 182-8585
東京都調布市調布ヶ丘 1-5-1, tsutsumi@ai.lab.uec.ac.jp

2. ダイナミックアセスメントのための項目反応理論

適切な足場がけを行うためには，学習者の能力を正確に把握し，各ヒントを提供した後の学習者のパフォーマンスを予測しなければならない．これまで，学習者の能力とヒントごとの学習者のパフォーマンスを予測するための項目反応モデルとして段階反応モデルが提案されてきた [Ueno 17]．以降は，この段階反応モデルを IRT(Item Response Theory) と略記する．

本章ではダイナミックアセスメントのための段階反応モデルについて説明する．段階反応モデルでは学習者 j が課題 i に対してヒント k で正答する確率 P_{ijk} を次式で与える．

$$P_{ijk} = P^*_{ijk-1} - P^*_{ijk} \tag{1}$$

$$P^*_{ijk} = \frac{1}{1 + exp(-a_i(\theta_j - b_{ik}))} \tag{2}$$

ただし，$P^*_{ij0} = 1$，$P^*_{ijK} = 0$ である．ここで，a_i は課題 i の識別力を表すパラメータ，b_{ik} は課題 i でヒント k が提示され

た時の難易度を表す困難度パラメータ，θ_j は学習者 j の能力値パラメータを表す．ただし，$b_{j1} < \cdots < b_{jk} < \cdots < b_{jK-1}$ である. 項目パラメータ a_i,b_{ik} はヒントを 1 つずつ提示した場合の学習データから、あらかじめ推定した値を利用する。問題終了時に項目反応理論に基づいて学習者の能力値を推定する。

3. 隠れマルコフ IRT モデル

本研究では，ダイナミックアセスメントのための新しい IRT モデルを提案する．段階反応モデルにおいて，従来では固定されていた学習者 j の能力値 θ_j を時系列で変化させ，ある時点 t の能力値 θ_{jt} が，一つ前の時点 $t-1$ での能力値 θ_{jt-1} に依存する隠れマルコフモデルを IRT に組み込んだ隠れマルコフ IRT モデルを提案する．通常，隠れマルコフモデルの隠れ変数は離散値で扱われるが，提案モデルでは能力値を隠れ変数とするため，連続値で扱う．

従来の IRT モデルと隠れマルコフ IRT モデルのグラフィカルモデルを図 1, 図 2 に示す．従来の IRT モデルは学習過程が一つの能力値 θ_j に依存する．一方，隠れマルコフ IRT モデルは, 学習過程 (課題) が進むごとに，学習者の能力値 θ_{jt} が直前の θ_{jt-1} に依存して確率的に変化していくモデルである．このとき，能力値 θ_{jt} の変動パラメータ δ を設定することで，θ_j の変動を制限する．

能力値 $\theta_{jt}(t = 1, \cdots, I-L)$ の変動モデルには，音声認識や画像認識の分野でパラメータ推定の手法に用いられるスライディングウィンドウ方式 [Ortiz 11] を用いる．この方法によって，学習者が取り組んだ直近の L 個の課題以前の学習データを忘却した能力推定が可能となる．

提案モデルでは時点 t において学習者 j が課題 i にヒント k で正答する確率 P_{ijtk} を次式で表す．

$$P_{ijtk} = P^*_{ijtk} - P^*_{ijtk-1} \tag{3}$$

$$P^*_{ijtk} = \frac{1}{(1 + \exp(-a_i(\theta_{jt} - b_{ik}))} \tag{4}$$

a_i は課題 i の識別力パラメータ，b_{ik} は課題 i のヒント k での難易度パラメータ，θ_{jt} は時点 t での学習者 j の能力パラメータを表す．ただし，

$$\theta_{jt} \sim N(\theta_{jt-1}, \delta)\ , \quad \theta_{j0} \sim N(0, 1) \tag{5}$$

ここで，$N(\mu, \sigma)$ は平均 μ，標準偏差 σ の正規分布を表す．δ は時間経過による能力の変動の大きさを表すパラメータである．また，提案モデルは，ウィンドウサイズ L を全課題数に一致させた場合には，能力値が過去のデータを忘却せず時系列変化しないモデルとなるため，従来の IRT モデルと同じモデルを表現することができる．

能力推定に利用する学習データ数と能力変化の推定精度のトレードオフの問題が解消するためには，学習に合わせて最適なウィンドウサイズ L と変動パラメータ δ の組み合わせを求める必要がある．ウィンドウサイズ L と変動パラメータ δ の関係は以下の通りである．

1. L と δ が共に小さい
   θ_{jt} が影響する課題数が少なく，能力の変動もほぼ起こらないため，それまでの学習過程に関係なく，θ_{jt} がほとんど変化しないモデル．
2. L が小さく δ が大きい
   直前の学習過程にのみ影響され，能力値の変動幅が大きいため，θ_{jt} の急激な変動が起こるモデル．

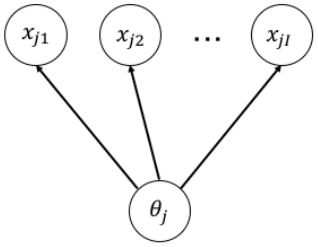


図 1: 従来の IRT モデル

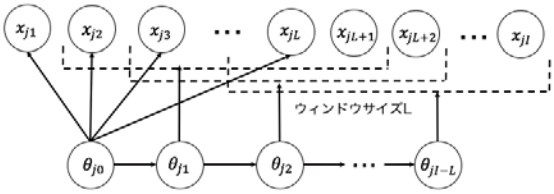


図 2: 隠れマルコフ IRT モデル

3. L と δ が共に大きい
   それまでの学習過程に強く影響を受け，θ_{jt} が大きく変動するモデル．
4. L が大きく δ が小さい
   それまでの学習過程の影響を受けるが，θ_{jt} の急激な変動を抑制するモデル．

次章で，本モデルのパラメータ推定法について述べる．

4. 項目パラメータ推定

本研究では，項目パラメータの推定にマルコフ連鎖モンテカルロ (MCMC) 法を用いた期待事後確率推定（Expected A Posteriori: EAP）を用いた．MCMC 法は事後分布からのランダムサンプルを用いてパラメータを推定する手法であり，本研究のようにモデルが複雑な場合やデータ数が少ない場合にも高精度なパラメータ推定を実現できる [Uto 16].

ここで，各パラメータの集合をそれぞれ $\boldsymbol{\theta} = \{\theta_{10}, \cdots, \theta_{JI-L}\}, \boldsymbol{a} = \{a_1, \cdots, a_I\}, \boldsymbol{b} = \{b_{11}, \cdots, b_{IK-1}\}$, 各パラメータの事前分布をそれぞれ $g(\theta_{jt}), g(a_i), g(b_{ik})$ と表し，以下のように設定する．

$$\log a_i \sim N(0.1, 0.4)$$

$$\theta_{j0} \sim N(0.0, 1.0), \quad \theta_{jt} \sim N(\theta_{jt-1}, \delta)$$

$$\boldsymbol{b}_i \sim MN(\mu, \Sigma)\ , \quad \mu = \{-2.0, -1.0, 0.0, 1.0, 2.0\}$$

$$\Sigma = diag[0.16, 0.16, \cdots, 0.16]$$

このとき，反応データ $\boldsymbol{X}$ を所与としたパラメータの事後分布は以下のように表せる．

$$\begin{aligned} &p(\boldsymbol{\theta}, \boldsymbol{a}, \boldsymbol{b} \mid \boldsymbol{X}) \\ &\propto L(\boldsymbol{X} \mid \boldsymbol{\theta}, \boldsymbol{a}, \boldsymbol{b}) g(\boldsymbol{a}) g(\boldsymbol{b}) g(\boldsymbol{\theta}) \\ &= \left[\prod_{t=0}^{I-L} \prod_{i=t+1}^{L+t+1} \prod_{k=1}^{K} (P_{ijtk})^{z_{ijk}}\right] \\ &\quad \left[\prod_{i=1}^{I} g(a_i) \prod_{k=1}^{K} g(b_{ik})\right] \left[\prod_{t=0}^{I-L} \prod_{j=1}^{J} g(\theta_{jt})\right] \end{aligned} \tag{6}$$

ここで,

$$z_{ijk} = \begin{cases} 1: & x_{ji} = k \\ 0: & \text{上記以外} \end{cases}$$

MCMC の手法のうち，ブロック化ギブス・サンプリング法とメトロポリスヘイスティングス法を組み合わせた手法 [Uto 16] でパラメータ推定を行った．

5. 評価実験

5.1 実験データ

プログラミング学習におけるトレース問題 7 項目についてプログラミング初学者の大学生 148 人の学習データを収集した．課題ごとのヒント数は全て 4 である．

5.2 ウィンドウサイズと変動パラメータの推定

提案モデルは，モデルごとに項目パラメータ a_i,b_{ik} と学習者の能力の変動を反映する変動パラメータ δ の値が変化するため，実施するテストや学習ごとに最適なマルコフ多重度を求める必要がある．ここでは，ウィンドウサイズ $L = \{1, 2, 3, 4, 5, 6\}$ と時間経過による学習者の能力値の変動幅 $\delta = \{0.1, 0.2, 0.3, 0.5, 1.0\}$ の組み合わせを変えて周辺尤度 (Marginal Lilkelihood: ML) を求め，本実験で用いるデータに最適な L と δ の組み合わせを求める．また，従来の IRT モデル (L=7) での周辺尤度との比較も行った．

図 3 に L と δ の組み合わせを変えた各モデルでの周辺尤度を示す．図 3 は，横軸が提案モデル ($L = 1, \cdots, L = 6$) と従来の IRT モデル (L=7)，縦軸が各条件での周辺尤度 (ML) の値を表し，周辺尤度の大きいモデルが反応データに対して最も適切なモデルであることを示す．

図 3 より，本実験で用いているデータには，$L = 5, \delta = 0.1$ としたモデルが最も周辺尤度が大きく，従来の IRT モデルに比較して学習データへの当てはまりが良いモデルであることが示されている．提案モデル ($L = 5, \delta = 0.1$) は，能力値が直前の 5 つの学習データに影響し，課題ごとの能力の変動が小さいモデルである．この組み合わせの提案モデルを用いることで，能力推定に利用する学習データ数と能力変化の推定精度のトレードオフの問題が解消し，より正確な学習者の能力変化をとらえた能力値推定が行われると期待できる．従来の IRT モデル ($L = 7$) は能力値の変動がないモデルであるため，δ の値に関係なく周辺尤度が比較的低い値となり，データの当てはまりが悪いことがわかった．

5.3 能力値 θ の推定

5.2 では，提案モデルが従来の IRT モデルに比較して学習データへの当てはまりが良いことを示した．ここでは，提案モデルと従来の IRT モデルで推定される能力推定値の差異について考察する．従来の IRT モデルと提案モデルを用いて，各課題 n においてそれ以前の学習履歴データから，それぞれ期待事後 (Expected a posteriori:EAP) 推定法を用いて $\hat{\theta}_j$ を推定する．

図 6 に，従来の IRT モデル，$\delta = 0.1$ に固定したときの提案モデル ($L = 5, L = 3, L = 1$) を用いた課題 $i = 2, \cdots, 7$ での能力推定値の平均を示す．図 6 から，従来の IRT モデルは，課題ごとに θ_{jt} が大きく上昇しており，初期の課題では推定値の変動が大きい．一方，提案モデルでは L の値が小さいほど θ_{jt} の変動が小さく，推定能力値が少しずつ変化することが分かる．5.2 より，実験データに対して $L = 5, \delta = 0.1$ の提案モデルが最も適切なモデルであるということは，学習者の真の能力値 θ は実際には，従来の IRT モデルで推定された能力値ほど増加していないと考えられる．このことから，従来の IRT モデルは能力値の時系列変化が考慮されていないために，能力推定値が真の能力値より過大評価されることが分かる．

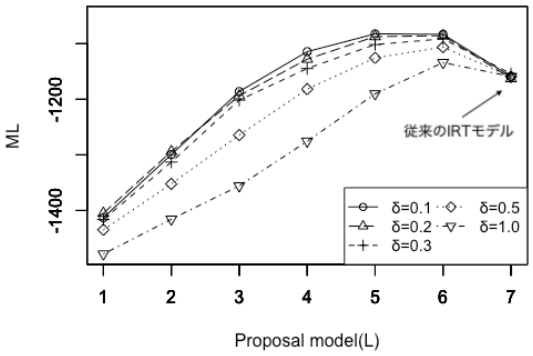


図 3: モデル (L) と δ ごとの周辺尤度比較

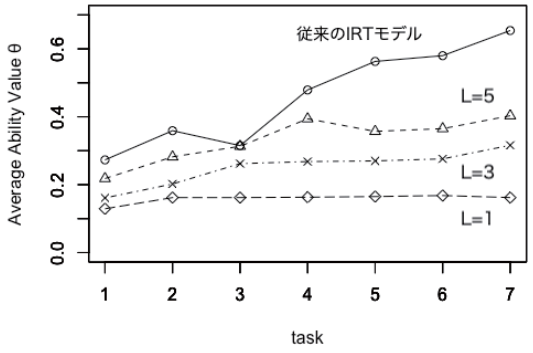


図 4: 学習者の能力値の推移

5.4 予測利用ヒント数の精度

学習者のために適切な足場がけを行うためには，学習者にヒントを与えた後のパフォーマンスを予測することが必要となる．ここでは，提案モデル ($L = 5, \delta = 0.1$) と従来の IRT モデルでの学習者のパフォーマンスの予測精度を以下のように評価する．推定した能力値 θ_{jt} を用いて，次の課題で各ヒント k を与えた場合の正答確率を段階反応モデルで予測し，利用ヒント数の予測確率の情報を組み込んだ期待値を求めた．課題 i での学習者の予測利用ヒント数の期待値 $\hat{x_i}$ は (5) 式を用いて以下の式で求める．

$$\hat{x_i} = \frac{1}{J}\sum_{j=1}^{J} \hat{x_{ji}} = \frac{1}{J}\sum_{j=1}^{J}\sum_{k=0}^{K-1} kP_{ijtk} \tag{7}$$

さらに，課題，学習者ごとに予測利用ヒント数の期待値 $\hat{x_{ji}}$ と実際に利用されたヒント数 x_{ji} との誤差 ϵ_i を以下の式で求めた．

$$\epsilon_i = \frac{1}{J}\sum_{j=1}^{J} \sqrt{(x_{ji} - \hat{x_{ji}})^2} \tag{8}$$

横軸を課題数，縦軸を予測利用ヒント数の誤差 ϵ_i として，提案モデル ($L = 5, \delta = 0.1$) と従来の IRT モデルで求めた結果をグラフ図 5 に示す．利用ヒント数の予測は課題 2 から行った．図 5 より，提案モデル ($L = 5, \delta = 0.1$) は従来の IRT モデルに対して，全ての課題で各ヒントでの予測正答確率の誤差

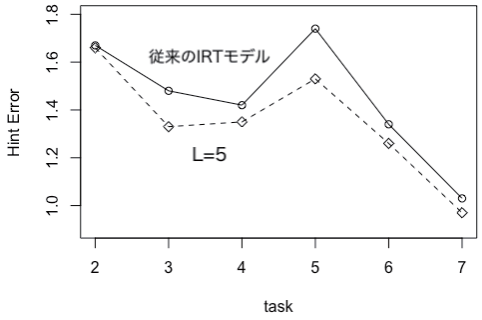


図 5: ヒントの予測利用数期待値の誤差 ϵ_i

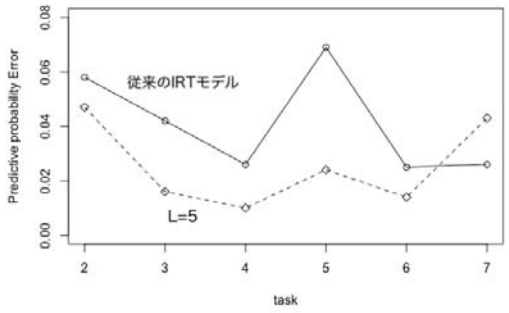


図 6: 各課題のヒントでの予測反応確率の平均誤差 ϵ_i

が減少している．有意水準 5%で片側検定の t 検定を行ったところ，$t(5) = 3.31, p < .02$ であり，従来の IRT モデルと提案モデルの誤差の差は有意であった．このことから，提案モデルを用いることでより正確なパフォーマンス予測が行われることが分かる．

5.5 課題ごとの各ヒントでの正答確率の予測精度

植野ら [Ueno 17] によれば，学習者に予測正当確率が 0.5 となるようなヒントを与えることで最も学習効果が期待できる．そのためには，各ヒントを提示した後の予測正答確率の精度が高いことが望ましい．この節では，従来の IRT モデルと提案モデル ($L = 5, \delta = 0.1$) を用いて，どちらのモデルが予測正答確率の予測精度が高いかを比較する．課題ごとに学習者の各ヒントでの予測反応確率の平均を求め，実際の学習者の各ヒントでの正答者割合との誤差 ϵ_i を比較した．

$$\epsilon_i = \frac{1}{K}\sum_{k=1}^{K-1}\sqrt{\left(\frac{1}{J}\sum_{j=1}^{J} z_{jik} - \frac{1}{J}\sum_{j=1}^{J} P_{ijtk}\right)^2} \qquad (9)$$

z_{jik} は学習者 j が課題 i のヒント k で正答したとき $z_{jik} = 1$ となり，誤答した場合は $z_{jik} = 0$ となる．根号内の第一項は，課題 i でヒント k を提示されたときに正答した学習者の割合を表す．第二項は，課題 i での各学習者のヒント k での予測正答確率の平均値を表す．

図 6 は横軸が課題数，縦軸が予測反応確率の誤差 ϵ_i を表す．図 6 より，各ヒントの予測正答確率の誤差は，課題 7 を除いて従来の IRT モデルより提案モデルの方が小さく，予測精度が向上することが示されている．有意水準 5%での片側検定の t 検定では，$t(5) = 5.65, p < .01$ となり，予測精度の差は有意であった．提案モデルによって各ヒントでの予測正答確率の精度を向上させることで，より学習者に最適なヒントを与えることが可能となる．

課題 7 では従来の IRT モデルが予測精度が上回る結果となっているが，表 1 の通り，課題 7 はほとんどの学習者がヒントを利用せず正答しているため，項目パラメータが正しく推定されず，ヒントの予測反応確率の誤差が大きくなったと考えられる．

表 1: 各課題におけるヒントなしで正解した学習者の割合

課題 i	1	2	3	4	5	6	7
正答割合	70%	48%	42%	40%	66%	69%	89%

6. むすび

本論文では，学習者の能力が学習過程において変化していくプロセスを項目反応理論に組み込んだ新しい隠れマルコフ IRT モデルを提案した．もっともデータによく当てはまった提案モデル ($L = 5, \delta = 0.1$) を用いることで，従来の IRT モデルでの能力推定値の過剰評価を避けることが可能となり，予測利用ヒント数の誤差が減少し，学習者のパフォーマンスの予測精度が向上することを示した．

参考文献

[Brown 85] A. Brown and R. Ferrara.:Diagnosing zones of proximal development, in Culture, communication, and cognition: Vygotskian perspectives, J. Wertsch,ed., pp.273 - 305, *Cambridge, England, Cambridge University Press*(1985)

[Bruner 96] J.Bruner.: The Culture of Education,*Harvard University Press*(1996)

[Collins 89] A.Collins.:JS & Newman,SE(1989).Cognitive apprenticeship: teaching the craft of reading, writing and mathematics,*Resnick,LB Knowing, learning and instruction*, pp.453-494(1989)

[Ortiz 11] J.Ortiz, A.G.Olaya and D. Borrajo.:A Dynamic Sliding Window Approach for Activity Recognition, *UMAP'11 Proceedings of the 19th international conference on User modeling, adaption, and personalization*, pp.219-230(2011)

[Ueno 17] M. Ueno and Y. Miyazawa.:IRT-based adaptive hints to scaffold learning in programming,*IEEE Transactions on Learning Technologies*, Vol.14, No.8(2017)

[Uto 16] M.Uto and M.Ueno.:Item Response Theory for Peer Assessment,*IEEE Transactions on Learning Technologies*,Vol.9,No.2,pp.157-170(2016)

[Vygotsky 62] L.S.Vygotsky,:Thought and language, *Harvard University Press*(1962)

[Vygotsky 78] L.S. Vygotsky,:Mind in society,*Harvard University Press*(1978)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

社会人向け教育における記述式問題回答自動分類

Automatic Classification of Description Problem Answers in Business Education

佐々木 健太[*1] Kenta Sasaki
鈴木 健一[*1] Kenichi Suzuki
乾 健太郎[*2] Kentaro Inui

[*1] グロービス経営大学院 Graduate School of Management, Globis University
[*2] 東北大学 Tohoku University

Recently, automatic text scoring research using machine learning is progressing in an education field. Most of the short description problems have specific model answers. However, about business education, most of them don't have specific model answers. Therefore, we investigated the possibility of classifying short description problem answers in a business education field, to develop an adaptive learning system. As a result, we confirmed that we could classify them with high accuracy if the number of answer characters is about 50 and answers can be clearly classified into less than three patterns. Then we could detect the words that contribute to the classification. Moreover, we found that the way of creating problems is one of the important factors to classify answers.

1. はじめに

近年，教育分野において，記述式問題回答の自動採点に関する研究が進んでいる [Sultan 16, Taghipour 16, 水本 18]. 実際，2020 年度から始まる新共通テスト（既存の大学入試センター試験の代替試験）において，採点支援システム，または，自動採点システムの導入が検討されている [石岡 16, 亀田 17]. 具体的には，それぞれの問題に対して複数の採点基準を用意しておき，回答がそれらの採点基準をどの程度満たしているのかによって採点するというものである．一方，このような手法を社会人向け教育にそのまま適用することは難しい．なぜなら，社会人向け教育では正解が一意に決まらない問題が多く，採点基準を明文化することが難しいからである．例えば，「リーダーに必要なスキルを述べよ．」という問題に対して，「人を動かす力」「ビジョンを描く力」などが模範回答として考えられるが，例えば「鈍感力」「体力」などの回答も間違いとは言い切れない．そこで，本研究では，社会人向け教育における記述式問題回答の自動分類の可能性を調査した．自動分類することができれば，回答のパターンによってフィードバックを換えるなど，学習者の回答に応じた適切な振り返りサービスを提供することができる．そして，例えば，学習者が回答した以外の回答パターンを知ることができれば，学習者の思考の幅を広げることができる可能性がある．また，分類タスクに落とし込むことで，数多くの既存研究がある文書分類の技術や知見を活かすことができると考えられる．

2. 先行研究

先行研究として，先に紹介した新共通テストの採点支援（自動採点）に関する研究と，Twitter (https://twitter.com/) に投稿されたツイートの分類を題材に分散表現を獲得する際に使用するデータセットに関する研究を紹介する．前者の研究として，[石岡 16, 亀田 17] らは採点基準を複数用意し，採点基準毎に回答がその基準を満たしているのかをチェックする手法を提案した．同義語，言い換え可能な表現等を同等に扱うことで，回答の表現の揺れを吸収している．そして，採点基準毎の点数を足し合わせたものを当該回答のチェックスコアとする．さらに，回答と模範回答や問題文とのコサイン類似度などを素性とした機械学習（ランダムフォレスト）による手法も提案し，チェックスコアを上回る精度が出ることを確認している．後者として，[Li 17] らはツイートの分類を題材にし，どのようなデータセットから分散表現を獲得すれば分類精度が高くなるのかについて述べている．まず，データセットとしてツイートデータ（スパム付きとスパム除去済みの 2 パターン）と一般データ（ニュース記事，Wikipedia 記事）の2種類を用意する．そして，それぞれを単独で使用する場合と組み合わせて使用する場合，さらには 2 単語以上から成るフレーズを考慮する場合と考慮しない場合で，ツイートの分類精度を比較した．なお，ツイートを構成する単語，もしくはフレーズの分散表現の最大値，最小値，平均値のいずれかを当該ツイートの分散表現としている．また，分類には LibLinear やランダムフォレストなどを使っている．結果，フレーズを考慮した上でツイートデータ（スパム除去済み）と一般データを組み合わせ，単語，もしくはフレーズの分散表現の平均値を当該ツイートの分散表現とした場合に最も分類精度が高くなったことを示した．

3. 問題と回答

本研究では，問題 A，問題 B，問題 B'の 3 つの問題とそれぞれの回答を取り上げる．これらは人の思考パターンを掴むために開発された問題で，問題 A は回答が数パターンに集約される問題，問題 B は回答が数パターンに集約されずに発散する問題である．既存の文書分類の技術や知見を使えば，問題 A の回答はある程度の精度で分類でき，問題 B の回答は分類が難しいものの問題を細分化するなどの工夫をすれば分類が可能になると考えた．実際，問題 B を細分化したものが問題 B'である．問題を細分化することで回答が発散することを防ぐことができ，問題 A と同様に回答をある程度の精度で分類できると考えた．なお，他の問題と比較して回答数が多いという理由から，本研究ではこれらの問題とそれぞれの回答を取り上げる．

問題 A

夏休みも終盤，家族で外食に出かけることにしました.具体的にどんなお店を選ぶべきかについて，枠組みを置いて考えてみることにしました.以下の 2 つの枠組み，どのような状況であれば A が，どのような状況であれば B の枠組みの方が適切となるでしょうか.50 字程度で答えてください.

A いい雰囲気か，料理は満足できるか，手ごろな値段か
B 量はあるか，美味しいか，盛りつけはきれいか.

連絡先：kenta.sasaki@globis.ac.jp, suzuki-k@globis.ac.jp

問題 A の回答

グロービス経営大学院に通っている学生 111 名(20 代〜50 代の社会人)に回答して貰い, 回答データを集めた. そして, 各回答を 3 パターン(意味合いの回答, 具体的な回答, その他の回答)に分類した. 実施の回答を幾つか掲載する.

1. 意味合いの回答(42 件)
- A はレストランに興味がある場合. B は料理そのものに興味がある場合.

2. 具体的な回答(39 件)
- A は大人だけで外食に出かける場合, B は子供も含む家族全体で出かける場合.

3. その他の回答(判断が難しいものも含む)(42 件)
- A は, 価格と雰囲気を重視する場合に有効です.例えば, 大人数で個室を探したい時が考えられます. B は, ボリュームを重視する場合に有効です.例えば, 食べ盛りの子供が多い場合時が考えられます.

問題 B

「運動は, 毎日とは限らず, 実施のハードルもある.睡眠は, 毎日のことではあるが, 忙しい人にとって時間は減らせない.一方で, 食事は, 毎日のことで, 意識すれば, アクションにつなげられる」という根拠の「穴」をいくつか指摘してください.

※この問題の前段の説明で, 健康志向を意識した際に取り組める要素として,

1. 食事
2. 運動
3. 睡眠

の 3 つを挙げている. そして,「食事」は恒常性と実行容易性の観点からアクションに繋げられやすい一方で,「運動」「睡眠」は実施のハードルが高いことを述べている. その上で, その逆を押さえるという問題である.

問題 B の回答

問題 A と同様, グロービス経営大学院に通っている学生 15 名に回答して貰い, 回答データを集めた. そして, 各回答を 4 パターン(全ての要素に言及している回答, 一部の要素にしか言及していない回答, 根拠が弱い回答, イシューずれ回答(論点を外している回答))に分類した. 形式的には 4 パターンに分類できているものの, 根拠が弱い回答やイシューずれ回答はさらに幾つかのパターンに分けることができるので, 回答が発散していると言えるであろう. 実際の回答を幾つか掲載する.

1. 全ての要素に言及している回答(3 件)
- 運動は毎日ムリとされているが駅まで歩くことで運動は可能.睡眠時間は少なくともマクラ改善による質の良い睡眠が可能.食事は意識すればとあるが, 毎日の勤務が遅い時間であれば自炊やバランスの良い食事が取れない可能性もある.

2. 一部の要素にしか言及していない回答(5 件)
- 食事についても仕事による時間的制約や飲み会等があり得る.
- 食事はお金との関係性があるので, その費用内で収まるように健康を意識した食事が可能か検討する必要がある.

3. 根拠が弱い回答(4 件)
- 全ての人が定期的に食事をしているわけではない, そもそも食事をする時間がない, アクションすることの難しさ
- 食事は, 睡眠や運動と異なり一人でとるものとは限らないため, 自分の意思だけでは達成できないことがある.休みの日と出勤日で意識が変わってしまう.

4. イシューずれ回答(3 件)
- 睡眠を減らせないほど忙しいビジネスマンは, 食事への意識も回らない.
- 食べる物を選べない, 場所を選べない, 時間を選べない,
- 運動も意識すれば毎日(通勤時), 徒歩距離を伸ばすことでも実現可能.時間が取れないから睡眠が取れないなら食事も同様

問題 B'

1. 「運動は, 毎日できるとは限らず, 実施するハードルもある」という主張の「弱さ」はなんでしょうか.
2. 「睡眠は, 毎日のことではあるが, 忙しいヒトにとっては増やすことは難しい」という主張の「弱さ」はなんでしょうか.
3. 「食事は, 毎日のことで, アクションのハードルも高くない」という主張の「弱さ」はなんでしょうか.

問題 B'の回答

この問題もグロービス経営大学院に通っている学生 23 名に回答して貰い, 回答データを集めた. 問題 B の回答のように発散することはなく, 各回答を2~3パターンに分類することができた. 例えば, 1 つ目の「運動」問題に対する回答は 2 パターン(反証の回答, その他の回答)に分類できた.

1. 反証の回答(13 件)
- 階段を上る, 一駅歩くなど, 日常生活の中でできる運動もあること

2. その他の回答(10 件)
- 個人の生活環境によりハードルに差が生まれるので, 一般論としての根拠が弱い.

4. 手法

本研究の手法を述べる. まずは回答の分散表現獲得方法, 次に回答の分類方法について説明する. そして, 最後に回答の分類に寄与している単語の特定方法を説明する.

4.1 回答の分散表現獲得

回答の分散表現獲得には, 先行研究で紹介した [Li 17] らの手法を参考にした. まず, コーパスとして, Wikipedia のダンプデータに加え, グロービス経営大学院が出版している書籍のテキストデータを利用した. そして, word2vec で学習したものから, 単語の分散表現を得た. なお, 単語分割には MeCab を利用し, 単語の分散表現は 200 次元, ウインドウサイズは 5 とした. そして, 回答を構成する単語分散表現の平均を当該回答の分散表現とした(図 1). 但し, 助詞や句読点などはノイズになり得ると考え, 名詞, 動詞, 形容詞の単語に限定した.

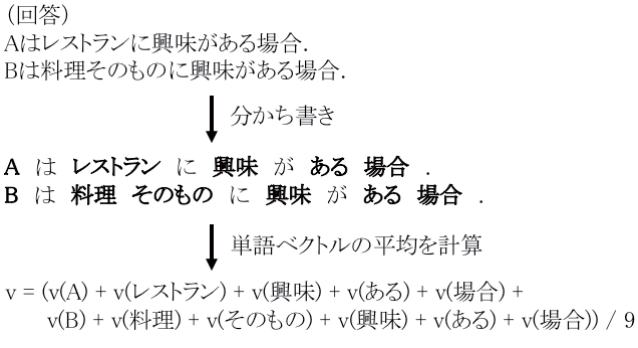


図 1 回答の分散表現化

4.2 回答の分類

回答の分類アルゴリズムには SVM (Support Vector Machine) を用い，無償で利用可能な LIBSVM (https://www.csie.ntu.edu.tw/~cjlin/libsvm/) を利用した．カーネルには RBF カーネルを採用し，ハイパーパラメータはグリッドサーチによって最も精度が高くなるものに決めた．なお，精度は leave-one-out 交差検証で評価した．

4.3 回答の分類に寄与している単語の特定

本研究では，回答の分類に寄与している単語（分類において影響力の大きい単語）の特定も行った．分類に寄与している単語を特定できれば，学習者へのフィードバックを回答のパターンによって換える場合，そのフィードバックが返ってくる理由を学習者に提示することができるかもしれない．その結果，フィードバックへの納得感が高まり，学習者の理解の向上に繋がる可能性がある．具体的には，例えば「A は新婚の場合なら適切であり，B は小さい子供がいる家族なら適切である.」という回答の場合，

1. A は~~新婚~~の場合なら適切であり，B は小さい子供がいる家族なら適切である．
2. A は新婚の~~場合~~なら適切であり，B は小さい子供がいる家族なら適切である．

（以下省略）

の 8 パターンの回答を用意する．今回，「A」「B」も除く単語の対象となるが，これらは全ての回答に出現するので対象外とした．そして，それぞれの回答をモデルに掛け，各回答の予測スコア（分類超平面からの距離）を算出した．予測スコアが悪化している（絶対値が小さくなっている）回答ほど，その回答で除いた単語の影響力が大きいと考えられる．前記の例で，1 番目の回答で予測スコアが最も悪化している場合，「新婚」という単語が分類に最も影響していると言える．

5. 結果と考察

まずは，問題 A による分類結果と分類に寄与している単語について述べる．次に，問題 B'による分類結果と分類に寄与している単語について述べる．

5.1 分類結果（問題 A）

SVM による分類結果を表1に示す．まずは，「1. 意味合いの回答」と「2. 具体的な回答」の 81 件のデータセットだけを使って分類（二値分類）した．結果，分類誤りは 81 件中 3 件だけであり，96.3%(=78/81)という非常に高い精度であった（表1）．また，分類誤りとなった 3 件も予測スコアは非常に小さく，つまり，誤り方として惜しいものであることが分かった（表 2）．ここで，予測スコアが正であれば「1. 意味合いの回答」，負であれば「2. 具体的な回答」と予測したことになる．

表1 問題 A の回答分類結果（概要）

		予測	
		1. 意味合い	2. 具体的
実際	1. 意味合い	39	2
	2. 具体的	1	38

表 2 問題 A の回答分類結果（詳細）※予測スコアで昇順ソート

予測スコア	正解ラベル	回答
1.45	1	A は料理以外の要素も大事な場合，B は料理自体が大切な場合
（略）	（略）	（略）
0.15	**2**	**旅行中などはじめての土地で食事をする場合には A, 平日のランチなどすでに何度も行ったことのあるお店から選ぶ場合には B**
0.07	1	A は雰囲気重視の場合，B は食欲重視の場合
-0.01	**2**	**A.レストランに興味がある場合.B.料理そのものに興味がある場合.**
-0.05	2	A は異性と時間を楽しみたい状況，B は部活の仲間と楽しみたい状況
-0.08	2	小さい子ども連れ，バリアフリー環境が必要など，制約がある場合は A，制約はなく料理のみで判断できる場合には B
-0.08	**1**	**食事だけでなく，外食の体験そのものの満足度を最大化したい場合は A，食事に関する満足度を最大化したい場合は B**
（略）	（略）	（略）
-1.61	2	A は核家族(親と子供)，B は祖父母な親戚も含めた大勢の状況

次に，「1. 意味合いの回答」と「2. 具体的な回答」のデータからモデルを作成し，「3. その他の回答」のデータ 42 件のラベルを予測した．ここで，予測スコアの絶対値が大きい 2 件の回答と，絶対値が小さい 2 件の回答を表 3 に示す．絶対値が大きい回答については，「3. その他の回答」とラベル付けしたものの，「1. 意味合いの回答」と「2. 具体的な回答」にラベル付けしても問題なかった回答だと考えられる．一方，絶対値が小さい回答については，特に予測スコアが-0.04 の回答は「1. 意味合いの回答」と「2. 具体的な回答」の双方に言及している．この場合はどちらとも言えないというのが正解であり，予測スコアの絶対値が小さくなっていることから，予測結果は妥当であったと言える．

表 3 予測スコアの絶対値が大きい回答と小さい回答

予測スコア	回答
1.22	料理そのものに関心がある場合は A，料理だけではなくコストパフォーマンスが大切な場合は B
0.00	外食の目的に応じて変わる，コミュニケーションが目的なら A，食べることが目的なら B
-0.04	A は，価格と雰囲気を重視する場合に有効です.例えば，大人数で個室を探したい時が考えられます．B は，ボリュームを重視する場合に有効です.例えば，食べ盛りの子供が多い場合時が考えられます．
-0.67	参加者が雰囲気の良いお店が好きな場合は A，参加者に美食家が多い場合は B

5.2 回答の分類に寄与している単語（問題 A）

今回対象とした回答は，「お店そのものを重要視する場合は A，料理そのものを重要視する場合は B（回答 1）」「A は新婚の場合なら適切であり，B は小さい子供がいる家族なら適切である.（回答 2）」の 2 つである．結果を表 4，表 5 に示す．回答 1 では，「料理」「店」の影響力が大きく，「そのもの」「場合」の影響力が小さいことが分かる．「料理」「店」は回答を意味付ける重要な単語の一つであるが，「そのもの」「場合」はその単語が無くても文の解釈はほとんど変わらないという点で，分類に寄与している単語をうまく抽出できたと言えるであろう．回答 2 では，「子供」「家

族」の影響力が大きく,「小さい」「適切」の影響力が小さいことが分かる. これも回答 1 と同様,「子供」「家族」は回答を意味づける重要な単語の一つであるが,「小さい」「適切」はその単語が無くても文の解釈はほとんど変わらないという点で, 分類に寄与している単語をうまく抽出できたと考えられる.

表 4 回答の分類に寄与している単語(回答 1)

単語	予測スコア
料理	0.73
店	1.00
重要	1.00
する	1.16
視	1.19
そのもの	1.19
場合	1.22

表 5 回答の分類に寄与している単語(回答 2)

単語	予測スコア
子供	-0.95
家族	-0.97
いる	-1.04
新婚	-1.10
場合	-1.10
小さい	-1.13
適切	-1.39

5.3 分類結果(問題 B')

SVM による分類結果を表 6 に示す. 結果, 分類誤りは 23 件中 5 件となり, 78.3%(=18/23)という高い精度であった(表 6). 問題 A の時よりも精度が落ちた要因として学習データの数が少なかったことが挙げられ, 学習データの数が増えれば問題 A の時と同様に非常に高い精度で分類できると考えられる.

表 6 問題 B'の回答分類結果(概要)

		予測	
		1. 反証	2. その他
実際	1. 反証	12	1
	2. その他	4	6

5.4 回答の分類に寄与している単語(問題 B')

今回対象とした回答は,「毎日の通勤で歩くなど, 運動の見方によっては毎日実行可能.(回答 3)」「実施するハードルが具体性に欠けている点(回答 4)」の 2 つである. 結果を表 7 と表 8 に示す. 予測スコアが正であれば「1. 反証の回答」, 負であれば「2. その他の回答」と予測したことになる. 回答 3 では,「歩く」「通勤」の影響力が大きく,「可能」「見方」の影響力が小さいことが分かる. また, 回答 4 では,「性」「具体」の影響力が大きく,「する」「いる」の影響力が小さいことが分かる. 影響力が大きい単語は回答を意味付ける重要な単語の一つであるが, 影響力が小さい単語はその単語が無くても文の解釈はほとんど変わらない. これより, 問題 A の時と同様に, 分類に寄与している単語をうまく抽出できたと言えるであろう.

表 7 回答の分類に寄与している単語(回答 3)

単語	予測スコア
歩く	0.57
通勤	0.69
毎日	0.80
運動	0.86
実行	0.99
可能	1.00
見方	1.14

表 8 回答の分類に寄与している単語(回答 4)

単語	予測スコア
性	-0.75
具体	-0.79
欠け	-0.81
実施	-0.85
点	-0.85
ハードル	-0.89
する	-1.01
いる	-1.13

6. 結論と今後

本研究では, 社会人向け教育における記述式問題回答自動分類の可能性について述べた. 回答が 50 文字程度, 且つ, 3 パターン程度に明確に分かれる問題においては, シンプルな手法でも高精度に回答を分類できることが分かった. さらに, 分類に寄与している単語を特定することもできた. また, 回答が発散する問題においては, 問題を細分化することで, 高精度で回答を分類でき, 且つ, 分類に寄与している単語を特定することができた. これにより, 社会人向け教育における記述式問題において, 回答のパターンによってフィードバックを換えるなど学習者の回答に応じた適切な振り返りサービスを提供することができる可能性があることが確認できた.

今後は, 学習者の回答に応じた適切な振り返りサービスが, 本当に学習者の理解の向上に繋がるのか検証したい. また, 問題の細分化などの工夫をしてもあらゆる問題の回答をパターン化できるとは限らないので, そのような場合にどのようなアプローチを取るのが良いのかについて考えていきたい. さらに, 50 文字を超えるような長い回答の場合でも, 本研究のような回答の自動分類が可能であるのかについても調査したい.

参考文献

[Li 17] Quanzhi Li, Sameena Shah, Xiaomo Liu and Armineh Nourbakhsh: Data Sets: Word Embeddings Learned from Tweets and General Data, In Proc. of ICWSM, pp.428-436 (2017)

[Sultan 16] Md Arafat Sultan, Cristobal Salazar and Tamara Sumner: Fast and Easy Short Answer Grading with High Accuracy, In Proc. of NAACL, pp.1070-1075 (2016)

[Taghipour 16] Kaveh Taghipour and Hwee Tou Ng: A Neural Approach to Automated Essay Scoring, In Proc. of EMNLP, pp.1882-1891 (2016)

[水本 18] 水本智也, 磯部順子, 関根聡, 乾健太郎: 採点項目に基づく国語記述式答案の自動採点, 言語処理学会 第 24 回年次大会 発表論文集, pp.552-555(2018)

[石岡 16] 石岡恒憲, 亀田雅之, 劉東岳: 人工知能を利用した短答式記述採点支援システムの開発, 信学技報, vol.116, no. 379, pp.87-92(2016)

[亀田 17] 亀田雅之, 石岡恒憲, 劉東岳: 短答記述式問題解答文の採点支援システム JS4の試作, 言語処理学会 第 23 回年次大会 発表論文集, pp.1137-1140(2017)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

Competency-oriented Learning by Teaching is as effective as Mastery Learning provided by Cognitive Tutor

Noboru Matsuda[*1]
[*1] Department of Teaching, Learning and Culture
Texas A&M University

The effect of Learning by Teaching and learning by being tutored was compared for learning linear equations. Three versions of an online learning environment were created: (1) APLUS for Learning by Teaching, (2) AplusTutor that is a cognitive tutor without problem selection adaptation, and (3) CogTutor+ that is equivalent to the traditional cognitive tutor. A randomized controlled study was conducted in two public schools with 184 7th and 8th grade students. The results showed (i) students' in the AplusTutor condition finished the quiz quicker than students in the APLUS condition, and (ii) there was a notable difference between Learning by Teaching and learning by being tutored in the "effort" students made.

1. Introduction

Learning by Teaching is a promising style of learning that has been empirically studied in various educational settings with remarkable positive effects in many subject domains [1, 2]. In recent years, researchers use the teachable agent technology to build an online learning environment that allows students to learn by teaching a synthetic peer, often called a teachable agent [3]. In the previous studies, the effect was often measured relative to traditional classroom instruction [4] or with different scaffolding strategies [6]. Learning by Teaching has rarely been compared with other types of instructional strategy. To advance the theory of Learning by Teaching, it is necessary to understand the similarities and differences between Learning by Teaching and other types of instructional strategy.

The goal of this study is to compare the effect of Learning by Teaching with learning by being tutored (aka cognitive tutoring [7]). We used an existing online learning environment for Learning by Teaching—APLUS (Artificial Peer Learning environment Using SimStudent)—where students can interactively teach a teachable agent called SimStudent [5]. As a comparison, we developed two versions of cognitive tutors using the APLUS interface—AplusTutor and CogTutor+. A classroom study was conducted to measure the effect of these three types of learning technologies.

2. Evaluation Study

Students using APLUS (Fig. 1) act as a tutor. The goal for students is to have their SimStudent pass the quiz. The quiz has four sections based on difficulty. One Step Equation (1 problem), Two Step Equations (2 problems), Equations with Variables on Both Sides (4 problems) and Final Challenge (8 problems, which is all equations with variables on both sides). SimStudent then applies what it has learned thus far to solve the quiz problems. There are learning resources available for students to review,:: (1) Problem Bank (a list of suggested equation problems to teach SimStudent), (2), Introduction Video (shows students how to use APLUS), (3) Unit Overview (a brief overview of how to solve algebra equations) and (4) Examples (worked-out examples for the target quiz level equations).

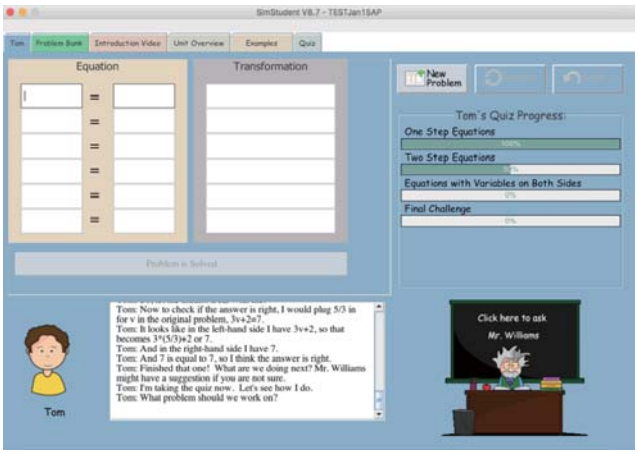


Fig. 1: Example screenshot of APLUS

CogTutor+ (Fig. 2) is designed in such a way that it closely mimics the tutoring behavior of a cognitive tutor—i.e., adaptive problem selection based on knowledge tracing for mastery learning [8]. CogTutor+ is developed to most strictly compare Learning by Teaching and learning by being tutored. The students' goal on CogTutor+ is the same as the traditional Cognitive Tutor, i.e., to reach the predefined mastery level in solving equations.

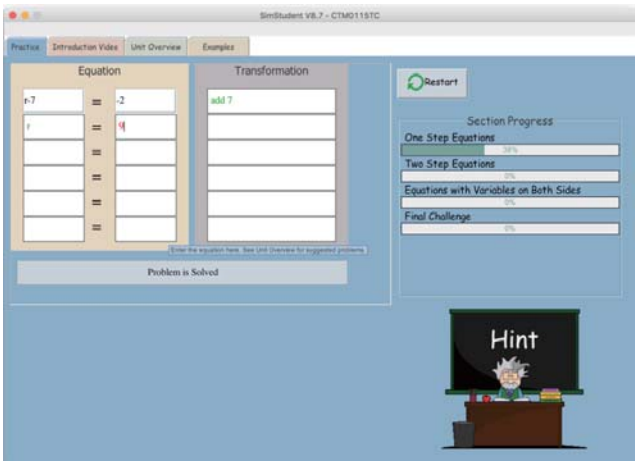


Fig. 2: Example screenshot of CogTutor+

Contact Infor: Noboru Matsuda, Noboru.Matsuda@tamu.edu

AplusTutor, on the other hand, is designed to control student's goal of learning—i.e., to pass the quiz. Students using AplusTutor select problems by themselves to practice in order to pass the quiz (by themselves). For this reason, we call students' learning on AplusTutor *Self-Regulated Practice*.

The goal of the current paper is to answer two specific research questions: (Q1) Which learning strategy is the most effective? — Learning by Teaching (APLUS), Self-Regulated Practice (AplusTutorr), or Cognitive Tutoring (CogTutor+). (Q2) How do different learning strategies impact students' learning differently? To address these research questions with tight controls, we developed two versions of cognitive tutors that look almost identical to APLUS. We call these cognitive tutors, AplusTutor and CogTutor+.

To answer these two research questions, we tested the following specific hypotheses: (H1) There is no difference on learning outcomes between different learning strategies. Completing the quiz (either by SimStudent or by students themselves) leads to no better learning than achieving the mastery level in cognitive tutoring. However, students in the Self-Regulated Practice condition finish the quiz faster than Learning by Teaching, because the Learning by Teaching condition requires interactively teaching SimStudent, which takes time. (H2) Learning by Teaching students show more improvement on the Conceptual Knowledge Test compared to the other conditions because SimStudent asks "why" questions which builds students conceptual understanding. To test these hypotheses, we conducted a classroom ("in-vivo") study where we compared the three strategies.

2.1 Method and Participants

The study was a randomized controlled trial with three conditions: (1) *Learning by Teaching* (LBT) where students used APLUS. (2) *Cognitive Tutoring* (CT) where students used CogTutor+. (3) *Self-Regulated Practice* (SRP) where students used AplusTutor.

Two public schools participated in the study with the total of 184 students in 12 7th and 8th grade algebra classrooms. In each classroom, students were randomly assigned to one of three conditions (i.e., within-class randomization).

The study ran for six days, one class period (45 to 50 minutes) per day. On the first day, all participants took a pre-test. On the 2nd through 5th day, participants used the software. On the last day, participants took a post-test.

2.2 Measures

We measured learning outcome and learning activity. Students' *learning outcome* was measured with an online (pre- and post-) test that consisted of two parts: a Procedural Skill Test and a Conceptual Knowledge Test.

The *Procedural Skill Test* has three sections: (1) An Equation section with 10 equation problems—2 one-step equations, 2 two-step equations, and 6 equations with variables on both sides. (2) An Effective Next Step section with 2 equation problems that are half solved. Students identify the correctness of each of four operations proposed as a next step. (3) An Error Detection section with 3 equation problems that are solved incorrectly. Students identify the incorrect step and explain their reasoning.

The *Conceptual Knowledge Test* consists of 24 true/false questions—6 items asking about variable terms, 6 about constant terms, 6 about like terms, and 6 about equivalent terms.

Students' *learning activity* was measured using learning process data that showed detailed interactions between a student and the system. The interactions are automatically collected by the system such as problems used for tutoring or practice, solutions entered by the student and the synthetic peer, quiz progress, and hint requested.

3. Results

For the analysis below, we included students who (a) took both pre and post-tests and (b) used the intervention at least for 3 (out of 4) days. There were 84 students (out of 184 in two schools) who met the criteria. Among these students, we excluded 17 students who scored 100% correct in the Equation part of the Procedural Skill Pre-Test. As a consequence, there were 67 students in the analysis: 24 in Learning by Teaching (LBT), 22 in Self-Regulated Practice (SRP), and 21 in Cognitive Tutoring (CT).

3.1 Learning outcomes

Table 1 shows the average test score for all three conditions. A repeated-measures ANOVA for test score as the dependent variable with test-time (pre vs. post) and condition (LBT vs. SRP vs. CT) as independent variables revealed a main effect for test-time for the Procedural Skill Test (PST); $F(1, 64)=15.43$, $p < 0.001$; $d = 0.29$. The condition is not a main effect; $F(2, 64) = .56$, $p = .58$. For Conceptual Knowledge Test (CKT), test-time was not a main effect; $F(1, 64) = 2.36$, $p = 0.13$, nor condition; $F(2,64) = 0.67$, $p = .52$.

Table1: scores. The number in parentheses shows standard deviation. CKT: Conceptual Knowledge Test. PST: Procedural Skill Test.

	CKT		PST	
	Pre	Post	Pre	Post
LBT	0.49(0.23)	0.53(0.22)	0.55(0.27)	0.62(0.22)
SRP	0.48(0.21)	0.51(0.14)	0.48(0.25)	0.56(0.20)
CT	0.43(0.23)	0.47(0.16)	0.54(0.22)	0.62(0.24)
Total	0.47(0.22)	0.50(0.18)	**0.53(0.24)[a]**	**0.60(0.22)[a]**

The data show that students in all three conditions equally improved their performance in solving equations (the PST score). The data also show that students did not improve their competency on the Conceptual Knowledge Test regardless of the learning strategy. The first half of hypothesis H1 (learning achievement) is supported. H2 is not supported.

3.2 Learning process

To test the second half of H1(speed of learning), we compared learning processes across the three strategies. We analyzed process data with a focus on speed to complete a learning goal and the amount of effort required. We operationalized *speed* as the number of days needed to pass the quiz for LBT and SRP and to reach to a mastery level for CT. As there was an error in data collection for the CT, speed to complete was only measured in LBT and SRP. Eight students in LBT passed all quiz levels and 18 in SRP.

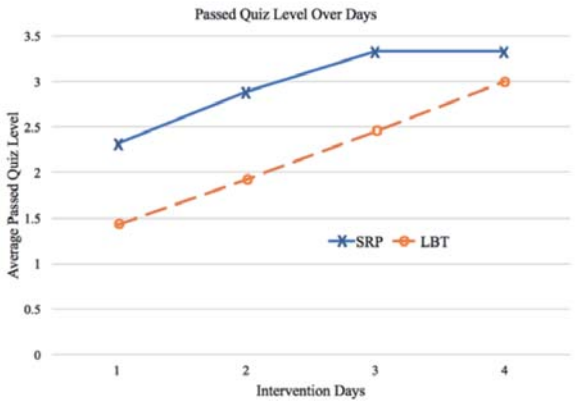


Fig. 3: Transition of quiz levels for Self-Regulated Practice (SRP) and Learning by Teaching (LBT). The X-axis shows intervention days and the y-axis shows the average quiz level passed.

Fig. 3 shows the average quiz level for each intervention day. Figure 3 also shows that SRP students reached higher quiz levels quicker than LBT students. The Learning by Teaching condition plots the quiz level that *SimStudent* passed whereas Self-Regulated Practice plots the one that *students* passed.

The quiz level was operationalized in such a way that One Step Equation is encoded as 1, Two Step Equations as 2, and Equations with Variable on Both Sides as 3. Overall, among all students the average highest quiz level passed was 2.0 for LBT students and 2.8 for SRP students. The difference was statistically significant; $t(60) = 6.18$, $p < 0.001$. These results imply that *students in SRP passed the quiz quicker than SimStudent taught by students in LBT*.

We operationalized *effort* as the number of problems practiced. In the LBT condition, this means the number of problems students entered to teach SimStudent. For the SRP and CT conditions, this is the number of problems that students solved with cognitive tutoring. Fig. 4 shows the number of problems practiced during four days of intervention. The plot shows that CT students practiced on the most number of problems (M=35±11.1) and SRP students practiced on the least number of problems (M=7±7.5). The average number of practice problems for LBT students is 22±8.9.

CT students spent more "effort" on practice than LBT students in terms of the number of practice problems to achieve the same level of learning (measured as the post-test PST score). SRP students spent the least "effort" on practice in all three conditions, but still achieved at the same level of learning.

Fig. 4 also shows that SRP students achieved the same level of learning with a smaller number of practice problems. However, *SRP students spent a considerable amount of time on "editing" their quiz solutions*. Since the system provides corrective feedback on quiz solutions, students knew which step was wrong. They then simply made another attempt on the incorrect step and submitted an "edited" solution. The average number of attempts to submit the quiz was 58.5±6.5 (5.1±1.6 per quiz item). Along with the fact that SRP students practiced 7 problems on average, the data implied that *Learning by Editing (aka Self-Regulated Practice) is as effective as LBT while it requires less practice on solving problems.*

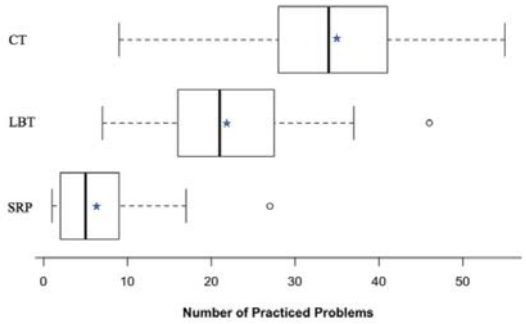


Fig. 4: Boxplot showing the number of practiced problems by students in each condition during the four days of intervention. An asterisk shows a mean.

4. Conclusion

The current study replicated lessons learned from previous studies [5, 6] including the following: (1) Students improved their competency in solving equations by 17% after teaching a synthetic peer on APLUS for four days. (2) The current implementation of APLUS for Learning by Teaching does not necessarily impact students' performance on the conceptual test (Conceptual Knowledge Test in the current paper).

The most important finding from the current study showed no condition difference between Self-Regulated Practice (SRP) and Cognitive Tutoring (CT) in students' learning measured by test scores (both procedural and conceptual tests). This implies that SRP, which is driven by *an intelligent tutoring system without a global student model* (i.e., knowledge tracing), *is as effective as a fully functional cognitive tutoring*. Also, the study showed that SRP and CT are both equally effective as Learning by Teaching.

We found a notable difference in the amount of work students needed to complete in order to achieve the same level of learning. There were no hints available on the quiz in AplusTutor. Therefore, students can enter a failed quiz item into practice and have the cognitive tutor provide scaffolding on how to solve it. As a result, students in our study chose to simply edit solutions most likely on the trial-and-error basis. With VanLehn's terminology [10], this is an "intelligent" tutor without the outer loop for the adaptive problem selection. We call this type of intelligent tutor the Competency Driven Cognitive Tutor (as opposed to the mastery based Cognitive Tutor).

It is not clear why Self-Regulated Practice with a small amount of practice is as effective as LBT. Further studies are required to replicate this finding and validate the results. One concern is about "shallow learning" where students become competent in solving a particular type of problem without deep understanding [11]. To test this hypothesis in a future study, we must measure students' ability on far transfer problems.

References:

1. Roscoe, R.D. and M.T.H. Chi, *Understanding tutor learning: Knowledge-building and knowledge-telling in peer tutors' explanations and questions.* Review of Educational Research, 2007. **77**(4): p. 534-574.
2. Cohen, E.G., *Restructuring the classroom: Conditions for productive small groups.* Review of Educational

Research, 1994. **64**(1): p. 1-35.
3. Blair, K., et al., *Pedagogical agents for learning by teaching: Teachable agents.* Educational Technology & Society, 2006. **Special Issue on Pedagogical Agents**: p. 56-61.
4. Biswas, G., J.R. Segedy, and K. Bunchongchit, *From Design to Implementation to Practice a Learning by Teaching System: Betty's Brain.* International Journal of Artificial Intelligence in Education, 2016. **26**(1): p. 350-364.
5. Matsuda, N., et al., *Cognitive anatomy of tutor learning: Lessons learned with SimStudent.* Journal of Educational Psychology, 2013. **105**(4): p. 1152-1163.
6. Matsuda, N., et al., *Tell me how to teach, I'll learn how to solve problems*, in *Proceedings of the International Conference on Intelligent Tutoring Systems*, A. Micarelli, J. Stamper, and K. Panourgia, Editors. 2016, Springer: Switzerland. p. 111-121.
7. Anderson, J.R., et al., *Cognitive modeling and intelligent tutoring.* Artificial Intelligence, 1990. **42**(1): p. 7-49.
8. Corbett, A.T. and J.R. Anderson, *Knowledge tracing: Modeling the acquisition of procedural knowledge.* User Modeling and User Adapted Interaction, 1995. **4**(4): p. 253-278.
9. Matsuda, N., W.W. Cohen, and K.R. Koedinger, *Teaching the Teacher: Tutoring SimStudent leads to more Effective Cognitive Tutor Authoring.* International Journal of Artificial Intelligence in Education, 2015. **25**: p. 1-34.
10. VanLehn, K., *The Behavior of Tutoring Systems.* International Journal of Artificial Intelligence in Education, 2006. **16**.
11. Matsuda, N., et al., *Shallow learning as a pathway for successful learning both for tutors and tutees*, in *Proceedings of the 34th Annual Conference of the Cognitive Science Society*, N. Miyake, D. Peebles, and R.P. Cooper, Editors. 2012, Cognitive Science Society: Austin, TX. p. 731-736.
12. Bredeweg, B., et al., *DynaLearn - Engaging and Informed Tools for Learning Conceptual System Knowledge*, in *Cognitive and Metacognitive Educational Systems (MCES2009), AAAI Fall Symposium*, P. R., R. Azevedo, and G. Biswas, Editors. 2009, AAAI Press: Arlington, VA. p. 46-51.
13. Jun, Y., *Linear Kid: A mathematical software designed as a computer-based peer tutoring system*, in *Proceedings of the Second Asian Technology Conference in Mathematics*. 1997.
14. Tecuci, G. and H. Keeling, *Developing an Intelligent Educational Agent with Disciple*. International Journal of Artificial Intelligence in Education, 1999. **10**: p. 221-237.
15. Ur, S. and K. VanLehn, *STEPS: A Simulated, Tutorable Physics Student.* Journal of Articial Intelligence in Education, 1995. **6**(4): p. 405-437.
16. Uresti, J.A.R. and B. du Boulay, *Expertise, Motivation and Teaching in Learning Companion Systems.* International Journal of Artificial Intelligence in Education, 2004. **14**(2): p. 193-231.
17. Biswas, G., et al., *Measuring Self-Regulated Learning Skills through Social Interactions in a teachable Agent Environment.* Research and Practice in Technology Enhanced Learning, 2010: p. 123-152.
18. Pareto, L., et al., *A Teachable-Agent Arithmetic Game's Effects on Mathematics Understanding, Attitude and Self-efficacy*, in *Proceedings of the International Conference on Artificial Intelligence in Education*, G. Biswas, et al., Editors. 2011, Springer: Heidelberg, Berlin. p. 247-255.
19. Matsuda, N., et al., *Learning by Teaching SimStudent – An Initial Classroom Baseline Study comparing with Cognitive Tutor*, in *Proceedings of the International Conference on Artificial Intelligence in Education*, G. Biswas and S. Bull, Editors. 2011, Springer: Berlin, Heidelberg. p. 213-221.
20. Metcalfe, J. and N. Kornell, *A region of proximal learning model of study time allocation.* Journal of Memory and Language, 2005. **52**(4): p. 463-477.
21. Corbett, A., *Cognitive Materly Learning in the ACT Programming Tutor*. 2000, AAAI Technical Report SS-00-01.
22. Thiede, K.W., M.C.M. Anderson, and D. Therriault, *Accuracy of metacognitive monitoring affects learning of texts.* Journal of Educational Psychology, 2003. **95**(1): p. 66-73.
23. Schneider, W., *The Development of Metacognitive Knowledge in Children and Adolescents: Major Trends and Implications for Education.* Mind, Brain & Education, 2008. **2**(3): p. 114-121.
24. Atkinson, R.C., *Optimizing the learning of a second-language vocabulary*. Journal of Experimental Psychology, 1972. **96**(1): p. 124-129.
25. Kostons, D., T. van Gog, and F. Paas, *Self-assessment and task selection in learner-controlled instruction: Differences between effective and ineffective learners.* Computers & Education, 2010. **54**(4): p. 932-940.
26. Long, Y., Z. Aman, and V. Aleven, *Motivational Design in an Intelligent Tutoring System that Helps Students Make Good Task Selection Decisions*, in *Artificial Intelligence in Education: 17th International Conference, AIED 2015, Madrid, Spain, June 22-26, 2015. Proceedings*, C. Conati, et al., Editors. 2015, Springer International Publishing: Cham. p. 226-236.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

アニメを用いた日本語の聴解スキルの訓練システムに関する検討

A Study on Japanese Listening Training Support System by Using Anime

Junjie Shan[*1] 西原陽子[*2] 山西良典[*2]
Junjie Shan Yoko Nishihara Ryosuke Yamanishi

[*1]立命館大学大学院情報理工学研究科
Graduate School of Information Science and Engineering, Ritsumeikan University

[*2]立命館大学情報理工学部
College of Information Science and Engineering, Ritsumeikan University

This paper reports a study on Japanese listening training support system by using Anime. The proposed system divides episodes of Anime into scenes by using silent sections of Anime. The system evaluates a level of a scene by using words and expressions in subtitles of the scene. Users of the proposed system are assigned scenes of Anime which level is suitable for the users. We experimented with the proposed system to verify the efficiency of the system. Participants of the experiment watched scenes given by the proposed system. They took tests prepared from previous JLPT listening tests before and after watching scenes. The scores after watching scenes were higher than those before.

1. はじめに

第二外国語として日本語を学ぶ人の数は年々増えている [国際交流基金 15]．日本の古典的な文化やモダンカルチャが海外で紹介されたのをきっかけとして，日本語に興味を持つ外国人も少なからずいると考えられる．モダンカルチャの一種として日本語のアニメやコミックがある．いずれも海外では高い評価を受け，現地での言語に翻訳され楽しまれていることも多い．我々は，単語や文法などを示した教科書に加えて，生きた言語が含まれるアニメやコミックを用いた言語学習の研究を行なっている [Shan 17]．

特にアニメは聞き取りやすい発音の声優がキャラクターの声をあてており，耳で聞いて内容を理解するスキルを訓練するには最適の材料と考えられる．アニメのキャラクターたちは年齢，性別が多岐に渡っており，会話の中にも様々な種類の単語が含まれている．したがって，日本語を母語としない人たちにとっては，その人の日本語のレベルに応じてわかりやすいセリフとそうでないセリフが存在すると考えられる．各人のレベルにあったセリフが含まれるアニメを選択してみることにより，聞くスキルの訓練が効率よく行えると考えられる．

そこで本論文では，アニメを用いた日本語の聴解スキルの訓練システムを提案し，その実験結果を報告する．アニメやコミックを用いた日本語教育においては，教科書の事例としてアニメのシーンやコミックのコマを利用するものが多いが [Lammers 04]，聴解のスキルの訓練にアニメを用いた例は我々の知る限りでは少なく，利用するための手法が求められている．

2. アニメを用いた日本語聴解スキルの訓練システム

システムの処理手順の概要を説明する．

1. アニメの動画データを無音区間を用いてシーンに分割する
2. 分割されたシーン内のセリフのテキストを取得する
3. テキストを形態素解析にかけ，単語を取得する
4. 取得した単語のレベルを評価する
5. シーン全体の日本語のレベルを評価する

連絡先: 西原陽子，立命館大学情報理工学部，滋賀県草津市野路東 1-1-1

表 1: 日本語の単語と表現のレベルごとの数

Level	L4	L3	L2	L1
Word	738	685	3636	2962
Expression	none	108	177	105

それぞれの手順について本論文での詳細を説明する．3. の形態素解析では Igo を用いた．4. の単語のレベルは，日本語能力検定試験の参考書で分類されていたものを用いた．日本語能力検定試験は英語における TOEIC や TOEFL のようなもので，日本語を母語としない人が日本語の学習の程度を評価するために受験する試験である．旧基準では L1 から L4 までの 4 つのレベルがあり，L1 がもっとも難しく，L4 がもっとも平易となっている．各レベルで主に出題される単語と表現が定まっており，表 1 に示す分布となっている．本論文では各単語のレベルを L1 から L4 のいずれかとして評価し，各表現のレベルは L1 から L3 のいずれかとして評価する．

5. のシーン全体の日本語レベルは，シーンに含まれる単語と表現のレベルを用いて評価する．はじめに評価のための基準となるデータを日本語能力検定試験の聴解問題から用意する．聴解問題は L1 から L4 まである．聴解問題で使われる音声データを書き起こし，含まれる単語と表現のレベルを取得する．つづいて，各レベルの単語と表現の割合を算出する．レベル L_i の聴解問題の単語と表現のレベルを，式 (1) と式 (2) に示す 2 つのベクトルで表現する．

$$Word(L_i) = \{wr(L1), wr(L2), wr(L3), wr(L4)\}, \quad (1)$$

$$Exp(L_i) = \{er(L1), er(L2), er(L3)\}. \quad (2)$$

表 2: 実験被験者のデータ

回答レベル	実験群	統制群
L1	16	20
L2	25	21
L3	17	21

シーン S_j の単語と表現のレベルも同様に，式 (1) と式 (2) を用いて 2 つのベクトルで表現する．各シーンのベクトル $Word(S_j)$ と $Exp(S_j)$ が，どのレベルの分布のベクトル $Word(L_i)$ と $Exp(L_i)$ と似ているかを評価するために，式 (3) を用いて，類似度を評価する．類似度がもっとも高いレベルを一つ選択し，シーンのレベルとして付与する．

$$\begin{aligned} Sim(L_i, S_j) &= \alpha * Cos(Word(L_i), Word(S_j)) \quad (3) \\ &+ (1-\alpha) * Cos(Exp(L_i), Exp(S_j)). \end{aligned}$$

式 (3) の $Cos()$ は 2 つのベクトルのコサイン類似度である．α は重みであり，単語と表現のどちらを重視するかを決めるものである．

3. 評価実験と結果

提案したシステムを評価する実験を行なった．実験では 3 つのアニメから合計 71 本のエピソードを用意し，提案システムへの入力として与えた．実験者は被験者を募集し，実験群と統制群に分けた．被験者は中国に住む日本語を学習している主には大学生であった．被験者には現状の日本語のレベルを質問し，一つ上のレベルを目指すという設定でグループ分けをした．例えば，現状 L2 の人は L1 を目指して学習するという意味である．結果として被験者のグループ分けは表 2 に示す通りとなった．

はじめに被験者たちの現状の日本語レベルを評価するためにテストを課した．テストは過去の JLPT の試験の聴解問題から 5 問ずつ用意し，各レベルの被験者に回答させた．このスコアを視聴前スコアとする．実験群の被験者はグループ分けされたレベルのシーンを 10 件から 12 件視聴した．統制群の被験者はグループ分けされた 3 つのレベルから 4 件ずつ，合計 12 件のシーンを視聴した．

視聴後に被験者は訓練効果を評価するためのテストを受験した．テストは過去の JLPT の試験の聴解問題から 5 問ずつ用意し，各レベルの被験者に回答させた．視聴前に行った問題とは異なる問題を用意した．このスコアを視聴後スコアとする．

3.1 実験結果：視聴前スコアと視聴後スコアの比較

表 3 に実験群の視聴前スコアと視聴後スコアを示す．表 4 に統制群の視聴前スコアと視聴後スコアを示す．

視聴前の正解率と視聴後の正解率を比較すると，実験群の L1 から L3 のグループと，統制群の L1 から L3 のグループのいずれにおいても，正解率が上昇した．アニメを視聴することにより，聴解テストのスコアは上昇することが示された．

上昇率を比較すると，実験群の上昇率の方が統制群の上昇率よりも高くなっていた．特に L2 では，実験群の上昇率は 26.4%であるのに対し，統制群の上昇率は 10.6%であり，もっとも差が大きかった．

表 3: 実験群の視聴前スコアと視聴後スコア

		Q1	Q2	Q3	Q4	Q5	正解率
L1	Pre	10	9	9	10	7	56.4%
	After	12	11	12	10	9	67.6%
L2	Pre	14	10	17	9	5	44%
	After	18	22	19	20	9	70.4%
L3	Pre	5	12	8	9	1	41.2%
	After	11	13	11	10	3	56.6%

表 4: 統制群の視聴前スコアと視聴後スコア

		Q1	Q2	Q3	Q4	Q5	正解率
L1	Pre	12	9	10	8	6	45%
	After	11	12	16	8	8	55%
L2	Pre	9	9	11	12	5	43.8%
	After	16	8	14	14	5	54.4%
L3	Pre	8	9	14	10	6	45%
	After	11	10	18	12	3	51.4%

4. おわりに

本論文では，アニメを用いた日本語の聴解スキル訓練システムを提案し，その実験結果を報告した．提案システムではアニメのシーンごとに，日本語能力検定試験の聴解問題のレベルとの類似度を評価することにより，シーンのレベルを 3 段階で評価する．類似度の評価にあたっては，シーンに含まれる単語と表現のレベルごとの分布と，聴解問題に含まれる単語と表現のレベルの分布を用いた．提案システムを評価する実験を行なった．提案システムを用いてレベルを評価されたシーンを視聴した被験者は，実験前のテストの点数に比べて，実験後のテストの点数が高くなった．このことから提案システムの有効性を確認した．

謝辞

本研究の一部は科研費若手 B(17K13254) と基盤 C(16K00307) の補助を受けた．記して謝意を申し上げる．

参考文献

[国際交流基金 15] 国際交流基金: 2015 年度「海外日本語教育機関調査」結果, https://www.jpf.go.jp/j/about/press/2016/dl/2016-057-1.pdf (2016)

[Lammers 04] Wayne P. Lammers: Japanese The Manga Way: An Illustrated Guide To Grammar And Structure, Stone Bridge Pr (2004).

[Shan 17] Junjie Shan, Yoko Nishihara, Ryosuke Yamanishi, and Junichi Fukumoto: Analysis of Dialogues Difficulty in Anime Comparing with JLPT Listening Tests, 21st International Conference on Knowledge-Based and Intelligent Information & Engineering Systems, Vol. 112, pp. 1345-1352 (2017).

[1L3] [General Session] 12. HI / Education Aid

座長:曽我 真人（和歌山大学）

Tue. Jun 5, 2018 5:20 PM - 6:40 PM Room L (3F Sapphire Hall Asuka)

[1L3-01] Development of Logical Thinking Training System by Proving Mathematical Problems

○Kayo Kawamoto[1,2], Minatsu Furutani[1], Ayako Miyawaki[1], Tomoyuki Uchida[1], Tsukasa Hirashima[2], Yusuke Hayashi[2] （1. Hiroshima City University, 2. Hiroshima University）

5:20 PM - 5:40 PM

[1L3-02] Student group formation multiobjective optimization with a hybrid of genetic algorithm and particle swarm optimization

○Satoshi V. Suzuki[1] （1. Osaka University of Economics and Law）

5:40 PM - 6:00 PM

[1L3-03] A Study on Oddball Tasks with Feedback for Measuring P300

○Tadashi Koike[1], Tomohiro Yoshikawa[1], Takeshi Furuhashi[1] （1. Nagoya university）

6:00 PM - 6:20 PM

[1L3-04] Constructive and Practical Research Methodology for Computational Understanding of Situated Intelligence

○Koryu Nagata[1], Yasutaka Kuroki[2], Masaya Okada[3] （1. Department of Computer Science, Faculty of Informatics, Shizuoka University, 2. Department of Informatics, Graduate School of Integrated Science and Technology, Shizuoka University, 3. Division of Behavior Informatics, College of Informatics, Academic Institute, Shizuoka University）

6:20 PM - 6:40 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

数学証明問題を用いた論理的思考力育成システムの開発

Development of Logical Thinking Training System by Proving Mathematical Problems

川本 佳代[*1*3] 古谷 美夏[*2] 宮脇 綾子[*2] 内田 智之[*1] 平嶋 宗[*3] 林 雄介[*3]
Kayo Kawamoto Minatsu Furutani Ayako Miyawaki Tomoyuki Uchida Tsukasa Hirashima Yusuke Hayashi

[*1] 広島市立大学大学院情報科学研究科
Graduate School of Information Sciences, Hiroshima City University

[*2] 広島市立大学情報科学部
Faculty of Information Sciences, Hiroshima City University

[*3] 広島大学大学院工学研究科
Graduate School of Engineering, Hiroshima University

Logical thinking ability is one of the most important abilities in our daily life situations. In this paper, we propose logical thinking training systems that to improve logical thinking abilities of high school students and college students by using proving mathematical problems. We show that the proposed systems implemented on Android tablets are effective for improving logical thinking abilities of college students by reporting experimental results and questionnaire.

1. はじめに

現代社会において，論理的思考力は最も重要な能力の 1 つである．高等学校学習指導要領解説においても，論理的な思考力の育成は重視されている．特に，高校の数学教育において数学証明を扱うことが論理的思考力の育成に役立つと述べられている[文部科学省 2013]．数学的な言語は通常の言語とは違い，論理的な操作が容易で，推論の過程を簡潔かつ正確に伝えることができるという特徴がある[山戸 2011]．さらに，表現手段としてだけではなく人間の論理的思考を促進する上で大きな効力を発揮すると考えられる [山戸 2011]．このことから，数学証明と論理的思考力との間には強い関係があり，数学の証明を記述する力を着けることが，論理的思考力の育成につながると考えられる．一方で，高等学校の数学教育では，数学の証明問題に十分な時間を割くことが出来ず，数学証明が論理的思考力の育成に充分活用されているとは言い難い．そこで本研究では，数学の証明問題を用いた論理的思考力育成支援システムを開発することを目的とする．本稿では，数学の証明論法の中でも背理法と対偶法に絞り，数学的な表現力および構成力の習得を通して，表現力を含む論理的思考力の育成を目指したシステムを Android Tablet 上に実装し，実験によりその有用性を示したのでその報告を行う．

2. 提案システム

本稿では，「証明全体の論理的整合性」と「局所的な論理的整合性」の 2 つの観点に基づいたシステム(赤システムと青システムと呼ぶ)をそれぞれ提案する．両システムとも，(1) ログイン画面，(2) ホーム画面，(3) 証明論法表示画面，(4) 証明論法に基づく問題確認画面，(5) 証明作成画面，(6) 証明確認画面，(7) 証明断念理由選択画面，(8) 証明論法解説画面などで構成される． 画面(3)と(4)では，証明する命題およびその命題における仮定と結論を，さらに対偶法では命題の対偶を，背理法では命題の否定を画面下部の語群からドラッグ＆ドロップして答えることで，指定された証明論法に基づいた証明を作成する準備を行う(図 1 左参照)．また，画面(5)では，学習者は証明にある複数個所の空行に適切な文を語群から選択することで証明を作成し，画面(6)で即時に正誤チェックを行う．もし誤っていた場合には再作成・断念の選択および証明論法の解説を行う画面

連絡先：川本佳代，広島市立大学情報科学研究科，〒731-3194 広島市安佐南区大塚東 3－4－1，kayo@hiroshima-cu.ac.jp

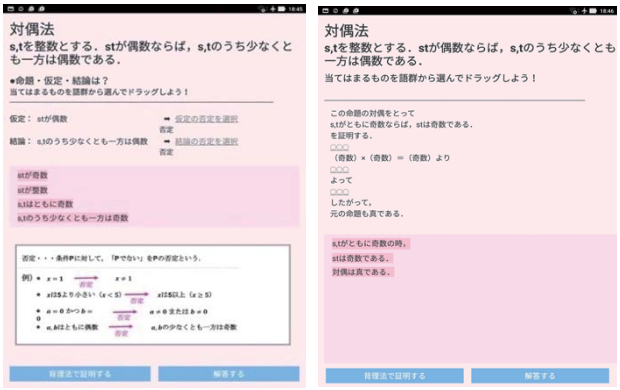


図 1 赤システムの対偶法の解説画面(4)と証明作成画面(5)

(7)に，正しい場合には作成した証明の再確認を行う画面(8)に移る．数学証明の論理構造を図示することで学習者が証明を理解しやすくしようという研究[青木 2015，森田 2016]があるが，本研究では単純な論理構造で証明できる問題のみを扱うため，一般的な証明の記述方式に近い提示とした．両システムの違いについて以下に述べる．

2.1 証明全体の論理的整合性に着目した赤システム

赤システムの証明作成画面(5)では，前後の文のつながりを理解させつつ，証明全体の論理的整合性を考えさせるために，パーツに分解された証明文を正しく組み立てなおして再構成する kit-build 方式[Hirashima et al. 2011]を用いる．具体的には、複数の空行がある証明が提示され(図 1 右参照)，画面下部にある語群から適切な文を適切な空行にドラッグ＆ドロップして証明を作成する．証明のどの行が空行であるかにより，問題の難易度が変化する．語群にある文と証明の空行の数は同じであり，語群には証明に必要な文のみが過不足なく与えられている．また作成した証明が正解になるまで何度でも繰り替えし作成することができる．正解すると，学習者が証明の流れを再度確認する証明確認画面(6)に移る．

2.2 局所的な論理的整合性に着目した青システム

青システムでは，前後の文のつながりを理解させることに重点があるため，初めから証明の論理構造が与えられている．このため，証明作成画面(5)では，赤システムと同様複数の空行がある証明が提示されが，空行の先頭にある選択ボタンをタップすることで，語群として画面下部にその行に入れるべき文を含む 3 つの文が現れる(図 2 左参照)．その語群から正しい文をドラッ

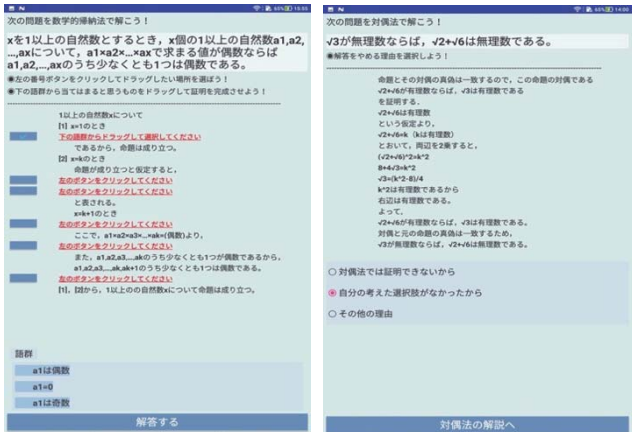


図 2 青システムの証明作成画面(5)と証明断念理由選択画面(7)

グ＆ドロップすることで証明を作成する．語群には，正しい文以外に，選択した行の前後のつながりを論理的に考えなければ間違ってしまうような，正解の変形としての誤選択肢が2つある．

3. 評価実験

2つの提案システム（赤システムと青システム）の有用性を調べる評価実験を行ったので，その報告と考察を行う．

3.1 実験設定

大学生 30 名の実験協力者を，事前テストの成績の平均が同程度になるよう，提案（赤システム）群，提案(青システム)群，比較(教科書)群の 3 群に分けた(提案(赤システム)群：平均 138.50 点，SD 61.44，提案（青システム）群：平均 137.20 点，SD 63.12，比較(教科書)群：平均 141.40 点，SD 61.88，分散分析 $F(1,27)=0.01$，n.s.)．実験は，事前テスト→事前アンケート→学習(30 分)→事後テストの順で行い，その後，比較（教科書）群は事後アンケート，提案（赤システム）群と提案（青システム)群は学習(未使用のシステム)→事後アンケートの順で進めた．比較(教科書)群は高等学校数学で用いられている教科用図書を用いた．なお，事前テストと事後テストともに，数学の証明問題を記述形式で解く課題とした．

3.2 実験結果および考察

事後テストの得点に関する各群の平均と標準偏差を表1に示す．分散分析の結果，表2の通り，学習方法の効果が有意であった ($F(2,27)=4.06$, $p<.05$)．Bonferroni法を用いた多重比較によれば，提案(赤システム)群と比較(教科書)群の間に有意差があった (MSe=5527.28, 5%水準)．しかしながら，提案(青システム)群と比較(教科書)群，提案(青システム)群と提案(赤システム)群の間に有意差はなかった．このことから，数学の証明の単元において，教科書よりも提案（赤システム）で学習した方が有効であると考えられる．

表 1 各群の平均と標準偏差

	人数	平均	標準偏差
提案(青システム)群	10	243.30	66.21
提案(赤システム)群	10	259.30	76.08
比較(教科書)群	10	170.40	68.92

表 2 分散分析表

S.V	SS	df	MS	F
群	44912.07	2	22456.03	4.06 $p < .05$
誤差	149236.60	27	5527.28	259.30
全体	194148.67	29		

提案（赤システム）群と提案（青システム）群の事後アンケートの結果より，「どちらのシステムの方がより勉強したなという充実感を感じましたか」の問いについて，有意に多くの人が青システムを選択した (17:3,二項検定 p<.01)．さらに，「どちらのシステムの方が論理的思考力を高めるのに有効だと思いますか」の問いについても，有意に多くの人が青システムを選択した (16:4, p<.05)．これらは，青システムでの学習の方が，自ら思考し，問題に取り組めていると学習者が感じていることを示していると考えられる．一方で，事後テストの得点に関する Bonferroni 法を用いた多重比較から，青システムを用いた学習方法と教科書を使用した学習方法に有意差はなかったが，赤システムを用いた学習方法では教科書を用いたときと比べて有意に良かった．このような結果となった理由として次のことが考えられる．両提案システムとも学習者に思考を促しているが，システムを用いて学習する時間が 30 分と短いことに加え，赤システムでは学習者が全体の証明の流れに着目して学習を進めていたのに対し，青システムでは誤った文を選ばないように個々の記述に注意しながら証明を完成させる必要があった．つまり，青システムにおいては，各空行でどこが間違っているのかを確認しながら正解となる文を見つける作業の時間がかかっていたためだと考えられる．その結果，全体的な論理構造は十分に考えられていないと思われる．これは，学習者はこの作業を行うことを思考していると感じているが，学習者の数学証明の力を育成することにはつながっていないことを示唆していると考えられる．以上により，赤システムの方が青システムより論理的思考力の育成には有用であると考えられる． さらに通常の演習では局所的な論理的整合性に焦点を当てた課題が広く受け入れられているが，必ずしも良いわけではないことを示していよう．

4. おわりに

数学の証明問題を用いた論理的思考力育成支援システムを 2 種類開発した．思考の度合いや充実感などについてのアンケートで，局所的な論理的整合性に着目した学習を行う青システムの方が有意に良いことを示した．さらに，教科書を用いた学習方法より，kit-build 方式を用いて証明全体の論理的整合性に着目した学習を行う赤システムの方が論理的思考力の育成により有用であることを事後テストに関する評価実験により示した．今後の課題としては，個々の学習者の能力に合った問題の提示とレベル設定を自動で行えるように拡張することがあげられる．

参考文献

[文部科学省 2013] 文部科学省，高等学校学習指導要領解説(2013)

[山戸 2011] 山戸正啓，谷直樹，松井悠歌:「数学的な思考力を育む授業の創造 ～言語活動を効果的に行うための学習課題の開発」，大阪教育大学附属池田中学校 研究紀要(第 50 集)， pp.26-35 (2011)

[Hirashima et al. 2011] Hirashima, T. et al., “Kit-build concept map for automatic diagnosis”, Proc. of AIED2011, pp.466-468 (2011)

[青木 2015] 青木 杏奈，渡部 孝幸，宮崎 佳典:「数学教育における証明学習のための図示化を用いた学習支援ツール」，情報処理学会第 77 回全国大会, pp.4-977―4-978 (2015)

[森田 2016] 森田 雄介，宮崎 佳典，渡部 孝幸:「数学教育における証明学習のための論理構造提示 Web アプリケーション」，情報処理学会第 78 回全国大会, pp.4-845―4-846 (2016)

1. はじめに

身近で同質な他者との会話ばかりでなく，自身と来歴や背景知識が大きく異なるような他者とも対話を成り立たせ，チームで活動して成果を挙げる能力の養成が社会の中で求められている [Griffin 12, 鈴木 17]．このような能力の基礎づくりとして，授業における学習者同士の相互作用を通じた学習活動は重要なものと位置づけられる．

その一方で，大学の授業においては欠席が多く，授業参加もままならない学生もいる．近年では授業に出席した上で活動することが成績評価で重きを置かれることも多く全体としては以前より出席率が高くなる傾向があるものの，大学生の専攻分野や学年による出席率の差が大きく，社会科学系専攻の大学生や就職活動で多忙になる 4 年次の学生は低めになる傾向がある [ベネ]．また，経済状況的に収入をアルバイトに大きく依存しており万全な態勢での授業参加が厳しい学生や，大学進学率上昇に伴いコミュニケーションのスキルや基礎学力に多大な問題を抱える学生も大学に在籍する割合が増してきている [濱中 13]．このような問題は大学授業の現場における工夫のみでは解決が難しいが，授業の出席が大変な大学生でも他者と学ぶ環境へ円滑に参加できる授業づくりは重要といえる．

本稿では，履修者の出席率と学修成績を考慮したグループ編成の最適化手法として遺伝的アルゴリズム・粒子群最適化ハイブリッド手法を導入し，他の最適化手法との比較による性能評価についても言及する．

2. 関連研究

グループワークにも様々な種類と役割があり，PBL のように長期間同じグループで活動するものも重要であるが，毎回の授業ごとにグループを組み替え，短時間のワークで多様な学生と接触する機会が持てるグループワークも同様に重要と考えられ，このようなグループ編成の手法についてはくじ引きなどランダムな手法をとられる事例が多い [Barkley 05, 中野 17]．しかし，Cruz and Isotani [Cruz 14] はランダムな手法の問題点を指摘した上で，ある定量的な基準に基づく協調学習向けのグループ編成の最適化の試みをレビューしている．その中で，複数の異なるアルゴリズムの比較を通した性能評価がなされていない点も指摘されている．また，くじ引きによる手法はグループ編成に時間がかかるという問題もあり，授業時間の有効活用という点からも，事前に決めたグループで極力進められる形が理想といえる．

また，学修遂行の様々な指標をもとに学習者のクラスタリングを行った上で，各グループメンバの長所に着目して自然な役割分担が行えるようなグループ編成を行う試みもある [椿本 13]．本稿では学修遂行の指標は 1 変数として扱うが，これに加えて出席率を新たに変数として導入し，事前に決めたグループで極力進められるようなグループ編成を求めるアルゴリズムを提案する．

3. 遺伝的アルゴリズム・粒子群最適化ハイブリッドによるグループ編成の多目的最適化

本稿では遺伝的アルゴリズム・粒子群最適化ハイブリッドによるグループ編成の多目的最適化を試みる．遺伝的アルゴリズム（Genetic Algorithm: GA）は生物の進化を模倣したアルゴリズムで，解探索や機械学習など広く応用されている [Goldberg 89]．粒子群最適化（Particle Swarm Optimization: PSO）は鳥が群れをなして飛ぶ場面などの生物の集団行動を模倣したアルゴリズムで，こちらも解探索などで広く応用されている [斎藤 11]．また，本稿では複数の基準で最適なグループ編成を求める多目的最適化を行うが，GA はたとえば 2 つの基準による多目的最適化において x，y をそれぞれ正の実数としてより小さい (x, y) を求める場合に $x_1 < x_2$ かつ $y_1 > y_2$ なる (x_1, y_1) および (x_2, y_2) となるような非劣解集合（パレート集合）に属する解を多数求める上で適している [廣安 00]．一方 PSO は，他のよりよい解を利用して解探索を行うという特徴から，局所最適な解を早く求めるには向いているが，局所最適でない解をそこから新たに見つけ出すまでに工夫を要するアルゴリズムといえる [斎藤 11]．すでに両者のハイブリッドによるアルゴリズムの応用も進んでいる（たとえば Juang [Juang 04] など）が，本研究ではこれをグループ編成の組合せ最適化問題に応用し，この両者の利点を組み合わせることで，高速かつ多様な最適解の発見を行えるようにする．多様な非劣解集合を求める形にすることで，複数のグループ編成の候補からクラスの状況などに合わせて柔軟に選択できる形にすることができる．

3.1 GA の応用：初期個体生成，交叉，突然変異，選択

本研究では，GA の遺伝子としてグループの組合せを採用する．

初期個体生成　まず，履修者のリストを用いて，任意のランダムな任意の人数からなるグループの組合せを任意の回数生成し，これを初期個体とする．

交叉　個体 $\mathbf{S}_1$，$\mathbf{S}_2$ について，個々の履修者の学修遂行を s，出席率を a とする．履修者数を n 名とした場合，グループ内の学修遂行の値の合計でグループを降順にソート，さらにグループ内でも履修者を学修遂行の値で降順にソートし 2 つの $2n$ 次元ベクトル

$$\mathbf{S}_1 = [s_{11}, s_{12}, \ldots, s_{1n}, a_{11}, a_{12}, \ldots, a_{1n}]$$
$$\mathbf{S}_2 = [s_{21}, s_{22}, \ldots, s_{2n}, a_{21}, a_{22}, \ldots, a_{2n}]$$

を構成する．この 2 ベクトルのなす角の余弦を $\mathbf{S}_1$，$\mathbf{S}_2$ の類似度とする．

親個体 $\mathbf{S}_1$，$\mathbf{S}_2$ について，任意の人数（数名程度）分履修者の属するグループをランダムに入れ替えた個体をその親個体の近傍とする．この近傍を複数生成し，$\mathbf{S}_1$ と最も類似度の高い $\mathbf{S}_2$ の近傍，および $\mathbf{S}_2$ と最も類似度の高い $\mathbf{S}_1$ の近傍をそれぞれ $\mathbf{S}_1$，$\mathbf{S}_2$ の子個体とする．

突然変異　あらかじめ設定された突然変異率に基づき，親個体・子個体に対して任意の人数（数名程度）分履修者の属するグループをランダムに入れ替える．

世代交代　解の評価はパレートランキング法 [Fonseca 98] を用い，他の解と比べ非劣解の集合はすべてタイ（同じ順位）として扱う．

この順位に基づき，設定された割合の個体をエリートとして扱い次世代に残す．さらにエリートでない個体からルーレット選択により，次世代に残す個体を選ぶ．

3.2 PSO の応用

上記の GA の過程の中で Juang [Juang 04] を踏まえ，毎回の世代交代の際のエリート個体群を粒子群とみなして PSO を適用する．この形のハイブリッド最適化を本稿では GAPSO と呼ぶ．

各個体が位置と速度の情報を持つとする．位置情報は前述の形で構成した $2n$ 次元ベクトル $\mathbf{x}$ とし，各個体が個体の最良位置 **pbest** と個体群全体の最良位置 **gbest** に近づくよう次式の

速度

$$\mathbf{V}_i^{k+1} = w\mathbf{V}_i^k + C_1 rand(\mathbf{pbest}_i - \mathbf{x}_i^k) + C_2 rand(\mathbf{gbest}_i - \mathbf{x}_i^k)$$

で速度 $\mathbf{V}$ を修正（ただし C_1，C_2，w を定数，$rand$ を $[0,1]$ の一様乱数，k を世代数とする）し，次の個体の位置候補 $\mathbf{x}_{ci}^{k+1}$ を

$$\mathbf{x}_{ci}^{k+1} = \mathbf{x}_i^k + \mathbf{V}_i^{k+1} \tag{1}$$

とする．ここで $\mathbf{x}_i^k$ の近傍を設定された回数分生成し，$\mathbf{x}_{ci}^{k+1}$ と最も類似度が高い近傍を $\mathbf{x}_i^{k+1}$ とする．

3.3 評価関数

次の 2 つの値を評価関数として用いる．

グループ間学修遂行分布の類似度 学修遂行の値のグループ内の分布についてカーネル密度推定を行った上で，すべてのグループについて 2 グループ間の総当たりで L_2 ノルムによる分布の類似度を求め，その平均を評価関数として用いる．

グループ間出席率分布の類似度 出席率の分布についても，上記の学修遂行分布と同じ方法で分布の類似度の平均を評価関数とする．

これらがトレードオフになっている可能性を考慮し，前述のように 1 つの最適解を求める方法ではなく，複数の非劣解集合を求める方法を本稿では採用する．

4. 性能評価・考察

次のアルゴリズムとの比較で，GAPSO を導入した最適化手法との比較を行った．

山登り法 各個体ごとに近傍を複数求め，その中の非劣解集合の中から次のループに用いる解をランダムに採用する．他個体との相互作用はない．

GA GA のみで解探索を行う．

PSO PSO のみで解探索を行う．

30 名のクラスを各 5 名の 6 グループに編成する形で評価を行った．学修遂行・出席率はダミーデータで，学修遂行は正規乱数で生成し，出席率は大学生の出席率の調査データ [ベネ] をもとに作成した．最適化のプログラムは OS X 10.11.6（Intel Core i7 2.8GHz，16GB RAM）上にて Ruby 2.4.2 で実行（カーネル密度推定は R 3.4.3 を呼び出し利用）し，各アルゴリズムとも 400 ループ分実行した．実行時間は山登り法が 9204 秒，GA が 8113 秒，PSO が 8809 秒，GAPSO が 7989 秒となった．

図 1 が各手法で共通に用いた初期の解候補集合で，解が左側に近づくほど，また下側に近づくほどよりよい解として扱う．図 2〜5 が 10 ループ後の解集合で，PSO が他と比べて高速に解候補集合全体が左下の最適に近い解に集まっていることがわかる．図 2〜5 が 400 ループ後の解集合で，GA は PSO と比べよい解を見つけるのが遅いものの多くの非劣解を見つけられる可能性があり，PSO は GA と比べよい解を見つけるのは速いものの解の多様性に問題がある可能性がある．両者の利点をある程度補っているのが GAPSO という見方もできるが，PSO 単体と比較すると解探索は遅いので，改善の余地を残しているといえる．また，GA と GAPSO を比較しても非劣解集合に含まれるグループ編成は他にも存在する可能性があり，より多くの非劣解集合を発見可能なアルゴリズムの改良も課題である．

5. 今後の課題

[鈴木 17] ではペアプログラミングによるコンピュータシミュレーション実習において，授業回ごとにペアを組み替える形で実習を進めていたが，このような授業では極力同じクラスの多くの他の履修者とともに活動する機会を設けたいため，以前同じグループだった相手とは再び組むのを避けたり，回数やクラスサイズの都合で再び組むことになってもできるだけ時間を置いたりする必要がある．このような履歴を解のランキングの中に組み込むことを検討している．

そして，GA の場合は対話的な最適化手法への拡張も可能である [高木 98]．つまり，最適化の過程で「この学生とこの学生が同じグループなのはまずい」「この学生とこの学生は同じグループである必要がある」といった介入を手動でユーザが行えるようなシステムの構成も可能ということである．このようなしくみを導入する以前の問題として，Web ベースなどで容易に利用可能なシステムの構築も，広く利用されることを考えれば必要といえる．また，広く利用されるという観点から考えれば，大学の授業以外での応用可能性も考えた上で，アルゴリズムとシステムの開発を進めることも重要である．

本稿では，遺伝的アルゴリズム・粒子群最適化ハイブリッド手法によるグループ編成の非劣解集合を求める多目的組合せ最適化アルゴリズムについて提案した．より効果的なグループワークが行える環境づくりの一環として，この知見に対してさらに考察を深め，アルゴリズムの改良を進め，グループワーク支援システム開発への応用を目指す．

参考文献

[Barkley 05] Barkley, E. F., Cross, K. P., and Major, C. H.: *Collaborative learning techniques: A handbook for college faculty*, Jossey-Bass, San Francisco, CA, USA (2005), 安永悟（監訳），協同学習の技法：大学教育の手引き，ナカニシヤ出版，京都 (2009)

[Cruz 14] Cruz, W. M. and Isotani, S.: Group Formation Algorithms in Collaborative Learning Contexts: A Systematic Mapping of the Literature, in *Proceedings of the 20th International Conference on Collaboration and Technology (CRIWG 2014)*, Lecture Notes in Computer Science 8658, pp. 199–214, Springer International Publishing, Santiago, Chile (2014)

[Fonseca 98] Fonseca, C. M. and Fleming, P. J.: Multiobjective optimization and multiple constraint handling with evolutionary algorithms. I. A unified formulation, *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, Vol. 28, No. 1, pp. 26–37 (1998)

[Goldberg 89] Goldberg, D. E.: *Genetic algorithms in search, optimization, and machine learning*, Addison-Wesley, Reading, MA, USA (1989)

[Griffin 12] Griffin, P. E., McGaw, B., and Care, E.: *Assessment and teaching of 21st century skills*, Springer, Dordrecht, the Netherlands (2012), 三宅なほみ (監訳), 益川 弘如, 望月 俊男 (編訳), 21 世紀型スキル：学びと評価の新たなかたち, 北大路書房, 京都, 2014

[濱中 13] 濱中 淳子 他：大衆化する大学：学生の多様性をどうみるか, シリーズ大学 2, 岩波書店, 東京 (2013)

[廣安 00] 廣安 知之, 三木 光範, 渡邊 真也：領域分割型多目的

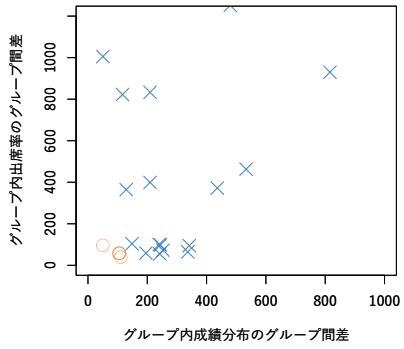


図 1　生成された初期解集合

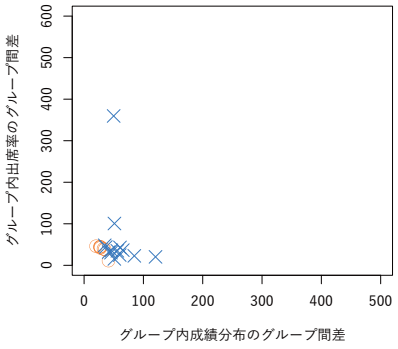


図 2　山登り法による 10 ループ後の個体の分布

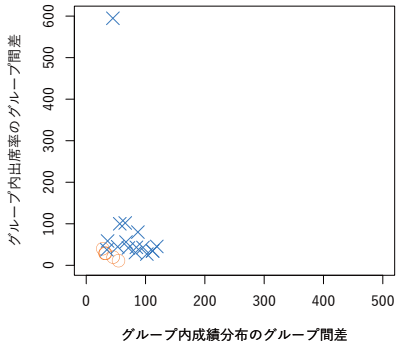


図 3　GA による 10 世代後の個体の分布

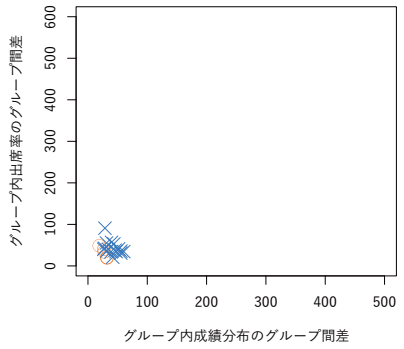


図 4　PSO による 10 ループ後の個体の分布

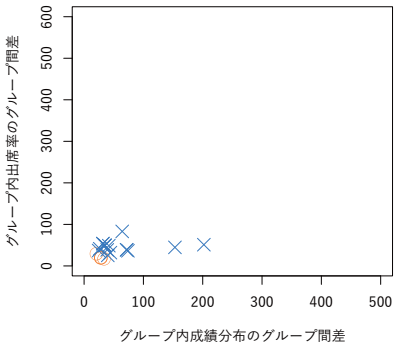


図 5　GAPSO による 10 世代後の個体の分布

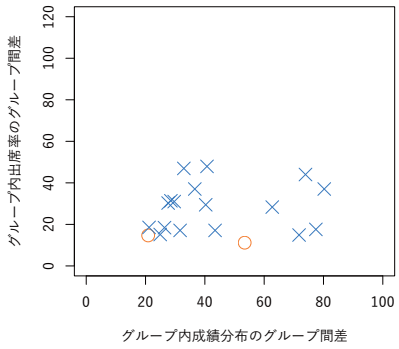


図 6　山登り法による 400 ループ後の個体の分布

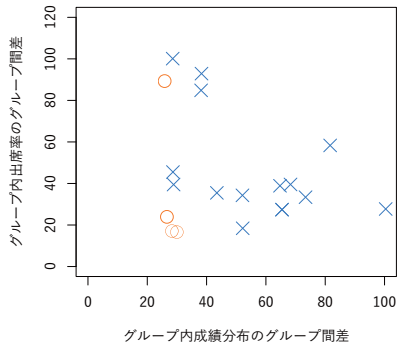


図 7　GA による 400 世代後の個体の分布

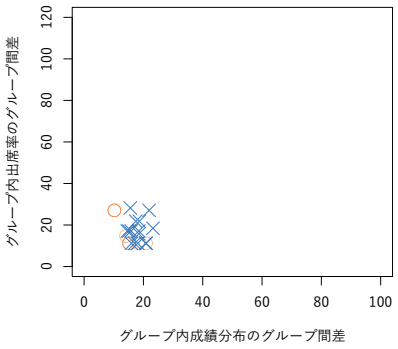


図 8　PSO による 400 ループ後の個体の分布

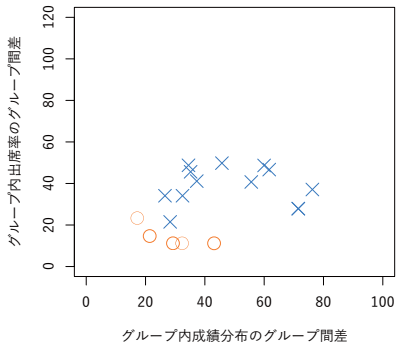


図 9　GAPSO による 400 世代後の個体の分布

遺伝的アルゴリズム, 情報処理学会論文誌：数理モデル化と応用, Vol. 41, No. SIG 7 (TOM 3) (2000)

[Juang 04] Juang, C.-F.: A hybrid of genetic algorithm and particle swarm optimization for recurrent network design, Vol. 34, pp. 997–1006 (2004)

[中野 17] 中野 民夫：学び合う場のつくり方：本当の学びへのファシリテーション, 岩波書店, 東京 (2017)

[ベネ] ベネッセ教育総合研究所高等教育研究室：第 2 回大学生の学習・生活実態調査報告書：`http://berd.benesse.jp/koutou/research/detail1.php?id=3159`（最終アクセス日：2017 年 12 月 24 日）

[斎藤 11] 斎藤 利通：粒子群最適化と非線形システム, 電子情報通信学会 基礎・境界ソサイエティ Fundamental Review, Vol. 5, No. 2 (2011)

[鈴木 17] 鈴木 聡, 廣川 佐千男：ペアプログラミングと反転授業を導入したコンピュータシミュレーション実習における履修

者の学習活動の分析, 日本教育工学会論文誌, Vol. 41, No. 3, pp. 255–269 (2017)

[高木 98] 高木 英行, 畝見 達夫, 寺野 隆雄：対話型進化計算法の研究動向, 人工知能学会誌, Vol. 13, No. 5, pp. 692–703 (1998)

[椿本 13] 椿本 弥生, 高橋 薫, 北村 智, 大辻 雄介, 鈴木 久, 山内 祐平：通信教育における意見文の協同推敲を支援するグループ編成方法の開発と評価, 日本教育工学会論文誌, Vol. 37, No. 3, pp. 255–267 (2013)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

事象関連電位P300計測のための フィードバック付きオドボール課題呈示法についての検討

A Study on Oddball Tasks with Feedback for Measuring P300.

小池忠 *1 Tadashi Koike　吉川大弘 *1 Tomohiro Yoshikawa　古橋武 *1 Takeshi Furuhashi

*1名古屋大学大学院工学研究科
Graduate School of Engineering Nagoya University

P300 is an Event-Related Potential (ERP), which is elicited as a positive component with a latency around 300ms after an infrequent stimulus appearing. We often use an oddball task for inducing P300. This paper carries out an experiment for measuring P300 in the oddball task with feedback. The author defined the feedback to show users whether their answers were correct or not. The result showed that the scores of "enjoying" and "not boring" in a semantic differential method improved more in oddball tasks with feedback than without feedback.

1. はじめに

P300 とは，二種類以上の刺激を呈示した際，意識している低頻度の刺激の呈示約 300ms 後に生じる陽性電位のことである．P300 を計測するための課題として，オドボール課題が用いられる．オドボール課題とは，頻度の異なる刺激が繰り返し呈示される中で，低頻度の刺激に意識を向ける課題であり，筆者らではこれまで，黄色い円を用いた視覚刺激を利用してきた [三輪 18][高倉 17]．ここでは，大きな円を高頻度の刺激（スタンダード刺激），小さな円を低頻度の刺激（ターゲット刺激）として，ターゲット刺激呈示時にボタン押すように被験者に指示している．しかし，従来のオドボール課題は，単調で飽きやすいという問題があった．飽きてしまうと脳波の振幅が小さくなり [入戸野 06]，P300 計測の妨げになる．そこで，オドボール課題に対する飽きない工夫として，P300 を計測可能なゲームの開発を，本研究の最終的な目標とする．しかし，ゲームには様々な要素があり，その全ての効果を一度に検証するのは難しい．そこで本稿では，要素の一つであるフィードバックに着目し，オドボール課題におけるフィードバックの効果に関する検討を行う．

2. 実験

2.1 フィードバックありオドボール課題

フィードバックありのオドボール課題では，図 1 に示すように，刺激呈示の後にフィードバック時間を 200ms 設ける．呈示刺激がターゲット刺激で，ボタンを押していた場合は“○”を画面に表示する．呈示刺激がターゲット刺激にもかかわらずボタンを押さなかった，あるいは，スタンダード刺激にもかかわらずボタンを押してしまった場合は“×”を画面に表示する．

2.2 実験概要

視覚オドボール課題を用いて，被験者の興味の持続に対するフィードバックの効果についての実験と検討を行った．被験者は健康な 20 代男性 12 名で，電極の位置は国際 10-20 法 [H.H.Jasper 58] に則り，1 電極 (Pz)，及び基準電極として A_1,A_2（耳朶）に電極を装着した．サンプリング周波数を

連絡先: 小池忠，名古屋大学大学院工学研究科，名古屋市千種区不老町工学部 3 号館 301 号室，052-789-2793，052-789-3166，koike@cmplx.cse.nagoya-u.ac.jp

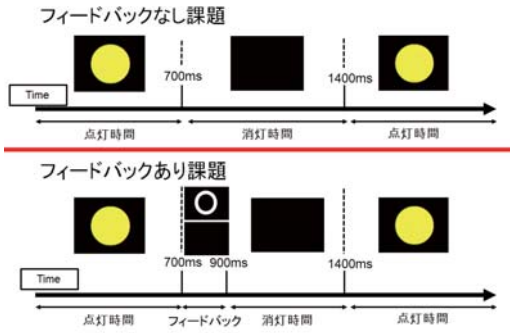


図 1: 使用するオドボール課題の流れ

1000Hz として計測を行った．刺激点灯時間は 700ms，刺激消灯時間は 700ms とした．刺激呈示数は 1 セット当たりターゲット刺激 22 点灯，スタンダード刺激 88 点灯とした．ターゲット刺激を，スタンダード刺激に対する半径比が 90%，70%，50%となるように 3 種類の難易度を設定し，各課題（フィードバックあり／なし），各半径比（3 種類）で被験者 1 人あたり計 6 セット行った．また順序効果を考慮して各被験者の課題の順番を設定した．被験者の興味が持続しているかの評価には Semantic Differential 法（SD 法）を用いた．SD 法の評価のため，アンケートを 1 セットごとに実施し，全 10 項目を 1 から 7 の 7 段階で評価をしてもらった．この 10 項目のうち，興味の持続に関する“集中できる”，“疲れない”，“楽しい”，“飽きない”の 4 項目を評価の対象とした．また，各被験者の加算平均波形から，P300 が計測できているかを目視で確認し，両課題間の頂点潜時と振幅の変化についても確認した．P300 の頂点潜時とは刺激呈示から P300 の頂点までの時間であり，P300 の振幅とは P300 の頂点の電位である．

2.3 結果と考察

SD 法のスコア

全被験者の SD 法のスコアの平均値を図 2 に示す．図 2 より，“集中できる”，“楽しい”，“飽きない”の 3 項目において，フィードバックあり課題のスコアの方がフィードバックなし課題のスコアよりも高いことがわかる．また，4 項目をそれぞれ対応のある t 検定で検定したところ，“楽しい”，“飽きない”の 2 項目で統計的有意差が認められた (それぞれ*p=0.000，*p=0.002)．

これにより，オドボール課題でフィードバックを行うことの効果が表れたといえる．

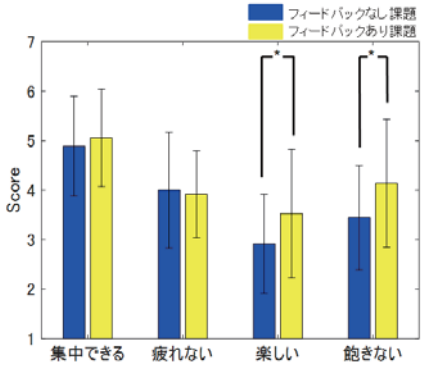


図 2: 全難易度を統合した SD 法のスコアの平均

難易度別にみた SD 法のスコアの平均値を図 3 に示す．図 3 より，難易度 90 におけるフィードバックあり課題の SD 法のスコアが，4 つの項目全てで高い傾向にあることがわかる．また，各難易度，各 4 項目それぞれに対して対応のある t 検定で検定したところ，難易度 90 の“楽しい”という項目において，統計的有意差が認められた（*p=0.002）．難易度 90 の課題を終えた直後のアンケートの自由欄には，「×がでると次頑張ろうと思う」「間違えると悔しいので熱中できる」という意見があったため，間違えたときの悔しい気持ちが興味をひいている可能性が示唆された．

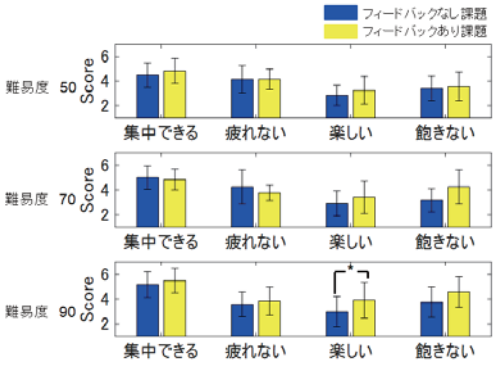


図 3: 難易度別にみた SD 法のスコアの平均

頂点潜時と振幅

例として，ある一人の被験者の加算平均波形を図 4 に示す．図 4 より，フィードバックのある課題から得られた脳波からも，P300 が計測できていることがわかった．他の 11 名についても同様に計測できていた．全被験者の頂点潜時と振幅の平均を図 5 に示す．図 5 より，フィードバックがある場合とない場合で頂点潜時と振幅に差がほとんどないことがわかる．確認のために，頂点潜時と振幅の全難易度の平均に対して対応のある t 検定で検定したところ，統計的有意差は認められなかった（それぞれ p=0.332，p=0.484）．

3. まとめ

本稿では，オドボール課題におけるフィードバックの効果について検討を行い，フィードバックありの課題が，なしの課題

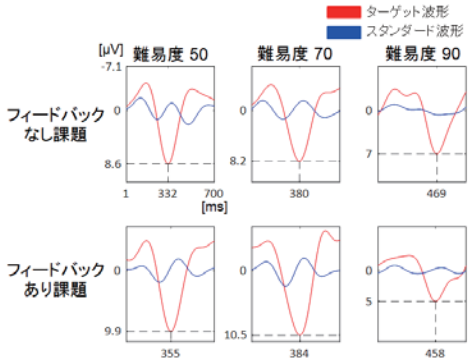


図 4: ある一人の被験者の加算平均波形

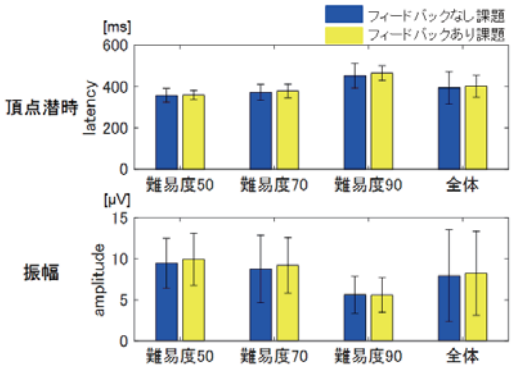


図 5: 全被験者の頂点潜時と振幅の平均

と比べて，被験者が“楽しい”，“飽きない”と感じることを確認した．また，両課題間で頂点潜時と振幅に大きな差がないことがわかった．今後は，ゲームに関する様々な要素を個別に検討し，最終的には P300 を計測できるゲームの開発を行っていく予定である．なお本研究の一部は，独立行政法人科学技術振興機構 (JST) の研究成果展開事業「センター・オブ・イノベーション (COI) プログラム」の支援によって行われた．

参考文献

[H.H.Jasper 58] H.H.Jasper, : The ten-twenty electrode system of the international federation, *Electroencephalography and clinical neurophysiology*, Vol. 10, No. 2, pp. 371–375 (1958)

[高倉 17] 高倉 健太郎 : 脳波に含まれる P300 の工学的応用に関する研究, Master's thesis, 名古屋大学大学院工学研究科計算理工学専攻 (2017)

[三輪 18] 三輪 晃暉 : 脳波データを用いた MMSE スコアの推定に関する検討, 電子情報通信学会技術研究報告= IEICE technical report: 信学技報, Vol. 117, No. 417, pp. 5–10 (2018)

[入戸野 06] 入戸野 宏 : 映像に対する注意を測る-事象関連電位を用いたプローブ刺激法の応用例-, 生理心理学と精神生理学, Vol. 24, No. 1, pp. 5–18 (2006)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

状況論的知能の計算論的理解のための構成・実践型研究手法

Constructive and Practical Research Methodology for Computational Understanding of Situated Intelligence

永田 鴻流 *1　黒木 康能 *2　岡田 昌也 *3
Koryu Nagata　Yasutaka Kuroki　Masaya Okada

*1静岡大学情報学部情報科学科
Department of Computer Science, Faculty of Informatics, Shizuoka University

*2静岡大学大学院総合科学技術研究科情報学専攻
Department of Informatics, Graduate School of Integrated Science and Technology, Shizuoka University

*3静岡大学学術院情報学領域行動情報学系列
Division of Behavior Informatics, College of Informatics, Academic Institute, Shizuoka University

A person in the world acquires the situation information that constraints possible range of behavior generation, and then determines proper behavior. We consider "situated intelligence" as the generation of behavior adapted to each of surrounding situations. To computationally understand the process mechanism of situated intelligence, our methodology is proposed to model and examine a person as a robotic system. Grounded on making an ecologically valid setting of research, our methodology repeats the following: (1) constructing a probabilistic model of situated intelligence by the parameters of behavior and situation, and (2) practically examining a new hypothesis by practicing the model in a real-world setting.

1. 緒論

一般的に人は，実世界の未知な状況の中でも以前の状況で得た知識をもとに，適応的に行動できる [香川 11]．この「これまで経験していない新しい状況に対応し，適応する能力」は，恒常的に社会的学習を行っている人が有する知能の本質であると考えられている [鈴木 06]．この多様な状況のそれぞれに適応した行動を生成することを，本稿では「状況論的知能の発現」と考える．例えば，以下がその例である．

看護行動　「今」の状況に適応する

ある病棟において，手の空いた状況にある看護師が，忙しい状況にある他の看護師に気づき，その人を助ける行動を取ることによって，病棟全体としての業務の効率化を行う．

運転行動　「未来」の状況にあらかじめ適応する

実世界の公道において，小学生が車道脇にいる状況にあれば，運転者は，飛び出しを予測し，ブレーキ操作ができる行動の状態とする．

本研究は，「人は行動の選択肢が膨大にある実世界の状況においても，解釈した状況情報から行動生成に関する制約条件を見出し，この制約条件の下で適切な行動を生成できる」という着想を提出し，実世界における状況論的知能の発現過程のモデル化・評価を行う研究方法論を提案する．具体的には，本研究は実世界における状況論的知能が発現する過程を，図 1 のようにモデル化する．人は，感覚器の特性に由来して課される「観測に関する制約」(図 1 C1) の下で，他者や物へ視線配布行動などを行い実世界 (i) を観測する．観測により，事物の状態を知覚・認知して実世界情報 (ii) として抽出する．この実世界情報と，「状況解釈に関する制約条件」(C2) をもとにして，状況情報 (iii) を取得する．解釈した状況情報と，ある状況における「行動生成に関する制約条件」(C3) によって，実世界での膨大な行動の中からいくつかの取り得る行動列を生成する (iv)．人は，その行動列の中から，それぞれを行動として実世界に出力したときの状況変化について予測 (v) する．その予測結果 (vi; C4) と制約 C3 を統合した行動生成の制約に基づき，適切なものを選択して行動 (vii) する．行動 (vii) は実世界 (i) の状況を変化させ，人はその状況変化を再度観測して行動の選択と実行を繰り返す．例えば，先の運転の例であれば，小学生が車道脇にいるという状況が行動生成に関する制約条件 (C3) となり，(あ) アクセルを緩めて減速する，(い) ハンドルを切って大きく避ける，(う) いつでも停止できるようブレーキに足をかける，という行動列を生成する (iv)．ここで，小学生の急な飛び出しや対向車の状況変化などの予測 (v) を行い，その予測結果 (vi; C4) により，(あ) と (い) の行動は抑制され，(う) の行動が選択される (vii)．

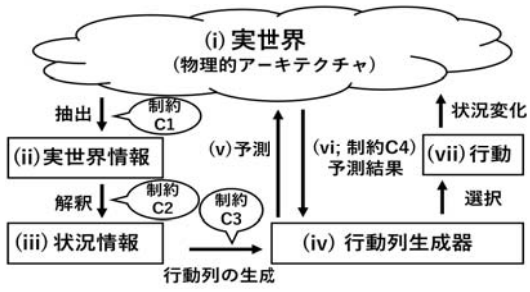


図 1: モデル：実世界における状況論的知能の発現過程

すなわち，図 1 より状況論的知能の発現過程において，以下のような関数関係が仮定できる．

1. 実世界情報=f(実世界，観測の制約)
2. 状況情報=g(実世界情報，状況解釈の制約)
3. 行動=h(状況情報，行動生成の制約)

本研究は，人がより適応的な知能を発現するためには，上記 1〜3 の関数関係およびそれぞれの制約条件の学習を個人ごとに行わなければならないと考える．ただし，個人の知識は多様かつ人の内部に閉じていて，さらに，情報処理の対象となる実世界情報は多様かつ複雑である．このような多様性と複雑性を

連絡先: 岡田 昌也，静岡大学学術院情報学領域行動情報学系列，〒 432-8011，浜松市中区城北 3-5-1，m.okada@acm.org

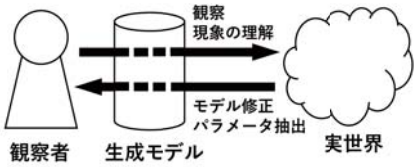


図 2: 「実世界での人由来の信号生成モデル」を通した観察

系の構成要素とする過程を分析・理解するための手法としては，(1) 行動を中心として，上記 1〜3 の関数関係に示す人の知能についての計算論的なモデルを仮説として構成すること，(2) そのモデルを実践の場で検討し，人の行動を状況変動のダイナミクスを考慮した視点で観察すること，の二点が必要である．

2. 実世界指向型研究フレームワーク

一般にロボットは，センサから取得される各種の実世界情報を，ロボットの内部で解釈し，これを制御情報に変換したのち，アクチュエータを介して行動情報として出力することで，駆動される．これは，実世界という外部空間も含めて，ロボティクスシステムと見立てる空間ロボティクスの構成問題と捉えられる．同様に，実世界で活動する人も，感覚器官から取得される実世界情報を，人の内部で解釈し，身体機能というアクチュエータを介して，駆動されると考えられる．すなわち，本研究は，実世界で活動する人を，空間ロボティクスのシステムと見立てることができると考え，特に，人のセンシング，プロセッシング，アクチュエーションの全てが実世界にグランディングしていることから，実世界指向の研究方法論の開発をもとに状況論的知能の探求を行うものである．

「見る」という行為は，たんに物質に反射した光が網膜に到達する以上のことであり，我々は，網膜上の映像を「解釈」している [森田 10]．ここで，何を観察するか，また，観察された結果をどう解釈するかは，人がもつ何らかの理論に依存しており，その理論が観察のフィルターとなる（観察の理論負荷性）[森田 10]．新しい発見は，適切な予期によってこそ可能であることから [森田 10]，本研究では，この予期を，計算モデルによって表現し，この計算モデルを理論のフィルターとして実世界を観察し，また，その実世界の観察を通してそのフィルターを修正するものである (図 2)．特に，本研究では，「実世界の中で人由来の信号が生成される仕組み」に関して生成モデルを仮定し，これを逐次的に修正することによって，状況論的知能の発現について，計算論的に理解することに繋げる．例えば，計算モデルの中で仮定した各パラメータの値やその変動が，実世界においては実際にどのように観察されるのかを確認することで，モデル表現のロバストネスについて理解を得る．さらには，「計算モデルの中で事前に想定されなかったが，実世界の中の現象の記述力に優れた潜在的なパラメータ」を，実世界の中での観察において抽出し，これを計算モデルの修正に反映する．これは，生態学的妥当性のある観測状況により，計算モデルの構成・修正を行う手法であり，構成と実践を基軸とする．具体的手続きは，定性的な仮説の生成・検証と，数理・確率的な仮説の表現・修正の，二側面のアプローチの融合であり，以下に詳述する (図 3)．

P1. 仮説立案：詳細な計算モデルを構築するために実世界における人の行動を参与観察などで分析し，その厚い状況記述データを参考に，人の行動の成り立ちについて定性的な仮説を立てる．

P2. 計算論的表現：P1 の仮説をもとに，人の知能について行動を中心とした生成モデルを，数理・確率的に表現する．

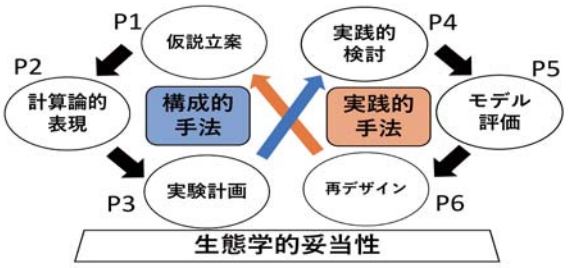


図 3: 実世界指向型の研究方法論：構成・実践的知能理解

P3. 実験計画：P1 の定性的な仮説および P2 の計算論的なモデルという質の異なる仮説を融合した仮説を設計し，その上で期待される人の行動が観測できるであろう実験を計画する．

P4. 実践的検討：実世界で実験を行い，「実際の状況における」人の行動を，P3 の仮説を観察のフィルターとして用いて吟味して，生態学的妥当性の高い実践的知見を得る．

P5. モデル評価：P3 の実験計画に基づき取得された定量データをもとに，構成したモデルの客観的な妥当性と限界を評価する．

P6. 再デザイン：人の行動をより適切に表現できるようモデルの修正点を明らかにし，更なる仮説立案 (P1) に繋げる．

以上のフレームワークに基づき，現在，研究者が参加者として参与し，実践の内部から他参加者の行動を分析する参与観察によって，実世界での人の知能発現についての知見を蓄積する研究を進めている．また，人の頭部に着けたカメラからの一人称映像によって視線配布行動 (図 1(ii)) のデータを取得することや，身体に着けたセンサから加速度や角速度を計測して，環境に対する作用 (vii) を分析する計測環境を開発中である．さらに，人の知識について階層性を仮定して音声記録の会話データなどから知識段階の推定を行い，知識データ，行動データ，環境作用データを計算構造の中で統合したものによって，人の知能について構造化する手法を開発している．

3. 結論

本研究において，人による状況論的知能の学習とは，「状況」の関数として発現する「行動」に関しての関数関係を適応的に学習する問題だと考える．本稿では，その計算構造を明らかにするために，人の知能発現状況に関して生態学的妥当性を有する実験環境において，(1) 実世界における人の知能について，行動と状況の視点で確率・数理モデルを構成すること，(2) そのモデルを実践的に検証して得られた知見から新たな仮説を生成すること，の二点を繰り返すことが必要であると述べた．現在，このフレームワークを基盤にして，状況論的知能についての計算論的な理解を深める研究を進めている．

謝辞

静岡大学情報学部/総合科学技術研究科 岡田研究室の皆様にいただいた議論に感謝いたします．本研究は，JSPS 科研費 16K00271 の助成による．

参考文献

[香川 11] 香川 秀太：状況論の拡大：状況的学習，文脈横断，そして共同体間の「境界」を問う議論へ，認知科学，Vol. 18，No. 4，pp. 604-623(2011)．

[鈴木 06] 鈴木 宏昭:知性の創発と起源，オーム社，東京 (2006)．

[森田 10] 森田 邦久：理系人に役立つ科学哲学，化学同人，京都 (2010)．

Oral presentation | General Session | [General Session] 13. AI Application

[1M2] [General Session] 13. AI Application

座長:佐々木 耀一（日本電気株式会社）

Tue. Jun 5, 2018 3:20 PM - 5:00 PM Room M (2F Amethyst Hall Hoo)

[1M2-01] Automatic Planning of Electrical Isolation with Deep Learning in Nuclear Power Plant

○Susumu Naito[1], Kei Takakura[1], Hiroki Shiba[1] （1. TOSHIBA ENERGY SYSTEMS &SOLUTIONS CORPORATION）

3:20 PM - 3:40 PM

[1M2-02] Approach to the transfer of quality control skills at the construction site using eye-gazing data

○Junya Morita[1], Nao Fujimoto[1], Katsumi Yanagita[1] （1. KAJIMA Corporation）

3:40 PM - 4:00 PM

[1M2-03] Toward Supporting Decision Making for Flood Control in a Hydroelectric Dam by Reinforcement Learning and Symbol Grounding

○Yukiko Tanaka[1,2], Takuya Hiraoka[1,2], Takashi Onishi[1,2], Yoshimasa Tsuruoka[2,3], Shohei Takino[4], Yosuke Matsumoto[5] （1. NEC Security Research Laboratories, 2. National Institute of Advanced Industrial Science and Technology, Artificial Intelligence Research Center, 3. The University of Tokyo, 4. Tokyo Electric Power Company Holdings, Inc., 5. Tokyo Electric Power Services Co., Ltd.）

4:00 PM - 4:20 PM

[1M2-04] Algorithmic Detection of Quote Spoofing in Stock Exchange Market Using Probability Density Ratio Estimation

○Kenichi Nakahara[1], Fumiya Shimada[1], Kunihiro Miyazaki[1], Masayuki Sekine[1], Shouhei Ohsawa[1], Makoto Ohshima[2], Yutaka Matsuo[1] （1. The University of Tokyo, 2. DSB Co., Ltd.）

4:20 PM - 4:40 PM

[1M2-05] Proposal of a business assisting framework with multiple chatbots

○Keisuke Tsunoda[1], Masahiro Okazaki[1], Ryuto Koyanagi[1], Fujie Nagamori[1], Daisuke Minoura[1] （1. NTT Comware Corporation）

4:40 PM - 5:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

原子力発電所の電気系アイソレーション計画の深層学習による自動生成

Automatic Planning of Electrical Isolation with Deep Learning in Nuclear Power Plant

内藤 晋[*1] 高倉 啓[*1] 芝 広樹[*1]
Susumu Naito Kei Takakura Hiroki Shiba

[*1] 東芝エネルギーシステムズ(株)
Toshiba Energy Systems & Solutions Corporation

We study automatic planning of electrical isolation with deep learning, one of applications of artificial intelligence to enhance operation and maintenance. Currently, a skilled engineer plans electrical isolation procedure with hundreds of the circuit diagrams and the related documents, taking man-hours. If this task becomes automatic, it is very efficient. A major issue of the automatic planning is much calculation time of electrical circuit simulator, searching billions of electrical conducting paths. We performed a simplified case study of the electrical isolation. We applied a deep neural network (DNN) for dropping in the calculation time. We trained the responses of the circuit simulator to the DNN, constructing an optimized path search algorithm in the DNN. The calculation time of the DNN was shorter by a factor of 560, compared with that of the electrical circuit simulator. There was no significant difference in accuracy between Multi-Layer Perceptron and Graph Convolutional Network.

1. はじめに

現在、人工知能技術は、高性能かつ低コストの計算機環境と、使い易いコーディングツールのおかげで容易に利用できる。我々は原子力発電所のオペレーション&メンテナンス高度化のために、人工知能を活用した様々なアプリケーションを開発している。現場支援においては、深層学習を用いた電気系アイソレーション計画の自動生成を試みている[1]。電気系アイソレーションは、検査／工事対象機器を電気的に隔離する作業であり、感電や他の系統および機器の機能喪失等の誤動作・誤不動作を起こすことなく、実施する必要がある。現在、熟練した技術者が、数百もの回路図や関連図書を用いて、工数をかけてアイソレーション手順の計画を作成している。この作業が自動化されれば非常に効率的である。

自動計画には二つの課題がある。一つは、膨大な電気導通経路を全て探索するためには、汎用の電気回路シミュレータでは非常に計算時間がかかること。もう一つは、作業のし易さなどの曖昧な情報の解釈である。深層学習はこれらの解決に役立つ。なぜなら深層学習は、複雑な情報からより良いルールを見つける手段である。深層学習には、高精度な予測と分類のための適用例が数多くあるが[2-5]、電気回路、特に計算の高速化の例はない。

我々は、電気系アイソレーションの簡略化したケーススタディを実施した。深層ニューラルネットワーク(DNN)を計算時間削減に適用し、効率的な経路探索アルゴリズムをDNNの内部に構築した。計算時間削減においては、多層パーセプトロン(Multi-Layer Perceptron : MLP)を適用し、さらに、より高速化を狙い、グラフ畳み込みネットワーク(Graph Convolutional Network : GCN)の適用を試みた。また深層Qネットワーク(DQN)を曖昧な情報の解釈に適用した。DQNは、機器配置図、線量、および熱中症を防ぐための湿球温度(WBGT)の値による作業負荷の観点から、アイソレーション手順を最適化した。最終結果の正しさは人が確認する必要があるが、大量の情報から手順を導く作業とは異なり、この作業は容易である。本論文では、前者の計算時間削減を対象とし、次節以降、詳細を述べる。

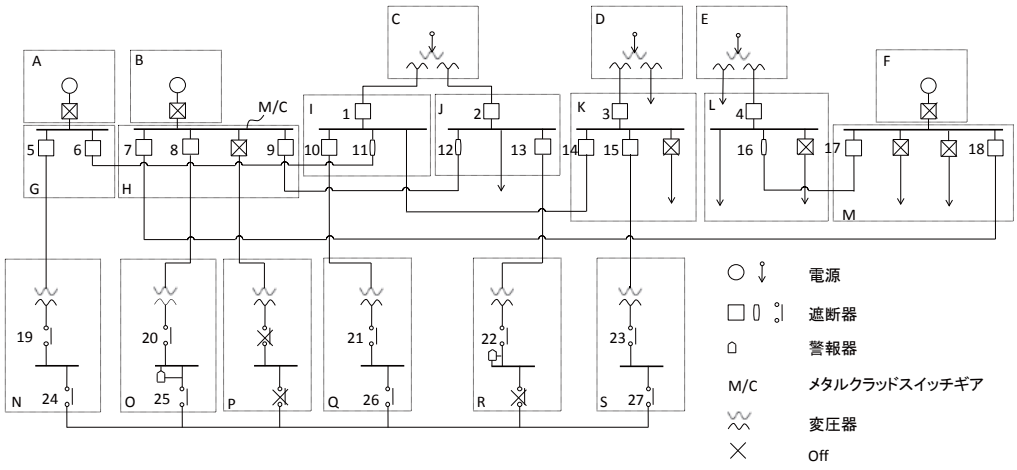


図 1. モデルケース図

連絡先: 内藤 晋、東芝エネルギーシステムズ(株)
横浜市磯子区新杉田町8、TEL:045-770-2379、
E-mail: susumu.naito@toshiba.co.jp

2. 方法論とケーススタディ

2.1 全体概要

図1と図2にモデルケース図と自動計画手順を示す。モデルケース図は、単線結線図であり、3 つの電源、27 の遮断器、2 つのアラームを含む 76 の機器で構成される。A～S のセクションは各機器の位置を示す。検査対象はメタルクラッドスイッチギア(M/C)であり、検査する前に警報を鳴らすことなく隔離する必要がある。自動計画手順を以下に説明する。最初に、単線結線図から、M/C を隔離する遮断器オン/オフパターンを導出する。第 2 に、作業負荷の観点からパターンを選別する。推奨されるパターンとその手順を導出する。計算環境は、High Performance Computer (Intel Xeon E5-2690、RAM:192GB、GPU:Tesla K20Xm)と“TensorFlow” [6]を使用した。

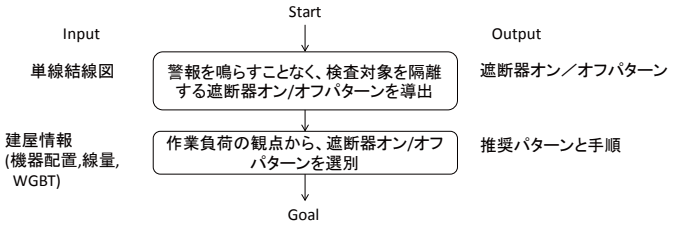


図 2. 自動計画手順

2.2 無警報で電気遮断する遮断器オン／オフパターンの導出

警報のない状態で検査対象物を隔離する遮断器オン/オフパターンは、電気導通経路の探索機能を有する従来の電気回路シミュレータを用いて導き出すことができる。しかしながら膨大な数の遮断器オン/オフパターンが存在するため、計算時間がかかる。ケーススタディでは、27 個のブレーカが 2^{27} のオン/オフパターンを生成する。シミュレータは、すべてを計算し、検査対象物を隔離するパターンを見つける必要がある。高速な計算が必要である。深層学習が、電気経路探索アルゴリズムを最適化し、警報なしでターゲットを隔離する遮断器オン/オフパターンの導出に特化したアルゴリズムを導出することを期待した。

深層学習は、学習データから論理を自動的に構築する能力を有する。我々は、深層ニューラルネットワーク(DNN)に回路シミュレータの応答を学習させた。図 3 に、使用した DNN 図を示す。6 層の隠れ層と各層 300 ユニットの多層パーセプトロン(MLP)を使用した。現在のところ、一般化された選択方法が存在しないため[7-9]、隠れ層とユニット数は経験的に選択した。活性化関数は ReLU を使用した。入力は、27 個の遮断器(x1, x2, x3, ...,x27)の遮断器オン/オフパターンであり、遮断器 i のオン／オフ状態は xi = 0 or 1 で表される。出力は、検査対象 y1 と 2 つの警報器 y2/y3 の導通状態(y1, y2, y3)であり、導通状態は、yi = 0 or 1 で表される。学習データと検証データは(x1, .., x27)と(y1, y2, y3)の組である。学習データと検証データは、回路シミュレータにランダムに遮断器オン/オフパターンを入力して作成した。DNN が計算を高速化しても、学習と検証データの作成に多くの時間を要すると意味がない。DNN の学習には、学習データ 12,000 個と検証データ 413,000 を使用した。これは、合計 2^{27} パターンのわずか 0.01%と 0.3%である。

図 4 に、12,000 の学習データに対する学習時間と 413,000 の検証データに対する DNN の正答率を示す(学習係数:0.03、ドロップアウト:無)。正答率は、急速に上昇し、学習開始 1 分後に 99％を超えた。学習時間は非常に短時間だった。413,000 の検証データを用いて学習済み DNN の計算時間を測定した。1 つの遮断器オン/オフパターン(x1, x2, x3, ..., x27)に対する導電状態パターン(y1, y2, y3)の平均計算時間は 0.0011 秒であった。同じコンピュータ環境下で、幅優先探索(BFS)を使用した回路シミュレータでは計算時間は 0.95 秒だった。学習済み DNN は回路シミュレータよりも 560 倍高速だった。

学習済み DNN を使用し、すべての遮断器オン/オフパターン(2^{27} パターン)について、(y1、y2、y3)を計算し、無警報で検査対象を隔離する遮断器オン/オフパターン、即ち(y1、y2、y3)=(0,1,1)となるパターンを導出した。図 5 は、オフにする遮断器の数と、導出されたパターンの数を示す。オフにする遮断器の数は 3～19 の範囲であった。パターンの数は 10 で最大であった。このケーススタディでは合計 798,217 パターンが得られた。多数の隔離パターンが存在し、スクリーニングする必要がある。スクリーニングは、単純に遮断器オフ数が少ないものにする等、様々な観点がありえる。作業のし易さの観点で、深層強化学習 DQN の適用を試みており[1]、方法論は構築できている。

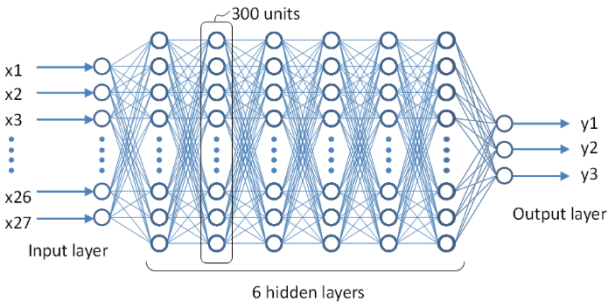


図 3. 深層ニューラルネットワーク(DNN)の構成

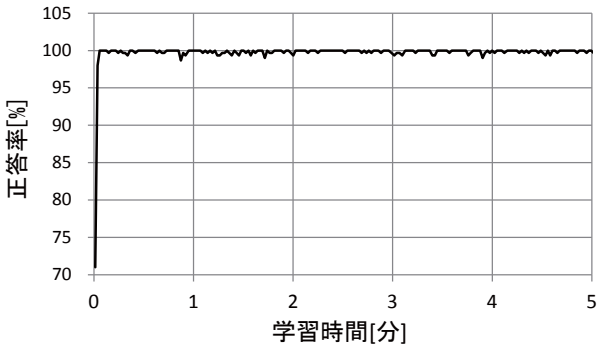


図 4. 学習時間 vs. 正答率

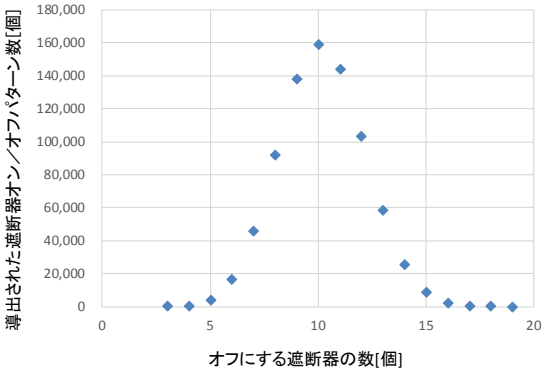


図 5. オフにする遮断器数 vs. 無警報で検査対象を隔離する遮断器オン/オフパターン数

2.3 グラフ畳み込みネットワークの適用

前節で、学習済み DNN は正答率 99%超が得られた。計算速度は DNN の規模(隠れ層の数、ユニット数)に依存するので、小規模でも良い正答率が得られるなら、更なる高速化が図れる。そこで、グラフ畳み込みネットワーク(GCN)の適用を試みた。

GCN は、グラフをそのまま入力できる深層学習ネットワークである。既知のルールを最初からネットワークに反映して、精度と速度の向上を狙う。近年活発な研究がされており、化学の分子構造をグラフにして分子の性質を従来手法よりも 30 万倍高速に予測した例[10]や、知識ベースでのデータの関係性に用いて関係性の予測精度向上[11]など、研究成果が発表されている。本ケースでは Schlichtkrull らの手法 [11]をアレンジして、図1の単線結線図へ適用した。グラフは、機器をノード(節)、配線をエッジ(辺)をとした。エッジの重みをパラメータにし、各ノードの近接エッジの重みを畳み込み演算して、多層ニューラルネットワークの次の層へと連結した。

単線結線図へのアレンジの詳細を述べる。ノード $v_i \in V$、エッジ $(v_i, r, v_j) \in E$、エッジの種類 $r \in R$ とした、グラフ $G = (V, E, R)$ に対し、GCN の各層は、次式(1)の構成をとる[10]。

$$h_i^{(l+1)} = \sigma\left(\sum_{r\in R}\sum_{j\in N_i^r}\frac{1}{c_{i,r}}W_r^{(l)}h_j^{(l)} + W_0^{(l)}h_i^{(l)}\right) \qquad (1)$$

ここで、$h_i^{(l)} \in R^{d(l)}$ はノード v_i の l 層目の隠れ層の状態、$d^{(l)}$ は l 層目の隠れ層の次元、σ は活性化関数、N_i^r は $r \in R$ 関係下でのノード i の隣接ノード、$c_{i,r}$ は問題特有の正規化定数である。$W_r^{(l)}$ は次式(2)で表される。

$$W_r^{(l)} = \sum_{b=1}^{B} a_{rb}^{(l)} V_b^{(l)} \qquad (2)$$

$W_r^{(l)}$ は、基底変換 $V_b^{(l)} \in R^{d(l+1)\times d(l)}$ と係数 $a_{rb}^{(l)}$ (スカラー)の積で表される。B は基底関数の数を表す。単線結線図では、このGCNを以下のアレンジで実装させた。

- 電気回路では、各機器の特徴はユニークに決まっているため、中間プロセスとして自己符号化器等による特徴量抽出は行わない。
- ノード(機器)とエッジ(配線)情報が隠れ層の何処へ行ったのかを明確に同定して、機器同士の結線関係をGCN全層において正確に反映させるために、各層のユニット数は機器数と一致させる。

これらは、式(2)において、基底変換を恒等写像としてとり扱うことでGCNに導入し、

B＝入力層の入力チャンネル数、$V_b^{(l)}$ は単位行列、

とした。

GCN は、入力 76 チャンネル(=機器数)、2層の隠れ層と各層76 ユニットで構成した。比較用の多層パーセプトロン(MLP)も同じ構成とした。これらは、前節で使用した 6 層の隠れ層と各層 300 ユニットの MLP に比べて、小規模の構成となっている。ケーススタディに対する正答率は、GCN が 91.6%、MLP が 92.0%となった。図6にオフする遮断器数と正答率の関係をしめす。GCN と MLP はほぼ同一の正答率となっており、有意な差はなかった。また、GCN は、6層の隠れ層で構成した場合についても試評価を行い、正答率 99.7%と非常に高い値が得られたが、MLP もほぼ同じ値となった。

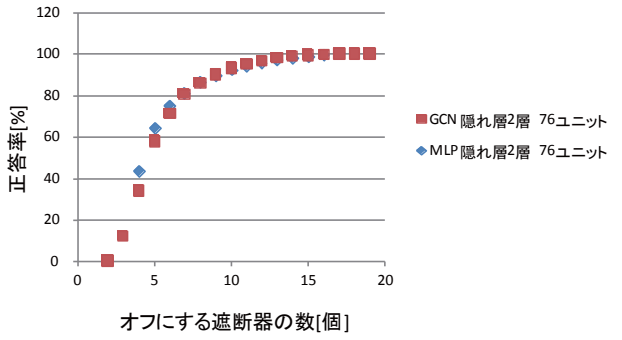


図 6. GCN と MLP の小規模構成での正答率の比較

3. 考察と結論

我々は、深層学習を用いた電気系アイソレーション計画の自動生成に関し、簡略化したケーススタディを実施した。深層ニューラルネットワーク(DNN)に回路シミュレータの応答を学習させ、DNN に最適化された経路探索アルゴリズムを構築した。 DNN の計算時間は、電気回路シミュレータの場合と比較して、560 倍短縮された。

計算時間がなぜ短縮したのかは、DNN の内部がブラックボックス状態ゆえ、明確には分からないが、もともとは複雑な経路探索の問題であったのが、DNN によって取り扱う問題の性質が変わり、画像認識などと似た、パターン認識の問題に置き換わったと推測する。

学習済み DNN は稀に間違いを起こす。ケーススタディでは正答率は 99%以上だったが、100%にはならなかった。実運用では、DNN が導出した結果を、作業のし易さ等でスクリーニングしたのち、残った最終結果の正しさを人が確認する必要がある。しかしながら、膨大な数の遮断器オン/オフパターンを確認するのとは異なり、最終結果、すなわち 1 つまたは複数の推奨されるアイソレーション手順を人が確認することは容易である。

GCN はケーススタディにおいては MLP と有意差はなかった。図1の単線結線図は、機器と配線のルールが単純明快であるので、小規模の MLP でも容易にルールを学習・発見でき、GCN のメリットが活かせなかったのではと推測する。

我々は、原子力発電所のオペレーション＆メンテナンス高度化の一つとして、深層学習による電気系アイソレーションの自動計画を報告した。この研究は、現場作業の効率化を目的としたものであり、また、火災等での電気系統の一部喪失によるプラント全体の影響評価等にも発展できる。我々は、継続して原子力発電所への人工知能応用の研究開発を進める。

本論文に掲載の商品の名称は、それぞれ各社が商標として使用している場合があります。

参考文献

1. 1. S. NAITO et al., “Applications of Data Mining Technology to Enhance O&M: Automatic Planning of Electrical Isolation with Deep Learning,” *10th International Conference on Nuclear Plant Instrumentation, Control, and Human-Machine Interface Technologies* (2017).
2. A. ESTEVA et al., “Dermatologist-level Classification of Skin Cancer with Deep Neural Networks,” *Nature* **542**, 115–118 (2017).
3. D. S. WEI et al., “Development and Validation of a Deep Learning System for Diabetic Retinopathy and Related Eye Diseases Using Retinal Images From Multiethnic

Populations with Diabetes," *Journal of the American Medical Association*, 318(22), 2211-2223 (2017).
4. S. RAMOS et al., "Detecting Unexpected Obstacles for Self-Driving Cars: Fusing Deep Learning and Geometric Modeling In Demos," *30th Annual Conference on Neural Information Processing Systems* (2016).
5. R. MIYAJIMA, "Deep Learning Triggers a New Era in Industrial Robotics," *IEEE MultiMedia* 24 (4), 91-96 (2017).
6. M. ABADI et al., "TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems," *Google Inc. White Papers*, arXiv preprint arXiv:1603.04467 (2015).
7. Y. BENGIO, "Practical Recommendations for Gradient-based Training of Deep Architectures," *Neural Networks: Tricks of the Trade*, 2nd ed., Springer, Berlin (2012).
8. J. BERGSTRA et. al, "Random Search for Hyper-Parameter Optimization," *Journal of Machine Learning Research* 13, 281-305 (2012).
9. J. SNOEK et. al., "Practical Bayesian Optimization of Machine Learning Algorithms," *26th Annual Conference on Neural Information Processing Systems* (2012).
10. J. Gilmer et al., "Neural Message Passing for Quantum Chemistry," arXiv preprint arXiv: 1704.01212 (2017).
11. M. Schlichtkrull et al., "Modeling Relational Data with Graph Convolutional Networks," arXiv preprint arXiv: 1703.06103 (2017).

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

視線データを活用した建設現場の品質管理技能伝承への取り組み

Approach to the transfer of quality control skills at the construction site using eye-gazing data

森田 順也[*1]
Junya Morita

藤本 奈央[*1]
Nao Fujimoto

柳田 克巳[*1]
Katsumi Yanagita

[*1] 鹿島建設株式会社
KAJIMA Corporation

Quality control at the construction site is subject to differences in results depending on the skill level of the field supervisor and precision collateral is a problem. In addition, to do precise quality check, it is important to find a suitable "Viewpoints". But it is difficult to efficiently train because it is difficult to extract these "Viewpoints". Also, due to the rapid expansion of the construction market in the current metropolitan area, we can not place employees enough, and we can not provide appropriate guidance by OJT (On-the-Job Training), which is the key to technology transfer. In this study, using an eye-tracking device, we tried to find out skilled field supervisors' "Viewpoints" or how to "recognize situation", and clarify "judgement criteria" that lead to "action". Then, we show how to inherit the extracted behavior process to supervisor with low skill level.

1. はじめに

建設業にとって，施工不良や材料不足などの品質事故（不具合）は，社会に与えるインパクトのみならず企業の死活問題につながりかねない大事である．にもかかわらず類似の事故は後を絶たず，原因を探ると，「いつもと違う作業（人）だった」「忙しくて見逃した」といった些細な見落としなど，日々行っている品質確認で「気づける」ものがほとんどである．このように建設現場の品質管理は，現場監督員の熟練度により品質確認の結果に差が出やすく，精度担保が課題である．加えて，精度の高い品質確認を行うには，現場の状況に即して適切な「着眼点」を見出すことがポイントとなっているが，形式知化が難しいため，効率的なトレーニングや人材育成の難易度が高い．さらに，現在の首都圏建設市場の急拡大により，社員をバランス良い年齢構成で配置することができず，技術伝承の要となる OJT（On-the-Job Training）による適切な指導ができていない．若手の早期戦力化は遠のくばかりである．

一方，他産業では，建設業と共通点が多い農業で先進的な取組みが行われている．農業も自然を相手にしているため状況対処的な作業が多く，また，同種類の野菜でも作り方によって美味しさが変わる等，農家の技能が品質を左右する．これら農家が持つコツ・ノウハウは身体に染みついているものなので形式知化は難しいと言われていたが，アイトラッキングという視線計測技術を用いることで，何を手掛かりにして「状況認識」し，その後どのような「判断」で「作業」をしているか，一連の作業プロセスが明らかにできるという [神成 15] .

これを建設業に当てはめると，建設業で言われている「着眼点」が「状況認識」能力に該当し，その後の「判断」「行動」につながるものと考えられる（図 1）．そこで本研究では，現場監督が行う日々の品質確認作業において熟達者と未熟者の違いが「着眼点」に現れるのかを見出すことにした．そして，抽出された熟達者の行動プロセスを未熟者に継承していく方策について，今後の展望を示す．



図 1：現場監督員の行動プロセス

連絡先：森田順也，鹿島建設株式会社，東京都港区赤坂 6-5-11，03-5544-1440，moritaj@kajima.com

2. アイトラッキングを用いた状況把握能力の抽出

アイトラッキング（eye-tracking）とは，「人がどこを見ているか」を調べる技術であり，アイトラッカー（EMR：Eye Mark Recorder とも呼ぶ）という装置（図 2）で目の動きを検知し，カメラで撮影する視野画像に視線（アイマーク）を重ねて表示する．こうして得られた動画データには，視線，音声，動画像が含まれており，これを見るだけでも被験者の目線を疑似体験することができるし，データ解析によって詳しい分析も可能となる． 鈴木は，視線データの分析方法は発展途上にあると指摘しつつも，医療スタッフの熟達度評価の一部としてアイトラッキングの可能性を見出している[鈴木 16].



図 2：アイトラッカーと現場監督員

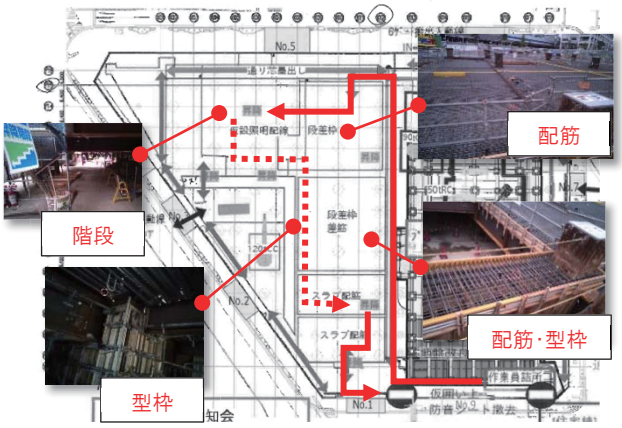


図 3：現場巡回ルート

2.1 実験方法

今回の実験では，眼鏡型のアイトラッカー（Tobii Pro Glasses2）を用い（図 2），「着眼点」が抽出可能かを検証した．未熟者と熟達者の違いを把握するため，経験年数が異なる 4 人の現場監督員（26 年，15 年，5 年，1 年）を被験者とし，施工現場を同一ルートで巡回させてデータを収集した（図 3）．

データ収集後，注視量の整理（表 1），注視箇所の書き起こし図（図 4），ヒートマップ解析図（図 5）などの資料を作成し，被験者とその上司（現場所長）を集めた映写会（図 6）を通じてインタビューを行った．

表 1：被験者毎の注視時間（注視=60msec 以上の視線停止）

被験者	総時間（秒）	注視時間（秒）	注視率（%）
A(26)	1626	495	30
B(15)	1149	413	36
C(5)	1016	466	46
D(1)	805	308	38

※被験者の括弧は現場監督経験年数

2.2 実験結果概観

表 1 を見ると，熟達者であればあるほど巡回にかける時間が長く，熟達者 A と未熟者 D では 2 倍も開きがある．これは「着眼点」の有無が反映されたためであり，予想通りの結果だった．

一方，「注視率（注視時間/総時間）」については熟達者のほうが少ない．映像で確認すると，未熟者 D はすれ違う人の顔を良く見ており，若手 C はデジカメで撮影しているシーンが多かった．後にインタビューで判明したが，C,D は安全についてしっかり見るように指導されていたため，安全上の観点で現場内をまんべんなく見て，気になることを記録に時間を割いていた．B は品質管理を担っているが，この日の作業は最も重要なコンクリートを流す前の最終確認工程だったため，鉄筋や型枠などの品質の確認が多かった．A は品質・安全を問わず現場内全体を，ゆっくりとした足取りながら，じっくり見ていた．



図 4：注視箇所の書き起こし図

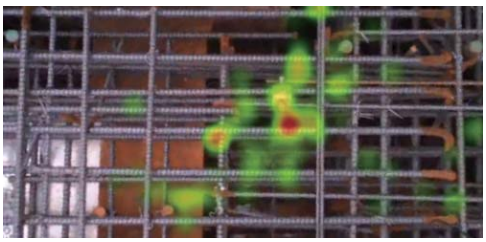


図 5：ヒートマップ解析図（被験者 A の視線）

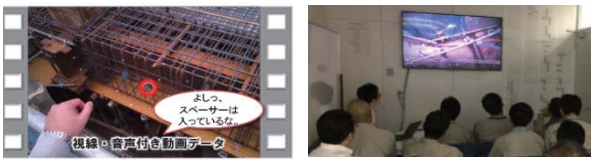


図 6：視線付き動画と現場での映写風景

2.3 インタビューで表出した知見

視線データをインタビューに併用することで，言葉だけのインタビューよりも 5 倍の情報を得ることができると言われる[Olsen 10]．今回，映写会を通じたインタビューと補助資料（図 4,5）を用いたことで多くの知見が得られた．以下，主なコメントを示す．

- 目線を見れば技能の有無が一目瞭然．C は型枠はわかっているようだが配筋の経験はないのだろう（所長）．
  →その通りだった．所長と C はまだ面識が浅かった．
- D は新人なのでまだ見るべき所がわかっていない．A は品質と安全をバランスよく見ている．B は品質担当なので品質回りが多い．C,D は安全面について厳しく言っているので安全に関しては A,B よりも細かく見ている（所長）．
- ヒートマップ（図 5）で鉄筋の間を注視していた理由は，型枠の底の汚れを気にしていたからである（A）．
- 視線付き映像（図 6）を見れば上司が気にする品質確認のポイントを知ることができる（C,D）．

このように視線データは想定以上に技能評価，技能訓練に効果があることが分かった．また，熟達者自身が言語化できていない知識や，その状況に直面して初めて引き出される知識を発見することもできるため，現場で動きながら記録・蓄積する仕組みは今後ますます重要になる．

3. まとめと今後の展望

本稿では，視線データを手掛かりにすれば熟達者が状況認識時に行っている「着眼点」を発見し，かつ，判断に解釈を与えられる可能性を見出した．そしてこの「着眼点」を疑似体験することで，これまで難しかった建設現場における品質監督業務の技能伝承を行える可能性も見出した．

今後，退職が迫る多くの熟達者からデータを収集・分析し，効率的なトレーニングや人材育成の仕組みを作り上げていく予定である．その際には，膨大な動画データの処理を効率的に行えるよう，音声識別や画像識別などの人工知能技術を適用する予定である．また，収集・処理したデータはアノテーション付きのデータセットになるので，そのデータセットを用いて未熟者に熟達者の「着眼点」を提供するシステムの開発を計画している．

これまで一品受注生産，かつ不確定要素が多いことを理由に生産性の向上が難しかった建設業だが，現場で使えるセンサー，デバイスの充実，画像・音声解析技術の進化により，向上の可能性が見えてきた．本稿を契機に，建設業に多くの関心が集まり，産業全体の底上げ，特に若い人が魅力を感じる業界になることを期待する．

参考文献

[神成 15] 神成淳司: AI（Agri-Informatics）に基づく学習支援システムの研究開発，人工知能，30 巻 2 号，2015.

[鈴木 16] 鈴木聡: 血液透析の作業遂行に対するアイトラッキング技術の利用効果と期待-タスク関連注視の把握により可能になること-，透析会誌，49(10)，2016.

[Olsen 10] Olsen, A.: Comparing different eye tracking cues when using the retrospective think aloud method in usability testing, Proceedings of the 24th BCS Interaction Specialist Group Conference, 2010.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

電力ダム操作における強化学習型シンボルグラウンディングによる意思決定支援に関する検討

Toward Supporting Decision Making for Flood Control in a Hydroelectric Dam by Reinforcement Learning and Symbol Grounding

田中　友紀子 *1*2　平岡　拓也 *1*2　大西　貴士 *1*2
Yukiko TANAKA　Takuya HIRAOKA　Takashi ONISHI
鶴岡　慶雅 *2*3　滝野　晶平 *4　松本　陽介 *5
Yoshimasa TSURUOKA　Shohei TAKINO　Yosuke MATSUMOTO

*1NEC セキュリティ研究所
NEC Security Research Laboratories
*2産業技術総合研究所 人工知能研究センター
National Institute of Advanced Industrial Science and Technology, Artificial Intelligence Research Center
*3東京大学 The University of Tokyo
*4東京電力ホールディングス株式会社 Tokyo Electric Power Company Holdings, Inc.
*5東電設計株式会社 Tokyo Electric Power Services Co., Ltd.

We present a hierarchical planner for dynamic systems based on reinforcement learning and symbol grounding. In experiments, we evaluate our planner using a hydroelectric dam simulator and demonstrate the potential effectiveness of our approach in supporting decision making in dam flood control.

1. はじめに

近年、人間の技能を超える人工知能が登場しており、その発達が目覚ましい。囲碁の領域では、人間の知識を使うことなく人間の技能を超える人工知能、AlphaGo Zero が誕生している [Silver 17]。産業分野においては、プラント制御や生産管理などの現場で熟練者の減少に伴う知識伝承の課題があり、現場で働く人間の支援に向けた人工知能活用の期待が高まっている。

人工知能の活用が期待できる産業分野のひとつとして、ダムの放流操作が挙げられる。ダム操作の中でも特に、洪水時 *1 のダム放流操作は操作員にとって難しい操作である。

発電を目的とする電力ダムでは通常、ダムに貯留した水を取水し、下流の発電所に導水することで発電を実施する。電力ダムの操作では河川の安全確保を第一優先とする。電力ダムの上流河川でのゲリラ豪雨や台風通過によって雨量が増加し洪水に至る可能性がある場合、流域の安全を考慮し、発電を停止し、洪水に至る前までに予め貯留した水を放流することでダム水位の低下を完了することがダム操作規程で定められている。水位低下のためには放流量を増やす必要があるが、放流量の急激な増加はダム下流域の河川氾濫を引き起こすため、河川の状況を監視しながら徐々に放流量を増やす必要がある。

洪水時や洪水時前後のダム放流操作はダム操作規程に定められているが、ダム操作員はダムへの流入量を予測し、洪水時までに放流すべき水量や水位低下に必要な時間を見積り、ダムの放流計画を立案することが求められる。現状では、熟練のダム操作員が気象状況や河川状況に合わせて、ダムの放流計画を逐次見直しながらダム放流操作をおこなっているが、時間的な制約の中、流域の安全確保が至上命題であり、操作員への心理的・肉体的な負担は非常に大きい。そこで本研究では、ダム操作員の負担軽減を目的とし、人工知能を活用した意思決定支援の有用性を検討する。

連絡先: 田中 友紀子，NEC セキュリティ研究所，川崎市中原区下沼部 1753，y-tanaka@jz.jp.nec.com

*1　ダムの流入量がある閾値を超えることを洪水という

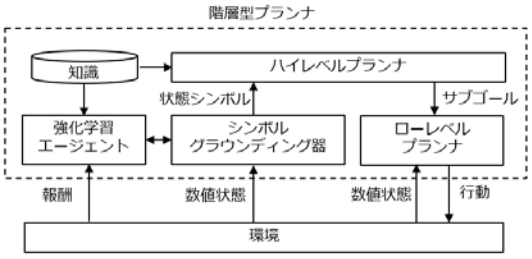


図 1: 強化学習と、シンボルを介したプランニングを融合した枠組み

ダム放流操作のような重要インフラ操作の場面では、責任所在の観点から最終的な意思決定は操作員が実施することが求められるため、人工知能が出した解を人間が理解できる必要がある。例えば、人工知能の分野で成果を挙げている人工知能 AlphaGo Zero [Silver 17] で用いられる手法は人間の技能を超えるという点で優れた手法だが、人工知能が出した解 (囲碁の場合は選んだ手) の根拠を人間が理解することが容易でない。

今回は、電力ダムのシミュレータを計算機上で構築し、人間が理解しやすい操作案を出すことが可能な枠組みである強化学習型のシンボルグラウンディングに基づく人工知能に、熟練者相当の操作を学ばせることを試みた。実験結果を評価した結果、有用性を確認することができたので報告する。

2. アプローチ

2.1 枠組み

本研究では、熟練者相当の操作を獲得でき、かつ人間が理解できる形で操作案を提示することを狙う枠組みを構築した (図 1 参照)。具体的には、強化学習とシンボルグラウンディングを含む階層型プランナの枠組みを構築した。

本研究での階層型プランナの大まかな処理の流れは、次の

通りである。まず、階層型プランナが、操作対象の電力ダムや上流河川などを含む環境から電力ダムへの流入量や水位などの数値状態を受け取る。次に、シンボルグラウンディング器が、各数値状態を状態シンボルに変換する。例えば、水位が 10m であるという数値状態を、「発電可能水位」という状態シンボルに変換する。その後、ハイレベルプランナが、状態シンボルの集合をもとに、人手で事前に設計した知識を用いたプランニングにより、現在達成すべき目標状態であるサブゴールを導く。本研究では目標水位の値がサブゴールに相当する。最後に、ローレベルプランナが、現在の数値状態とサブゴールをもとに現在取るべき行動を導き、環境に与える。本研究では放流量の値が行動に相当する。これらの処理を意思決定周期毎に繰り返す。

本研究の階層型プランナは、シンボルを介する。ダム放流操作では、最終的な操作決定と実行は操作員が担うものであるため、階層型プランナが導出した操作案を操作員が理解できることが求められる。シンボルを介する階層型プランナは、操作員が理解しやすい形で解を提示できる期待がある。

また、本枠組みでは、前述の階層型プランナの一連の処理に加え、シンボルグラウンディング器が担うシンボルグラウンディング、つまり数値状態と状態シンボルの対応づけに強化学習を用いる。強化学習を担う強化学習エージェントは、環境から得た報酬と数値状態をもとに、シンボルグラウンディングのふるまいを決めるグラウンディング関数のパラメータを学習する。強化学習は、熟練者の操作ログが豊富に用意されていない状況でも、報酬関数を定義することで、熟練者相当の操作を獲得できる期待がある。本研究では熟練者相当の操作を獲得するため、強化学習を用いる。

2.2 シンボルグラウンディング

階層型プランナ内のシンボルグラウンディング器が担うシンボルグラウンディングについて述べる。本研究でのシンボルグラウンディングは、階層型プランナが環境から得る複数の数値状態のうち各数値状態に対しそれぞれ 1 つの状態シンボルを対応づける。以降、1 つの数値状態から 1 つの状態シンボルへのグラウンディングを例に、シンボルグラウンディングの説明をする。

S をシンボルの集合を表す有限集合とし、数値状態を $x \in \mathbb{R}$、状態シンボルを $s \in S$ と定義する。本研究では、x から s への変換をシンボルグラウンディングとする。

シンボルグラウンディングの挙動を制御するパラメータ $\boldsymbol{\theta}$ を次のように定義する。

$$\boldsymbol{\theta} = (\mu_{s_1}, ..., \mu_{s_i}, ..., \mu_{s_{|S|}}, \sigma_{s_1}, ..., \sigma_{s_i}, ..., \sigma_{s_{|S|}}) \quad (1)$$

μ_{s_i}, σ_{s_i} はそれぞれ、$S = \{s_1, ..., s_i, ..., s_{|S|}\}$ としたときの、シンボル s_i に対応する平均と分散である。$\boldsymbol{\theta}$ を用いて、シンボルグラウンディングに使用するグラウンディング関数を、

$$\pi(s, \boldsymbol{\theta}|x) := \pi(s|x, \boldsymbol{\theta})P(\boldsymbol{\theta}) \quad (2)$$

と定義する。ここで、$\pi(s|x, \boldsymbol{\theta})$ は、各 s に対応づけたガウス分布 $N(x|\mu_s, \sigma_s)$ を用いて以下のように定義される。

$$\pi(s|x, \boldsymbol{\theta}) := \frac{N(x|\mu_s, \sigma_s)}{\sum_{s' \in S} N(x|\mu_{s'}, \sigma_{s'})} \quad (3)$$

$P(\boldsymbol{\theta})$ は、人間が理解しやすい形で x と s を対応づけるための $\boldsymbol{\theta}$ に関する事前分布 $P(\boldsymbol{\theta}) := N(\mu_s|\mu_m, 1)N(\sigma_s|\sigma_m, 1)$ である。$\pi(s, \boldsymbol{\theta}|x)$ は、人間が経験的に得る知識や操作手順書から学ぶ知識から大きく外れないようにすることが望ましい。電力ダムの操作はダム操作規程に従うため、本研究では予め、ダム操作規程の記述を参考に、$P(\boldsymbol{\theta})$ に用いる μ_m, σ_m を人手で作成した。人手で作成した μ_m, σ_m の例を表 1 に示す。人間がもつ前記知識を $P(\boldsymbol{\theta})$ に埋め込み、学習初期値と学習時の制約として考慮する。

表 1: 人手で作成した事前分布パラメータ μ_m, σ_m の例

No.	s	知識	(μ_m, σ_m)
1	通常時	流入量が 300m^3/s 未満ならば通常時	(150, 116.3)
2	洪水警戒時	流入量が 300m^3/s 以上 400m^3/s 未満ならば洪水警戒時	(350, 38.8)

なお、本研究では学習対象に含めないルールベースのグラウンディング関数も用意する。例えば、「発電可能水位」というシンボルの真偽は、電力ダムの諸元と水位の値によって一意に決まる。このように x から s への対応づけが一意に決まるものは、ルールベースのグラウンディング関数を使用した。

2.3 強化学習

本研究では、2.2 節で述べた $\pi(s, \boldsymbol{\theta}|x)$ を改善するために強化学習をおこなう。強化学習アルゴリズムは REINFORCE [Williams 92] を使用する。式 (4) を最大化する $\boldsymbol{\theta}$ を、式 (6) を用いた更新で求める。

$$\arg\max_{\boldsymbol{\theta}} E_{\pi\boldsymbol{\theta}}[\sum_{t=0} r_t] \quad (4)$$

$$\Delta\boldsymbol{\theta} = \alpha \left(\sum_{m=1}^{M} \sum_{t=1}^{T} r_t^m \nabla_{\boldsymbol{\theta}} \log \pi(s_t^m, \boldsymbol{\theta}|x_t^m) \right) \quad (5)$$

$$= \alpha \left(\sum_{m=1}^{M} \sum_{t=1}^{T} r_t^m \nabla_{\boldsymbol{\theta}} \log \pi(s_t^m|x_t^m, \boldsymbol{\theta}) + \sum_{m=1}^{m} \sum_{t=1}^{T} r_t^m \nabla_{\boldsymbol{\theta}} \log P(\boldsymbol{\theta}) \right) \quad (6)$$

ここで α, r_t^m, s_t^m と x_t^m はそれぞれ学習率、エピソード m 中の時点 t における報酬、状態シンボル、数値状態である。

ある時点 t において環境が強化学習エージェントに与える報酬 r_t は、単位時間当たりの発電放流量が多い程 、また規定違反が無い程 r_t が大きくなるよう、以下のように設計する。

$$r_t = Q_e/10 + RulePoint \quad (7)$$

ただし、

$$RulePoint = \begin{cases} 5.0 & (Flood \cap GateFullOpen) \\ -100(l - l_{min}) & (Flood \cap \neg GateFullOpen) \\ -l & (l > H_{HWL}) \\ 0.0 & (otherwise) \end{cases}$$

ここで、Q_e は発電放流量 (m^3/s) である。また、Q_{in} をダム流入量 (m^3/s)、Q_{flood} を洪水流量 (m^3/s) とし、$Flood := (Q_{in} > Q_{flood})$ である。l は電力ダム水位 (m)、l_{min} を Q_{in} に対応するゲート全開時 *2 の水位 (m) とし、$GateFullOpen := (l = l_{min})$ である。H_{HWL} は発電可能最大水位 (m) である。

*2 ゲート全開は水位低下完了と同義である

表 2: ハイレベルプランナで用いたルール例

No.	状態シンボルとサブゴール
1	「洪水警戒時」かつ「発電可能水位」ならば水位を「発電可能水位+1m」に設定
2	「洪水時」ならば水位を「最低水位」に設定

3. 実験

3.1 環境構築

本研究では、図 1 で示した枠組み内の環境を数値シミュレータで構築する。強化学習には多くの試行数が必要であり、実在の電力ダムを操作し、実施することは不可能である。そのため本研究では、電力ダムのシミュレータを計算機上で構築し、シミュレータ上で強化学習を高速に試行することを可能とした。

本シミュレータは、電力ダムの初期水位、単位時間当たりの流入量と放流量 *3 をもとに、数値計算で電力ダムの水位を算出することで水位変化をシミュレーションする。電力ダムのシミュレーションモデルは、水文シミュレータ CommonMP [CommonMP] を参考に自作した。電力ダムのシミュレーションモデルに用いるパラメータは、日本国内にある電力ダムの諸元を参照し構築した。

本シミュレータは電力ダムのシミュレーションモデルに加え、階層型プランナによる操作の試行錯誤を可能にするインターフェースを含む。具体的には、階層型プランナの操作決定周期である 10 分毎にシミュレータが階層型プランナへ、数値状態 (本研究では電力ダムへの流入量と流入量予測値、ダム水位) を渡し、階層型プランナがシミュレータへ、行動 (本研究では放流量) を渡し、シミュレータが 10 分間の数値シミュレーションを実行するという手順を繰り返す。

シミュレーションで使用する電力ダムの単位時間当たりの流入量は、実在の電力ダム流域で発生した複数の洪水パターン *4 を含む期間内の雨量データを用いて構築した 36 期間分の人工データを使用した。

3.2 ハイレベルプランナ

数値状態 $\boldsymbol{x} = (x_1, x_2, ...)$ からシンボルグラウンディングで得られた状態シンボルを $S_x = \{s_{x_1}, s_{x_2}, ...\}$ と定義する。また、G をシンボルの集合を表す有限集合とし、サブゴールを $g \in G$ と定義する。ハイレベルプランナは、S_x を受け取り、g を出力する。本研究のハイレベルプランナは、実在の電力ダムのダム操作規程に倣い人手で構築したルールに従い g を決定する。

本研究で構築したルールの例を表 2 に示す。本研究では 2 種類のルールセット、ruleA と ruleB を用意した。ruleA は現在の流入量と水位のシンボルグラウンディング用のルールセット、ruleB は現在の流入量と流入量予測値、水位のシンボルグラウンディング用のルールセットである。表 2 には ruleA のルールの一例を示す。

3.3 ローレベルプランナ

ローレベルプランナは、g と x を受け取り、行動 $\boldsymbol{a} \in \mathbb{R}^n$ を出力する。本研究ではゲート放流量 Q_g と発電放流量 Q_e の 2 つの値を行動とする。つまり、$\boldsymbol{a} = (Q_g, Q_e)$ である。

*3 本研究が対象とする電力ダムの放流量は、ゲート放流量 (発電に使用しない放流量) と発電放流量 (発電に使用する放流量) の 2 つがある。ここでの放流量は、ゲート放流量と発電放流量の合計値を表す

*4 前線性、台風性など

表 3: 評価結果

ルール	比較対象	平均発電時間 [h]
ruleA	handmade	53.39
ruleA	learned	68.15
ruleB	handmade	61.13
ruleB	learned	67.63

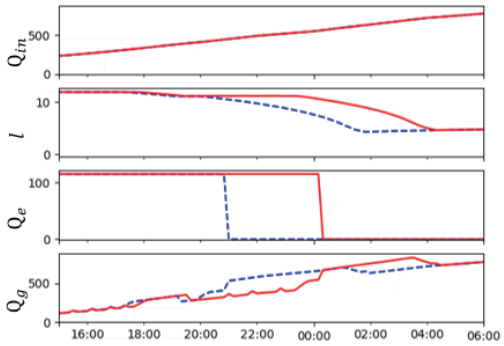


図 2: ダム放流操作案の例。点線が人手で作成したルールを用いて導出した操作案、実線が学習結果を用いて導出した操作案。縦軸はそれぞれ、Q_{in} はダム流入量 (m^3/s)、l はダム水位 (m)、Q_e は発電放流量 (m^3/s)、Q_g はゲート放流量 (m^3/s) である。

今回、g は目標水位と等価である。ローレベルプランナは目標水位 g と現在水位 x をもとに、水位上昇 (放流量減少)、水位低下 (放流量増加)、水位維持 (放流量維持)、の 3 つの操作から 1 つを選択する。選択した操作に従い、ルールベースの制御器でトータルの放流量、つまり Q_g と Q_e の合計値 $Q_g + Q_e$ を決定する。その後、Q_e の上限値を考慮した上で Q_e を最大化するように Q_e を設定し、残りの放流量を Q_g と設定する。本ルールベース制御器では、流域の安全を考慮し、急激な放流量の増減をしないための制約を含んでいる。

4. 評価

評価結果を表 3 に示す。今回は、学習データと別に用意した 9 期間分の評価データで検証し、各期間での発電時間を平均した値を評価結果とする。人手で作成したルールを使用した結果を handmade に示す。また、学習で得られたグラウンディング関数を用いた結果を learned に示す。

今回の評価データの範囲では、学習結果のほうが人手で作成したルールを用いる場合よりよい結果となった。具体的には、学習結果のほうが人手で作成したルールを用いる場合より発電時間を長くしていた。また、いずれの評価データの期間においても規定違反に該当する操作が認められなかった。今回、ハイレベルプランナで用いるルールセットを ruleA と ruleB の 2 種類用意したが、ruleA より ruleB のほうがよい結果となった。

評価の際に得られたダム放流操作の例を図 2 に示す。発電時間を長くし、かつ洪水時に至る前に水位低下を完了することができている。

5. 関連研究

5.1 シンボルグラウンディングと階層型プランナ研究

本研究で用いた枠組みはシンボルグラウンディングを含む階層型プランナの一種と見なすことができるが、階層型プランナに関連する従来研究で提案されてきた枠組みとは**人間がもつシンボルに関する事前知識を用いてグラウンディング関数を学習している**という点で大きく異なる。

階層型プランナに関する従来研究の多く [Nilsson 84, Malcolm 90, Cambon 09, Choi 09, Dornhege 09, Wolfe 10, Kaelbling 11] では、人間によってグラウンディング関数が設計され、グラウンディング関数の学習はおこなわれない。一方、本研究で提案した枠組みは、人間の設計者によるシンボルの定義に関する知識を基に、グラウンディング関数が強化学習される。そのため、人間の設計者があるシンボルの定義に関して不正確な（あるいは曖昧な）知識しか持っていない場合でも、階層型プランナが学習を通じてそのシンボルのより正確な定義を獲得することができる。

また、グラウンディング関数を自動で獲得する研究 [Konidaris 14, Konidaris 15, Konidaris 16] が存在するが、これらの研究では人間のシンボルに関する事前知識をグラウンディング関数の獲得に利用していない。そのため、獲得されたグラウンディング関数が出力するシンボルの意味を人間が解釈するためには、グラウンディング関数の分析が必要となる。一方、本研究で提案した枠組みは、人間のシンボルに関する知識となるべく異ならないようにグラウンディング関数を学習するため、学習後のグラウンディング関数の分析をせずとも、プランナが出力するシンボルを人間が解釈することができる。

5.2 ダム操作支援研究

ダム操作支援を目的とした研究の一例として、エキスパートシステムの研究 [Inoue 99] が挙げられる。従来研究でも、シンボルを介するプランニングと同様の仕組みを用いていた点で本研究と共通する部分がある。

従来研究 [Inoue 99] では、熟練操作員がもつ知識 (放流操作の意思決定に影響する判断基準) を数値的な重みとして設計し、ルールに付与していた。これらは熟練者相当の判断を再現するために決めた値であるが、学習による値の更新はしないため、人手で決めたルールよりよい操作を導出できない。本研究ではシンボルに関連付けたグラウンディング関数のパラメータを学習するため、人手で決めたルールよりよい結果を得ることができる。

6. まとめ

本研究では、電力ダムのシミュレータを構築し、人間が理解しやすい操作案を出すことが可能な枠組みである強化学習とシンボルグラウンディングを含む階層型プランナに、熟練者相当の操作を学ばせることを試みた。評価の結果、有用性を確認することができた。

本研究で提案した枠組みは従来研究と比較し、グラウンディング関数を強化学習する際に人間がもつ知識となるべく異ならないように制約を加える点が新しい。また、ダム操作員の負担軽減を目的とした意思決定支援をする上で、予め人間が決めたルールだけでプランニングをおこなう従来研究とは異なり、強化学習でグラウンディング関数を改善し熟練者相当のダム放流操作案を獲得する点も新しい試みである。

今回、過去事例を基に構築した流入量データを用いて学習したため、仮に過去の事例を著しく超える流入量が電力ダムに到達した場合、本研究の枠組みだけでは対応ができない。そのため、過去の経験を逸脱する事象への対処は大きな課題である。

また、現実環境での評価も今後の課題であり、今回構築した数値シミュレータの環境と現実環境はふるまいが異なることが予想されるため、ふるまいの差異を考慮した枠組みを導入することが必要となる。

参考文献

[Silver 17] Silver, D. et al.: Mastering the game of Go without human knowledge, Nature, 500, (2017).

[Inoue 99] 井上ら: 出水予測・ダム管理支援エキスパートシステム, 大ダム, 166, (1999).

[CommonMP] http://framework.nilim.go.jp/

[Williams 92] Williams, Ronald J: Simple statistical gradient-following algorithms for connectionist reinforcement learning, Reinforcement Learning, 5–32 (1992)

[Nilsson 84] Nilsson, Nils J: Shakey the robot, SRI INTERNATIONAL MENLO PARK CA, (1984).

[Malcolm 90] Malcolm, Chris, and Tim Smithers: Symbol grounding via a hybrid architecture in an autonomous assembly system, Robotics and Autonomous Systems 6.1-2 (1990).

[Cambon 09] Cambon, Stephane, Rachid Alami, and Fabien Gravot: A hybrid approach to intricate motion, manipulation and task planning, The International Journal of Robotics Research 28.1 (2009).

[Choi 09] Choi, Jaesik, and Eyal Amir: Combining planning and motion planning, Robotics and Automation, 2009. ICRA'09. IEEE International Conference on. IEEE, (2009).

[Dornhege 09] Dornhege, Christian, et al.: Integrating symbolic and geometric planning for mobile manipulation, Safety, Security Rescue Robotics (SSRR), 2009 IEEE International Workshop on. IEEE, (2009).

[Wolfe 10] Wolfe, Jason Andrew, Bhaskara Marthi, and Stuart J. Russell: Combined Task and Motion Planning for Mobile Manipulation, ICAPS, (2010).

[Kaelbling 11] Kaelbling, Leslie Pack, and Tomas Lozano-Perez: Hierarchical task and motion planning in the now, Robotics and Automation (ICRA), 2011 IEEE International Conference on. IEEE, (2011).

[Konidaris 14] Konidaris, George, Leslie Pack Kaelbling, and Tomas Lozano-Perez: Constructing Symbolic Representations for High-Level Planning, AAAI, (2014).

[Konidaris 15] Konidaris, George, Leslie Pack Kaelbling, and Tomas Lozano-Perez: Symbol acquisition for probabilistic high-level planning. IJCAI, (2015).

[Konidaris 16] Konidaris, George: Constructing abstraction hierarchies using a skill-symbol loop, IJCAI, (2016).

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

相場データ間密度比推定による株式市場における見せ玉検知

Algorithmic Detection of Quote Spoofing in Stock Exchange Market
Using Probability Density Ratio Estimation

中原 健一 *1　島田 史也 *1　宮崎 邦洋 *2　関根 正之 *2　大澤 昇平 *2　大島 眞 *3
松尾 豊 *2

*1 東京大学大学院 情報理工学系研究科　*2 東京大学大学院 工学系研究科
*3 株式会社 だいこう証券ビジネス

We propose a model to quantitatively estimate quote spoofing in stock exchange markets without any answer labels, for the sake of more efficient and thorough inspection. In our model, density ratio estimation is used to extract unusual trading activities in unsupervised manner. Using market data at Tokyo Exchange and judges by experts, we validate the model and the result indicates that about 50% of half-day grouped trading histories can be ignored of manual inspection with 80% of frauds in the rest half of the dataset.

1. はじめに

株式市場において公正な取引が執り行われるために，不当に利益を得ることを目的とした相場操縦行為を取り締まることは非常に重要である．そのため，相場操縦行為に対しては厳しい罰則が設けられている *1．しかし，取り扱う銘柄及び日々売買審査すべき取引量の膨大さから，実際に起きていたであろう不公正取引のすべてを人力で発見することは極めて難しく，法的枠組みと人力の売買審査のみによって株式市場における価格形成の公正性が確保されているかは保証されていない．そこで，なるべく精緻に不公正取引が疑われる取引や銘柄・時間帯を検出することができるアルゴリズムを売買審査プロセスに導入することによって，より効率的かつ合理的に株式市場の価格形成の公正性が確保されることが期待されている．ここでの売買審査プロセスにおける不公正取引検知アルゴリズムの役割は，疑わしき事例を限定して専門家に通知することである．実際に罰則が適用されるためには，より複雑な取引主体や行為等についての調査が必要であるため，不公正取引検知アルゴリズムは疑わしさを判定するタスクのみを行い，高い Recall Rate を保証した上で専門家に通知すべき事例を可能な限り限定することが求められる．そこで本研究では，相場操縦行為の中でも代表的な手口であるいわゆる見せ玉 (以下, 見せ玉とのみ表記) を可能な限り精緻かつ定量的に検知することを目的とする．

見せ玉を定量的に検知する同様の試みとして，一取引を一単位とした教師あり学習によって，海外市場において高い精度での判定を実現した事例が報告されている [Zhai 17]．しかし，一般に個人に紐づいた株式市場の取引データが公開されていないこと，及びそれらに対する十分なラベルが存在しないことから，十分量の教師データを要求する先行研究の手法を踏襲することは困難であった．また，銘柄間の取引量や期間による取引量の差異が無視できないことから，市場全体を統一的に説明するルールベースの判定規則を作成することも同様に困難である．

したがって本研究では，ラベルデータや強い分布の仮定を必要としない密度比推定による異常検知手法を採用し，注文量/キャンセル量について異常量を発見することによって，直感的に見せ玉の定義に沿った不公正取引の説明が可能なモデルを提案する．東京証券取引所の上場銘柄の中より無作為に選択され，専門家チームによってラベル付けされた 118 件の半日単位の一銘柄取引履歴による検証結果によると，見せ玉が疑われる事例の 80%は，モデルが予測した異常度順にソートした事例の上位 50%に含まれ，実務で使用されている単純な規則によるスクリーニングの結果と比較して更なる精緻化が達成できていることが示された．我々の知る限り，教師ラベル・決定的なルールを用いない相場操縦行為の検知手法として初の事例である．

連絡先: nakahara@akg.t.u-tokyo.ac.jp

*1　例えば日本においては，金融商品取引法第 159 条に記載された相場操縦行為について，刑罰 (同法第 197 条第 1 項第 5 号，同条第 2 項及び第 207 条第 1 項第 1 号) や課徴金納付命令 (同法第 174 条乃至第 174 条の 3) が適用される．

*2　金融商品取引法第 159 条第 2 項第 1 号

2. 背景

2.1 見せ玉とは

見せ玉 (Quote Spoofing) とは，不当に利益を得ることを目的として，約定の意思のない大量の売り/買い注文を最良気配値段付近に発注し，当該注文に誘引された売買注文によって価格を変動させることで他者に値段の下落/上昇を誤認させ，最終的に大量の注文を取り消す一連の相場操縦行為のことを指す *2．見せ玉に関連した相場操縦行為は様々な形態をとるが，一般にその成立に関わる必要条件を列挙すると以下の通りとなる．

1. 約定の意思のない大量の売り/買い注文を発注すること．
2. 当該行為を原因とする価格変動によって行為者が不当に利益を得ていること．

一つ目の必要条件は，大量の注文が相当時間経過後にキャンセルされることを意味する．したがって，見せ玉が行われる相場においては局所的に板の気配数量の不自然な増減が観察される．また二つ目の必要条件は，相場操縦行為が疑われる個人を特定した上で，その個人に紐づいた取引情報を確認することでその成立が確認される．ただし，相場データのみを観察することで，利益を得た個人を特定することは極めて難しい．

2.2 関連研究

上述した定性的な見せ玉の特性をモデル化する試みとして，一取引あたりの相対的な数量・価格・約定又はキャンセルまで

のライフタイムを特徴量とした教師あり学習による一取引単位の不公正取引推定や，時系列量の不自然な変化を隠れマルコフモデルにおける状態の変化として捉える手法などが提案されている [Zhai 17]．これらの手法は，いずれも膨大な量のラベル付きの相場データセットが必要であるため，一般の株式市場における適用のための人的・金銭的コストが非常に大きいことが予想される．また，取引量の少ない銘柄についての適用事例は詳細に報告されていない．

3. 提案手法

以上の議論を踏まえ，我々は見せ玉検知のための広く適用可能なアルゴリズムの要件を以下のように定義する．

1. 膨大量の教師ラベルを要求しないこと．
2. 高い Recall Rate を保証しつつ，人力の売買審査の工数を減らすことができる性能であること．
3. 銘柄の取引量の多寡や価格変動の激しさにかかわらず適用可能であること．

要件 1. を満たすため，我々は見せ玉の必要条件である大口の注文及びキャンセルを，教師ラベルを用いない異常検知手法によって発見することを目指した．しかし，異常検知手法の多くはデータに何らかの分布を仮定した上で異常度を計算するため，株式市場の全銘柄・全期間にわたって適用可能な分布を仮定しなければならず，要件 3. を満たすことが難しい．

そこで，標本に強い分布についての仮定を置かずに各標本の異常度が算出可能な手法である密度比推定を用い，異常値の共起性を調査することによって見せ玉が疑われる相場を検知するアルゴリズムを提案する．

3.1 密度比推定

密度比推定とは，変量に対して確率分布を仮定せずに二サンプル間の確率分布の比を直接推定することによって，標本ごとの異常度を算出する手法である．すなわち，正常データ $\mathcal{D}$ が従う確率分布 $p(x)$ と，観測データ $\mathcal{D}'$ が従う確率分布 $p'(x)$ の比である $r(x)$ を式 (1) に基づいて陽に推定する．このとき，ネイマン・ピアソン決定則に基づいて，各標本の異常度 $a(x)$ は式 (2) で表される．

$$p(x) = r(x)p'(x) \tag{1}$$
$$a(x) = -\ln r(x) \tag{2}$$

$r(x)$ は，基底関数の線型結合として表現され，密度比推定はその重みの最適化問題として定式化されることが多い．本研究では，取り扱うデータの多様さや膨大さに対応可能な手法であることが求められたため，解析的に一つ抜き交差検定の損失関数が計算可能な非制約最小二乗密度比推定法 [Kanamori 09] を採用した．すなわち，$p(x)$ 及び $\hat{r}(x)p'(x)$ の各標本の最小二乗誤差を正則化項を加えた下で最小化することで，$\hat{r}(x)$ を下式 (3)(4)(5)(6) に基づいて解析的に推定する．ここで b は基底関数の種類，n_{tr}, n_{te} はそれぞれ $\mathcal{D}' \cdot \mathcal{D}$ に属する標本数，λ は l2 正則化項の係数を表す．

$$\hat{r}(x) = \sum_{i=1}^{b} w_i \phi_i(x) \tag{3}$$

where

$$\boldsymbol{w}(\lambda) = \max\left(\left(\hat{\boldsymbol{H}} + \lambda \boldsymbol{I}_b\right)^{-1} \hat{\boldsymbol{h}}, \boldsymbol{0}\right) \tag{4}$$

$$\hat{\boldsymbol{H}}_{l,l'} = \frac{1}{n_{tr}} \sum_{i=1}^{n_{tr}} \phi_l(x_i^{tr}) \phi(x_i^{tr}) \tag{5}$$

$$\hat{\boldsymbol{h}}_l = \frac{1}{n_{te}} \sum_{j=1}^{n_{te}} \phi_l(x_j^{te}) \tag{6}$$

3.2 手法概要

ある銘柄 S のある一分間 t の注文量・キャンセル量をそれぞれ $q(t) \cdot c(t)$ と定義する．本手法では，売買審査対象となる日付 $\mathcal{T}'$ に対して，売買審査対象となる日付の前一週間 $\mathcal{T}$ に属する $q(t) \cdot c(t)$ を正常標本 $\mathcal{D}$ として扱い，$\mathcal{T}'$ に属する標本 $q(t), c(t) \in \mathcal{D}'$ に対する密度比 $r(x)$ を非制約最小二乗密度比推定法を用いて推定する．推定された密度比 $\hat{r}_{quote} \cdot \hat{r}_{cancel}$ を用いて，各銘柄・日付ごとに一分間の注文量・キャンセル量の異常度を算出する．

$$\begin{aligned}
\mathcal{D}'_{quote} &= \left\{q(t) \mid t \in \mathcal{T}'\right\} \sim p'_{quote}(x) \\
\mathcal{D}_{quote} &= \{q(t) \mid t \in \mathcal{T}\} \sim p_{quote}(x) \\
\mathcal{D}'_{cancel} &= \left\{c(t) \mid t \in \mathcal{T}'\right\} \sim p'_{cancel}(x) \\
\mathcal{D}_{cancel} &= \{c(t) \mid t \in \mathcal{T}\} \sim p_{cancel}(x) \\
p_{quote}(x) &\simeq \hat{r}_{quote}(x) p'_{quote}(x) \\
p_{cancel}(x) &\simeq \hat{r}_{cancel}(x) p'_{cancel}(x)
\end{aligned}$$

ここで，各日付に対して教師ラベルは付与されていないことを想定しているので，正常標本として扱うデータセット内に相場操縦行為が含まれている可能性は排除されていない．しかしながら，売買審査対象よりも長い期間の相場データにおける異常標本の割合は，実際に相場操縦行為が含まれる一日の相場データ内よりも低いと想定されることを鑑みると，密度比推定を通した異常標本の検出可能性は実用上担保されると考えられる．

上記の手法により計算された各標本の異常度に基づき，半日単位でもっとも異常度の高い標本ごとの異常度の積を，売り注文/売りキャンセル・買い注文/買いキャンセルごとに求める．そのいずれかが閾値を超えており，注文からキャンセルまでの価格変動において行為者が利益を得ることができた可能性がある場合，見せ玉が疑われる相場と判定する．

4. 手法評価

4.1 提案手法の評価

本手法の適用・評価にあたり，東京証券取引所が提供する相場データを使用した．そのうち，無作為に 59 件の日付・銘柄の組み合わせが選ばれ，株式会社だいこう証券ビジネスにおいて 10 年以上の売買審査の経験を有する専門家より構成されたチームによって，見せ玉が疑われる日付に半日単位でラベルが付与された．上記 118 件の標本に対する本手法の適用結果を表す Precision-Recall Curve を図 1 に示す．上位 50%の事例について疑いありと判定することを想定した場合，Recall

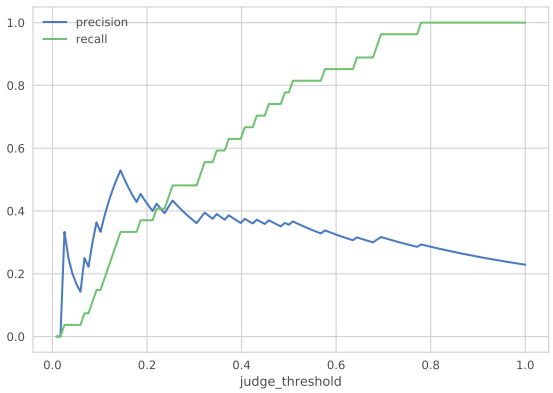


図 1: 無作為抽出事例に対する提案手法の適用結果．横軸は異常が疑われると判定する件数の全件数に占める割合を表し，縦軸は対応する Precision Rate 及び Recall Rate を表す．50%以上の事例について疑いありと判定する場合，Recall Rate80%・Precision Rate35%以上が期待できることがわかる．

表 1: 提案手法における異常度上位 50%の事例を疑いありと判定した場合の混同行列及び最大キャンセル量への閾値適用によるルールベースの規則による判定の混同行列．

	提案手法の判定		規則での判定	
専門家の判定	疑いなし	疑いあり	疑いなし	疑いあり
疑いなし	54	37	7	84
疑いあり	5	22	2	25

Rate が 81%であるのに対し，Precision Rate が 37%である．80%以上の Recall Rate が実用上十分な性能だと考えると，本手法の売買審査プロセスへの導入により，人力でのすべての相場データの売買審査の作業量が半減することが期待される．

4.2 ベンチマークとの比較

提案手法と同様に教師ラベルを用いない検知手法として，実務で実際に使用されている，単純なルールベースの規則による判定手法を同様に評価した．ベンチマーク手法では，五分間のキャンセル量に対し，当日一銘柄の約定量の 5%を閾値として判定する．ベンチマーク手法の評価結果と，提案手法において異常度上位 50%の事例を疑いありと判定した場合の評価を表 1 に示す．ベンチマーク手法は Recall Rate において提案手法をおよそ 10%上回っているが，全事例のうち 90%以上の事例を疑いありと判定しており，相場操縦行為のスキャニングツールとしての性能は提案手法がベンチマーク手法を上回ることが示された．

5. おわりに

本研究では，教師データを使用しない相場操縦行為の定量的モデリングの一手法として，密度比推定を使用した注文量・キャンセル量の異常検知を提案し，その評価を通して適用可能性を模索した．今後は Precision Rate の向上を目指し，異常度検出の更なる精緻化を試みる．また，検出された異常度を基にした相場操縦行為判定において，定性的な相場操縦行為の知見を更に活用するなどして，その性能の更なる向上を目指す．

謝辞

本研究は，株式会社だいこう証券ビジネス及び株式会社 DSB 情報システムの支援を受けて行われた．

参考文献

[Kanamori 09] Kanamori, T., Hido, S., and Sugiyama, M.: Efficient direct density ratio estimation for non-stationarity adaptation and outlier detection, in *Advances in neural information processing systems*, pp. 809–816 (2009)

[Zhai 17] Zhai, J., Cao, Y., Yao, Y., Ding, X., and Li, Y.: Computational intelligent hybrid model for detecting disruptive trading activity, *Decision Support Systems*, Vol. 93, pp. 26–41 (2017)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

複数チャットボットの連携による業務支援フレームワークの提案

Proposal of a business assisting framework with multiple chatbots

角田 啓介 *1 Keisuke TSUNODA
岡崎 優尋 *1 Masahiro OKAZAKI
小柳 隆人 *1 Ryuto KOYANAGI
長森 藤江 *1 Fujie NAGAMORI
箕浦 大祐 *1 Daisuke MINOURA

*1NTT コムウェア株式会社
NTT Comware Corporation

This paper introduces a business assisting framework with multiple chatbots. In enterprises, business activities are processed with different employees in multiple departments. Most of existing approaches for business assistance are classified into (1)an application of individual activity support and (2)large business suite for assisting business activities processed with different employees in multiple departments. However, to improve business activity more effectively, it is important for a business assisting approach to be applied to business activities processed with not only an employee, but different employees in multiple department, and to be easier to use for each employee and flexible for changing business process in each department. In this paper, we propose a new business assisting framework with multiple chatbots. In the framework, each department designs and implements the chatbot which assists its business process as approach (1). Then, these chatbots are connected with each other using shared database for assisting business activities processed with different workers in multiple departments as approach (2). We implemented a prototype of proposed framework applied to service order operation and discuss the effectiveness and issue of our proposal.

1. 緒言

ビジネス環境の競争激化や先進国における労働人口減少に伴い，多くの企業で業務，特に定型的業務の効率化が求められている．従来，ビジネスにおける業務効率化のアプローチは，(1) 各従業員が自身の業務に合わせてツールを導入し，自分の業務を効率化する (2) 全社的に業務プロセスを刷新した上でそれに合わせたシステムを全社に導入する，のいずれかが主であった．しかしながら，(1) のアプローチでは従業員個人の範囲しか業務を効率化できない点が，(2) のアプローチでは企業における経営陣や管理者がトップダウンで導入したシステムが各部署や従業員の実態にあっておらず業務効率化に寄与できない可能性がある点 [Buehrer 05] が，それぞれ課題であった．そのため，企業における業務を効果的に支援するためには，複数の従業員や部署を横断する業務を，各組織や従業員の実態へ柔軟に対応できる手法で支援する必要があると考えられる．

本稿では上記の課題を踏まえ，ある業務を担当するグループを部署と定義した上で，部署ごとの業務を対話的に支援するチャットボットを導入した上で，各チャットボットを疎結合に連携させることで，柔軟かつ効果的に業務を支援できるフレームワークを提案する．そして業務の具体例として，お客様があるサービスに申し込んだ時に発生するサービス申込対応業務を取り上げ，そのような業務プロセスを支援するプロトタイプを実装することで，提案フレームワークの効果と今後の展望について述べる．

2. 関連技術

2.1 従業員個人の業務支援

モバイルデバイスの普及に伴い，場所を問わずに従業員個人の業務を支援するアプリケーションやシステムが多数提案されてきた．その中でも特に近年，チャットボットを用いたシステムが多数提案されており，例としてメッセンジャアプリを用いたスケジュール管理支援システム [Comware 17]，ソフトウェア開発チームの支援システム [Storey 16] が挙げられる．チャットボットを用いることで，ユーザは普段使い慣れたモバイルデバイスのメッセンジャアプリ上で，チャットボットの発言に基づいた対話的操作により，そのバックエンドに接続された複数のシステムへアクセスできるようになる．その結果，ユーザは場所を問わず簡単に，システムを用いる業務を実施できるメリットがある [Tsunoda 17]．一方，チャットボットのふるまいは業務プロセスに合わせてシナリオという形で設定しておく必要があるが，多数の部署や従業員が関連する業務を対象とすると大規模化かつ複雑化してしまうため，一般的には従業員個人やある特定のチーム内での業務支援といった限られた範囲で利用される．

2.2 業務フロー全体の支援

業務効率を大きく向上させるためには，従業員個人やある部署だけでなく，複数の従業員や部署を横断する業務フロー全体を対象とし，それを最適化させると共に，最適化されたフローに合った大規模なシステムを導入することが最も根本的な解決策とされる．このような活動は “IT Transformation” と呼ばれる [Deloitte 16]．一方で，“IT Transformation” は準備や導入に多大な時間と費用がかかる上，新たなシステムが必ずしも各部署や個人の業務実態と合致しないため，有効に活用されない事例があるとされる [Buehrer 05].

他方，2000 年代後半から，業務志向でより柔軟なシステム構築の考え方として Service Oriented Architecture(SoA) [Laskey 09] が提唱されている．SoA では業務フロー全体を対象とするのではなく，ある単位（例えば部署毎）の業務フローのみを対象とし，それを支援する一つのソフトウェアモジュールを作成する．そして各モジュール間で共通なインタフェースを定義し，接続性を確保することで，複数のモジュールを組み合わせによる全社的な業務支援システムを構築するという考え方である．SoA のメリットとして，モジュール間インタフェースが共通化されているため，あるモジュールで支援する

連絡先: 108-8019 東京都港区港南 1-9-1 NTT 品川 TWINS アネックスビル email: tsunoda.keisuke@nttcom.co.jp

業務プロセスに変更がある場合でも柔軟に対応できる点が挙げられる．

3. 提案フレームワーク

本稿では，効果的な業務支援を目指して複数部署を横断する業務を対象としつつも，従業員各個人や各部署にとって利用しやすく，かつそれらの業務実態や業務フロー変更に柔軟に対応できる業務支援フレームワークを提案する．提案フレームワークの概要を図 1 に示す．本フレームワークでは，ある一業務を担う単位を部署と定義し，部署毎にその業務を支援するチャットボットが導入される．各チャットボットは，当該部署における業務プロセスに合わせたシナリオスクリプト，そのスクリプトを実行させるスクリプト実行エンジン，ボットとユーザの間に必要となるメッセンジャアプリ等の UI と接続する UI 接続機能を持つ．その上で，複数導入されたチャットボットは共有 DB を用いて疎結合に接続されている．提案フレームワークにより，各従業員個人や各部署の業務実態やその変化に合わせた対話的かつ柔軟な業務支援と，複数部署を横断する効果的な業務支援を両立することができる．

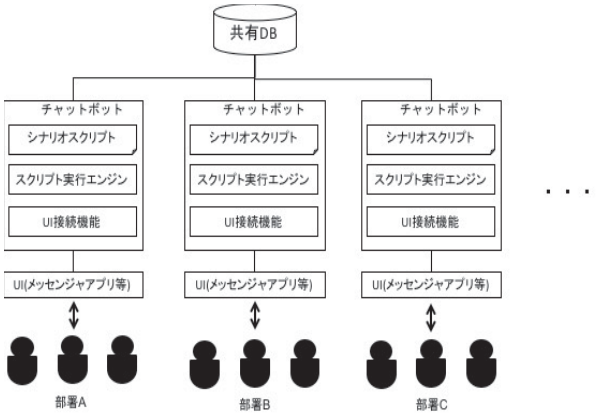


図 1: 提案フレームワーク

4. プロトタイプの設計と実装

4.1 対象とする業務プロセス例

プロトタイプ実装の対象として，本稿ではお客様対応を行うフロントエンドの部署 (以下，フロント部署) と事務処理等を行うバックエンド対応の部署 (以下，バックエンド部署) が連携したサービス申込対応業務を取り上げる．対象とする業務では，フロント部署がお客様から申込書を受領して申込書を確認の上，バックエンド部署へ申込書を送付する．バックエンド部署は申込書を元に申込内容の確認とシステム操作を実施した上で，結果をフロント対応の部署へ通知することで，お客様に申込完了，または不可を伝える．さらに管理者はこのような業務の状況を随時確認し，業務の停滞やトラブル等を発見したら随時サポートを行う．対象となる業務フローを図 2 に示す．

4.2 設計と実装

図 3 にプロトタイプの構成図を示す．プロトタイプでは 3 つのチャットボット (フロントボット，バックエンドボット，管理ボット) が実装され，それぞれの部署の業務に合わせたシナリオを持つ．シナリオはスクリプト言語で記述されているため，簡易に変更が可能である．また，各チャットボットは共有 DB

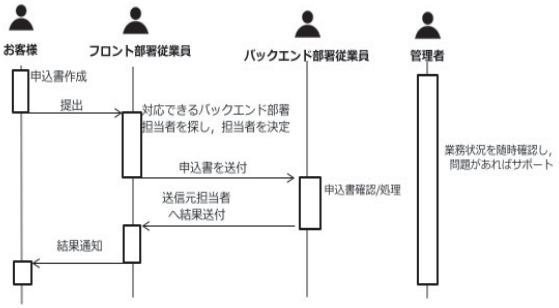


図 2: 対象となる業務フロー

を介して相互に通信を行うため，共有 DB におけるデータ操作方法さえ定義しておけば，それ以外の各チャットボットのシナリオは自由に変更可能である．なお，プロトタイプではフロントボット及びバックエンドボット用の UI として NTT コムウェアのシャナイン®TALK [Comware 18] を，管理ボット用の UI として Web ブラウザを用いた．

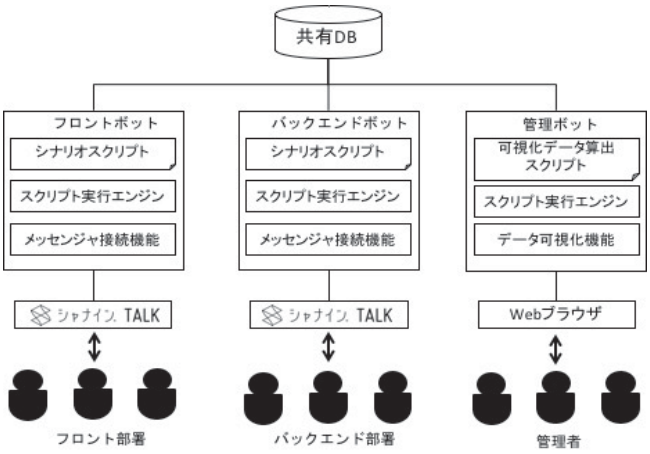


図 3: プロトタイプの構成

図 4 にプロトタイプ導入後の業務フローを示す．プロトタイプにおいて，フロント部署の従業員はお客様から申込書を受領し，項目の漏れ抜けなどを確認後，申込書画像を撮影の上フロントボットに送信し，その後スタンプを送信する．このスタンプが，フロントボットのシナリオで定義された業務開始コマンドとなっている．フロントボットは申込書画像データを受信し，シナリオで定義された処理，例えば画像品質やサイズ，記述内容の確認などを実施後，問題がなければ共有 DB の指定されたフィールドに申込書画像とその受領情報を書き込む．一方，バックエンドボットは常に共有 DB の指定されたフィールドを監視しており，もし新たな申込書画像と受領情報があった場合はそれらを取得する．その後．複数存在するバックエンド部署の従業員のうち，現在業務を実施していない従業員を 1 名選定した上でバックエンドボットは当該従業員を新たなチャットルームに招待する．そして共有 DB より取得した情報を送信し，申込書画像を元に業務を実施するように依頼する．当該従業員は送信された情報とバックエンドボットに記述されたシナリオに基づいて業務を実施する．具体的には申込書画像の確認と，その内容に基づいた他システムへの情報入力や書類作成などである．業務終了後，当該従業員が情報 (申込の完了/未了やその理由) とコマンドとなるスタンプをバックエンドボッ

トに入力すれば，その情報は共有 DB を通じてフロントボットに送信され，フロントボットは送信元のフロント部署従業員にその旨を通知する．一方，管理者は随時，管理ボットが共有 DB から随時取得したデータより，可視化データ算出スクリプトに沿って算出・可視化した業務状況データをブラウザを通じて確認する．管理者はもし所要時間が長い申込などを発見した際は，当該従業員へのサポートを実施する．

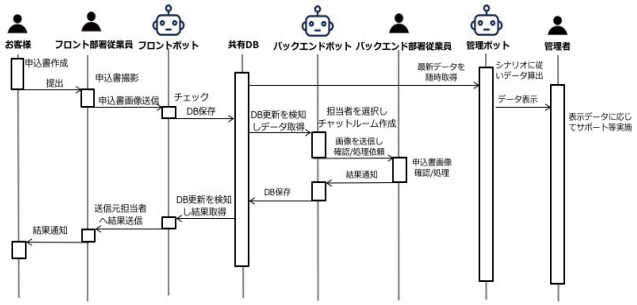


図 4: プロトタイプ導入後の業務フロー

プロトタイプとして実装したフロントボットとフロント部署従業員とのチャットルームの例を図 5 に，バックエンドボットとバックエンド部署従業員とのチャットルームの例を図 6 にそれぞれ示す．図 5 に示したように．フロント部署従業員は申込書を撮影後，フロントボットに画像と「依頼」というスタンプを送信することで，申込書の確認・処理依頼がバックエンド部署へ送られる．また図 6 に示したように，バックエンドボットからチャットルームに招待されたバックエンド部署従業員は画像を受け取り後,「確認中」というスタンプを送信することで，確認・処理中であることを送信でき,「完了」スタンプを送信すること確認・処理の完了をフロント部署へ通知できる．このように画像の撮影・送信とスタンプ送信を中心とすることで，従業員は最小限の入力操作で簡易に業務を遂行できる．

管理者ボットの画面例を図 7 にそれぞれ示す．図 7 における各行は各申込の処理状況を表わしており，フロント部署，バックエンド部署それぞれの従業員名，業務状態 (開始，バックエンド部署担当未割当，実行中，完了)，開始からの経過時間がそれぞれ表示される．管理者はこの画面を元に，所要時間が長い申込があった際の従業員へのサポートや，1 日の全データに基づく平均所要時間の把握及び改善策の策定などが実施できるようになる．なお．本プロトタイプにおける管理ボットは必ずしもキャラクタとの対話形式にする必要性はないと考え，ブラウザを UI として単に結果が随時可視化される形態としているが，例えば通知機能などが必要な場合は，メッセンジャアプリに接続し，他のボットと同様にキャラクタとの対話形式にすることも可能である．

5. 考察

図 5，図 6 で示したように，提案フレームワークに基づいたプロトタイプにより，各従業員はメッセンジャアプリ上における簡易な入出力のみで業務を実施することができようになる．また，図 7 で示したように，管理者向け画面ではフロントボットからの各申込の処理状況や開始からの経過時間などが一覧表示されており，逐次更新されるため，管理者は現状の業務状況の把握やボトルネックの把握，ある期間のデータを分析することによる業務改善の検討が簡易に実施できるようになる．さらに重要な点として，各部署の業務を支援するこれらのチャットボットは共有 DB のみを介して連携しているため，各部署の状況，例えば申込書の確認ステップの追加，従業員の変更や増減，管理 KPI の変更が生じた場合でも，自部署のチャットボットのシナリオスクリプトのみを変更すればよいため，柔軟に対応しやすいというメリットを実現できた点が挙げられる．



図 5: フロントボットの画面例

一方で，共有 DB の設計が全体に影響を及ぼすため，共有 DB のスキーマなどが根本的に変わるような場合は必ずしも変化に柔軟に対応できない可能性がある．しかしながら，提案フレームワークにおいてはチャットボットの追加や削除も当初より想定されるため，最初から共有 DB のスキーマ等を厳密に定め，全部署に一斉導入するのではなく，まずは一部の部署のみにチャットボットを導入して運用し，特に共有 DB などに関する課題を抽出の上，課題を解決して随時導入部署を拡大するといった，スモールスタートによってある程度問題を軽減できると考えられる．

6. まとめと今後の展開

本稿では，企業における業務支援を効果的に実施するため，複数部署を横断した業務を効率化を目的とした業務支援フレームワークを提案した．具体的には，部署ごとの業務を対話的に支援するチャットボットを導入した上で，各チャットボットを疎結合に連携させることで，柔軟かつ効果的に業務を支援できるフレームワークを提案した．そして，申込書に基づくサービス申込対応業務を対象にプロトタイプを実装し，その有効性と課題について述べた．

今後の展開としてはまず，提案フレームワークを企業における実業務に適用した際の効果を定量的・定性的に評価することが挙げられる．また，4 つ以上の部署が連携するような複雑な業務への適用と，そこから生じる課題の抽出と解決が挙げられる，さらに，提案フレームワークに基づく業務支援システムが導入されると，共有 DB をはじめとするシステムのログデータより業務全体のフローが把握できるようになるため，例えば並列処理化できるプロセスの発見など，業務プロセスの改善案が自動的に抽出できる可能性がある．そのため，対象業務の拡大と導入と合わせ，上記のような業務プロセス改善案の自動抽

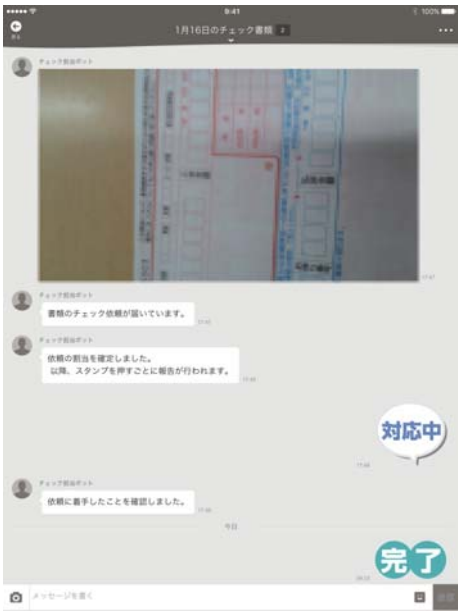


図 6: フロントボットの画面例



図 7: 管理ボットの画面例

出手法についても検討を進める予定である.

参考文献

[Storey 16] Storey M, and Zagalsky A.: Disrupting Developer Productivity One Bot at a Time, *Proc. the 24th ACM SIGSOFT International Symposium on the Foundations of Software Engineering*,pp.928–931 (2016).

[Comware 17] NTT コムウェア: スケジューラ AI, https://www.nttcom.co.jp/comware_plus/solution/201607_2.html(2018.3.1. 閲覧).

[Buehrer 05] Buehrer, R., Senecal S. and Pullins E., Sales force technology usage - Reasons, barriers, and support: An exploratory investigation. *Industrial Marketing Management*, Vol.34, pp.389-389(2005).

[Salesforce 17] Salesforce.com, https://www.salesforce.com/ (2018.3.1. 閲覧).

[Tsunoda 17] 角田 啓介, 後藤 充裕, 北野 孝俊, 中村 浩司, 箕浦 大祐, チャットボットを用いたリモートワーク支援手法の提案, 情報処理学会研究報告 グループウェアとネットワークサービス, 2017-GN-100(38)(2017).

[Deloitte 16] Deloitte: Next generation automation - Transform your business processes with robotic and intelligent automation, https://www2.deloitte.com/content/dam/Deloitte/ch/Documents/technology/ch-en-technology-next-generation-automation.pdf (2018.3.1. 閲覧).

[Laskey 09] Laskey K. B. and Laskey K., Service oriented architecture, *Wiley Interdisciplinary Reviews: Computational Statistics*, Vol.1, Issue 1, pp.101-105(2009).

[Comware 18] NTT コムウェア, シャナイン TALK, https://www.nttcom.co.jp/shanaing/ (2018.3.2. 閲覧)

[1M3] [General Session] 13. AI Application

座長:大西 貴士（NEC/産総研）

Tue. Jun 5, 2018 5:20 PM - 6:40 PM Room M (2F Amethyst Hall Hoo)

[1M3-01] A Lighting Control to Optimize Satisfaction of Illuminance and Color Temperature

○Wataru Bando[1], Mitsunori Miki[2], Hiroaki Nasu[1], Ryoto Tomioka[1], Hiroto Aida[2] （1. Graduate School of Science and Engineering, Doshisha University, 2. Department of Science and Engineering, Doshisha University）

5:20 PM - 5:40 PM

[1M3-02] Development of Machine Learning Models for Gas Identification Based on Transfer Functions

○Gaku Imamura[1], Genki Yoshikawa[1,2], Takashi Washio[3] （1. National Institute for Materials Science, 2. University of Tsukuba, 3. Osaka University）

5:40 PM - 6:00 PM

[1M3-03] Minimum Cost Mapping of Quantum Circuits to Quantum Computers

○Toshinari Itoko[1], Rudy Raymond[1], Takashi Imamichi[1] （1. IBM Research - Tokyo）

6:00 PM - 6:20 PM

[1M3-04] Segment Assignment in Shield Tunneling Method using Constrained Genetic Algorithm

○Koya Ihara[1], Shohei Kato[1,2], Takehiko Nakaya[3], Tomoaki Oki[3] （1. Dept. of Computer Science and Engineering, Graduate School of Engineering, Nagoya Institute of Technology, 2. Frontier Research Institute for Information Science, Nagoya Institute of Technology, 3. Shimizu Corporation）

6:20 PM - 6:40 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

執務者の照度・色温度に対する満足度を考慮した照明の個別分散制御手法

A Lighting Control to Optimize Satisfaction of Illuminance and Color Temperature

坂東 航 *1 Wataru Bando　三木 光範 *2 Mitsunori Miki　那須 大晃 *1 Nasu Hiroaki　富岡 亮登 *1 Ryoto Tomioka　間 博人 *2 Hiroto Aida

*1同志社大学大学院 理工学研究科
Graduate School of Science and Engineering, Doshisha University

*2同志社大学 理工学部
Department of Science and Engineering, Doshisha University

We have proposed an Intelligent Lighting System which individually provides illuminance and color temperature required by office workers. The Intelligent Lighting System has been introduced in several offices and its effectiveness is recognized. However, the Intelligent Lighting System can ' t realize greatly different illuminance and color temperature required by adjacent office workers because of relation between lighting position and office layout. Therefore, in this research, we propose a new lighting control method which treats illuminance and color temperature satisfactory in the area rather than the specific value by using the index of satisfaction. The verification experiment showed that the proposed method is effective for improving the total satisfaction of all officers. Also, it showed that the proposed method is effective for energy saving lighting control.

1. はじめに

近年，オフィスにおける執務者の知的生産生や快適性の向上への要求の高まりから，オフィス環境の改善に注目が集まっている．また，オフィス環境の中でも光環境に着目した先行研究では，執務者ごとに要求する照度および色温度は異なることが報告されている [1]．そこで，著者らはオフィスにおける執務者の快適性と省エネルギー性の向上を目的とし，各執務者が要求する照度および色温度を最小の消費電力で実現する知的照明システムの研究を行っている [2]．

知的照明システムは，最適化手法に基づいて天井照明を個別に制御することで，執務者が要求する照度および色温度を最小の消費電力で実現する．しかし，使用する天井照明の位置とオフィスレイアウトの関係によって，隣接する執務者が大きく異なる照度および色温度を要求したとき，それらを物理的に実現できない場合がある．

このとき，執務者が満足できる照度および色温度にはある程度の領域があり，また，その領域の広さには個人差があると考えられる．そのため，満足できる領域が広い執務者は要求する照度および色温度を実現せずとも十分満足できる．一方で，満足できる領域が狭い執務者は要求する照度および色温度を実現しないと全く満足できない．そこで，満足できる領域が狭い執務者の要求する照度および色温度を優先的に実現することで全執務者の満足度の合計を向上が可能である．また，満足できる照度と色温度の領域内で提供する照度を下げることで，満足度を損なうことなく省エネルギーな照明制御が可能である．

そこで本研究では，従来のように執務者が要求する照度と色温度を特定の値として捉えるのではなく，照度と色温度に対して満足度という評価指標を用いて領域として捉える．そして，執務者の照度と色温度に対する満足度を考慮した新たな照明制御手法を提案する．提案手法により全執務者の満足度の合計を最大化し，かつ省エネルギーになる最適な照度および色温度を実現する．これにより，知的照明システムによる執務者のさらなる快適性および省エネルギー性の向上を目指す．

連絡先: 坂東 航，同志社大学大学院 理工学研究科 情報工学専攻，京都府京田辺市多々羅都谷 1-3，0774-65-6924，wbando@mikilab.doshisha.ac.jp

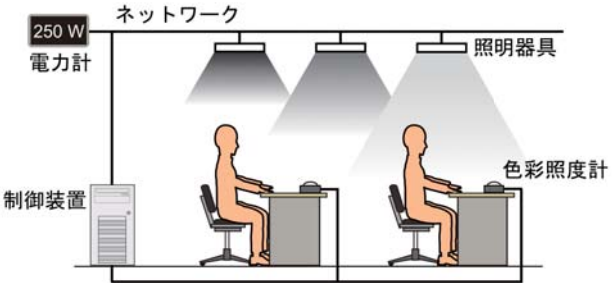


図 1: 知的照明システムの構成

2. 知的照明システム

2.1 知的照明システムの構成

知的照明システムは各執務者が要求する照度および色温度を最小の消費電力で実現するシステムである．知的照明システムの構成を図 1 に示す．知的照明システムは，複数の調光可能な照明器具，照明の制御装置，各執務者の机上面に設置された照度および色温度を測定するセンサ（以下，色彩照度計），および電力計を 1 つのネットワークに接続することで構成する．

各執務者は要求する照度（以下，目標照度）および色温度（以下，目標色温度）を設定する．制御装置は，最適化手法に基づいて各執務者の目標照度および目標色温度を最小の消費電力で実現する点灯パターンを求め，照明器具を個別に調光することで全執務者の目標照度および目標色温度を実現する．

2.2 知的照明システムの制御

知的照明システムにおける制御は，各執務者の目標照度および目標色温度の実現と消費電力の最小化の 2 つを目的とした各照明の光度の最適化問題として捉える．制御アルゴリズムには，大域的最適化問題に対する汎用的アルゴリズムである Simulated Annealing（SA）を基礎とし，回帰係数によっ

て次光度生成に用いる近傍設計を選択する手法を組み込んだ適応的近傍アルゴリズム（Adaptive Neighborhood Algorithm using Regression Cofficient : ANA/RC）や，高速に目標照度および目標色温度の実現と消費電力の最小化が可能な数理計画法を用いたアルゴリズムが用いられる [3].

2.3 目標照度・色温度の実現における物理的制約

一般的なオフィスの天井照明は，オフィス全体が均一な照度および色温度になるように配光角の広い照明が使用され，それぞれ 1.8 m 間隔で設置されている．また，デスクは 1.2 m(W) × 0.7 m(D) のものが使用され，デスクのレイアウトは執務者間の距離が近い対向島型が採用されている．このようなオフィスでは，1 つの照明の光が複数の執務者のデスクに影響を及ぼす．そのため，隣接する執務者が大きく異なる目標照度および目標色温度を設定したとき，各照明を最適な光度で点灯した場合でも各執務者の目標照度および目標色温度を物理的に実現できない場合がある．

このとき，執務者が満足できる照度および色温度にはある程度の領域があり，また，その領域の広さには個人差があると考えられる．そのため，満足できる領域が広い執務者は要求する照度および色温度を実現せずとも十分満足できる．一方で，満足できる領域が狭い執務者は要求する照度および色温度を実現しないと全く満足できない．そこで，満足できる領域が狭い執務者の要求する照度および色温度を優先的に実現することで全執務者の満足度の合計を向上が可能である．また，満足できる照度と色温度の領域内で提供する照度を下げることで，満足度を損なうことなく省エネルギーな照明制御が可能である．

そこで本研究では，従来のように執務者が要求する照度と色温度を特定の値として捉えるのではなく，照度と色温度に対して満足度という評価指標を用いて領域として捉える．満足度は「満足」「やや満足」「普通」「やや不満」「不満」の 5 段階で評価する．被験者実験により照度と色温度に対する満足度を計測し，照度と色温度に対する満足度の特性とその個人差について検証を行う．そして，執務者の照度と色温度に対する満足度を考慮した新たな照明制御手法を提案する．提案手法により全執務者の満足度の合計を最大化し，かつ省エネルギーになる最適な照度および色温度を実現する．

3. 照度・色温度に対する満足度計測実験

3.1 満足度計測実験の概要

照度と色温度に対する満足度の特性と個人差を明らかにするため，20 代前半の被験者 10 名を対象に満足度計測実験を行った．実験環境を図 2 に示す．実験は 7.2 m(W) × 6.0 m(D) × 2.6 m(H) の実験環境を構築し，天井照明には調光・調色可能な LED 照明を 28 灯使用した．

実験中，被験者は実験室中央付近に設置した席に座り，紙面作業として読書を行う．そして，後述する実験手順に従い，机上面に提供されている照度と色温度に対して「満足」「やや満足」「普通」「やや不満」「不満」の 5 段階で満足度の評価を行う．満足度の計測対象となる環境の照度および色温度は机上面の照度が 100 lx から 1000 lx までの 50 lx ごとと，机上面の色温度が 3000 K，3500 K，4200 K，5000 K，6500 K の 5 段階である．

3.2 満足度計測実験の手順

満足度の計測手順について述べる．被験者はまず，計測対象となる机上面の照度と色温度の組み合わせの中から読書をする上で最も良いと感じる照度（以下，選好照度）と色温度（以下，選好色温度）の組み合わせを選択する．そして，このとき

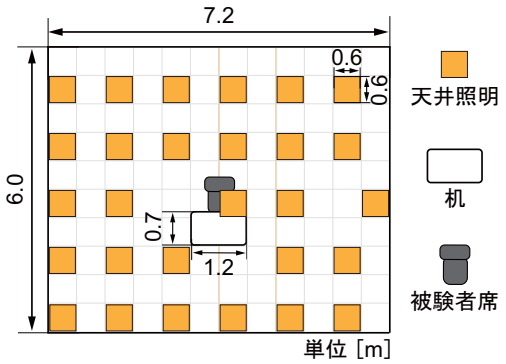


図 2: 満足度計測実験の実験環境（平面図）

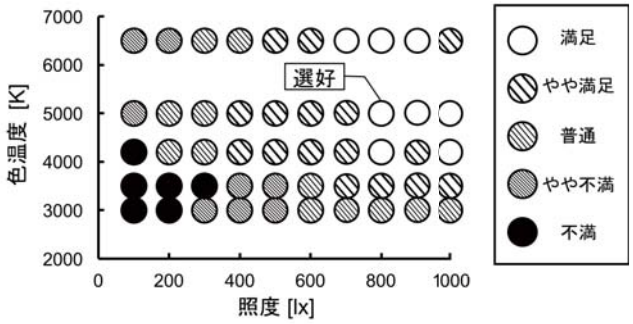


図 3: 満足度計測結果（被験者 A）

選択した選好照度と選好色温度の環境を満足度の中の「満足」に相当する環境とする．その後，実験者が天井照明を一律に調光・調色し，机上面の照度と色温度をランダムに選択した次の計測対象の環境に変更する．照度および色温度の変更後，被験者は変更された照度に対する明順応と色温度に対する色順応のため読書を行いながら 3 分間待機する [4]．そして順応後，被験者は照度と色温度に対して「満足」「やや満足」「普通」「やや不満」「不満」の 5 段階で満足度を評価する．

この実験者によるランダムな机上面の照度と色温度の変更から満足度の評価までの一連の手順を繰り返すことにより照度と色温度に対する満足度の計測を行う．

3.3 満足度計測実験の結果および考察

満足度計測実験の結果の一例を図 3 に示す．図 3 のグラフは被験者 A の満足度計測結果である．グラフ上のプロットはその照度と色温度に対する満足度を表す．白抜きのプロットは「満足」を表し，黒に近づくにつれて「不満」を表す．また,「選好」で示したプロットは被験者が最初に選択した選好照度と選好色温度を表す．

グラフより，被験者 A は 800 lx，5000K を選好照度と選好色温度に選択し，高照度の環境において高い満足度を得ていることがわかる．今回行った 10 人の被験者全てにおいて，選好照度と選好色温度の付近で高い満足度が得られる傾向が見られた．また,「満足」となる領域の広さに関しては，個人ごとに大きく異なった．

4. SVM による満足度の識別モデルの作成

4.1 満足度の識別モデル

満足度に基づいた照明の最適化制御を行うためには，提供されている照度と色温度に対する執務者の満足度を評価する必要がある．そこで本研究では，事前に計測した満足度から満足度の識別モデルを作成し，最適化途中で必要になる任意の照度

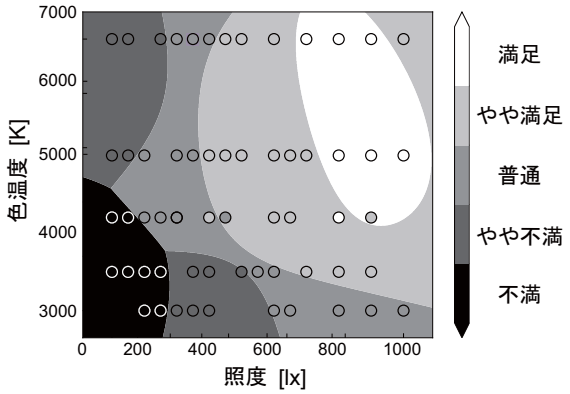


図 4: 満足度の識別モデル（被験者 A）

表 1: 各識別モデルの正解率と F 値

被験者	正解率 [%]	F 値	被験者	正解率 [%]	F 値
A	83.3	0.84	F	73.3	0.64
B	71.6	0.70	G	85.0	0.84
C	83.3	0.82	H	85.0	0.81
D	80.0	0.81	I	75.0	0.68
E	80.0	0.82	J	76.7	0.76
			平均	79.3	0.77

と色温度に対する満足度の評価を行う．満足度の識別モデルの作成には，教師あり学習によるパターン認識手法の 1 つである Support Vector Machine（以下，SVM）を用いる．

本実験では，3 章で計測した被験者ごとの 60 組の照度と色温度に対する満足度を教師データとして，SVM を用いて満足度の識別モデルを作成した．なお，特徴量に使用した照度と色温度は絶対値による差が生じるため，それぞれ 0-1 スケーリングにより標準化を行う．また，SVM のカーネルには RBF カーネルを使用し，識別モデルの性質を決定するコストパラメータ C と RBF パラメータ γ はグリッドサーチにより識別モデルごとに求める．

4.2 識別モデルの評価実験

作成した識別モデルの評価を行うため，教師データに対する一個抜き交差検証を行う．具体的には，60 組の教師データから 1 組をテスト用として抜き取り，残りの 59 組の教師データを基に識別モデルを作成し，作成した識別モデルでテスト用の教師データを推定する．これを 60 組の全ての教師データに対して行うことで，各識別モデルの正解率と F 値を評価する．

4.3 評価実験の結果および考察

作成した識別モデルの一例を図 4 に示す．図 4 は被験者 A の満足度計測実験の結果から作成した満足度の識別モデルである．グラフ上のプロットは教師データに用いた満足度を表す．また，グラフの背景の色分けは識別モデルにより識別された各満足度の領域を表す．

次に，各被験者の識別モデルの学習データに対する一個抜き交差検証による正解率と F 値を表 1 に示す．一個抜き交差検証の結果，正解率は最大で 85.0%，最小で 71.6%，平均 79.3%となった．正解率が比較的低かった被験者 B や被験者 F の識別器に関しては，学習データの中に外れ点が多かったことが原因として考えられる．また，F 値に関しては最大で 0.84，最小で 0.64，平均 0.77 となった．識別モデルによって大きく正解率や F 値が下がった結果はなく，SVM による満足度評価の有効性を示した．

5. 満足度を考慮した照明の個別分散制御

5.1 提案手法の概要

執務者の満足度を考慮した照明制御により，全執務者の満足度の合計を最大化しつつ，消費電力を最小化する新たな照明制御手法を提案する．提案手法では，4 章で述べた満足度の識別モデルを用いて，各執務者の満足度の評価を行う．そして，後述する制御アルゴリズムによって全執務者の満足度の合計を最大化しつつ，消費電力を最小化する．

5.2 制御アルゴリズム

提案手法の制御アルゴリズムは汎用的な最適化手法である確率的山登り法の考え方を基に作成した．以下に本アルゴリズムの制御の流れを示す．

(1) 識別モデルにより評価した各執務者の満足度と電力計から取得した消費電力量を基に目的関数値を算出する．
(2) ランダムに選択した執務者の目標照度および目標色温度を満足度が下がらない領域内でランダムに変化する．
(3) 知的照明システムによる照明制御を行う．
(4) 再び，識別モデルにより評価した各執務者の満足度と電力計から取得した消費電力量を基に目的関数値を算出する．
(5) 目的関数値が向上している場合は目標照度および目標色温度の変更を受理し，そうでない場合は変更を棄却する．
(6) 項目 (1) に戻る．

次に，提案手法の制御アルゴリズムの項目（1）および（4）で使用する目的関数について述べる．提案手法の目的は全執務者の合計満足度の最大化および消費電力の最小化である．そのため，目的関数は式（1）のように定式化する．式 (1) は各執務者の満足度 S の合計と消費電力 P から構成され，この目的関数を最大化することを目的とする．また，各執務者の満足度 S はその執務者の識別モデル g と現在の提供されている照度 I_c および色温度 T_c から算出し，「満足」「やや満足」「普通」「やや不満」「不満」をそれぞれ 5〜1 としてスコア化する．

$$f = w \times \sum_{i=1}^{n} S_i - P \quad (1)$$
$$S_i = g_i(I_{c_i}, T_{c_i})$$

n：執務者数，i：執務者番号, w：重み
S：満足度，g：識別モデル, P：消費電力 [W]
I_c：現在照度 [lx]，T_c：現在色温度 [K]

6. 提案手法の有効性検証実験

6.1 検証実験の概要

提案手法の有効性を示すため，シミュレーションによる検証実験を行った．実験に用いたシミュレーション環境を図 5 に示す．本実験は 3.6 m(W) × 5.4 m(D) × 2.6 m(H) の小規模の模擬オフィスを想定したシミュレーション環境を構築し行った．照明は 1.8 m 間隔で 6 灯設置し，机は一般的なオフィスで使用される対向島型レイアウトで 6 台設置した．

各机には 3 章の被験者 10 名が着席することを想定した．10 名中 6 名を重複がないように選択し，それぞれの机にランダムに着席した．全ての組み合わせ 210 通りのパターンに対して標準手法と提案手法による執務者の満足度のシミュレーションを行った．提案手法で用いる識別モデルには 4 章で作成した各被験者の識別モデルを用いた．また，各執務者の目標照度

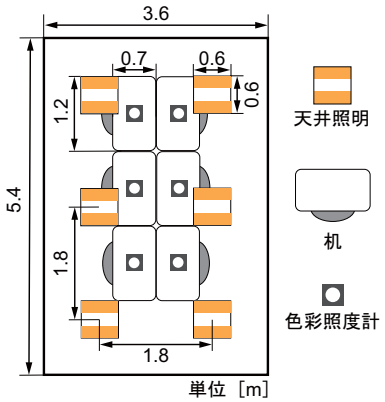


図 5: シミュレーション環境（平面図）

表 2: 各執務者の目標照度・目標色温度

執務者	目標照度 [lx]	目標色温度 [K]
A	800	5000
B	800	3000
C	300	4200
D	700	5000
E	700	4200
F	900	5000
G	300	3500
H	500	3000
I	700	5000
J	500	4200

および目標色温度は 3 章の満足度計測実験の際に各被験者が選択した選好照度および選好色温度を設定した．各執務者の目標照度および目標色温度を表 2 に示す．シミュレーション結果から，6 名の執務者の平均満足度および各満足度の執務者が占める割合と消費電力を比較し，提案手法の有効性を検証する．

6.2 シミュレーション結果および考察

標準手法と提案手法による執務者 6 名の平均満足度の分布を図 6 に示す．図 6 より，標準手法と比較して提案手法の方が高い平均満足度を実現する頻度が増加した．また，特に平均満足度が 4 以上、つまり平均的に執務者の満足度が「やや満足」以上となる頻度が大きく増加した．

次に，標準手法と提案手法による各満足度の執務者が占める割合を図 7 に示す．図 7 の (a) より，標準手法では「やや満足」「普通」の執務者の割合がそれぞれ 35.8%，50.4%であり，2 つで全体の 8 割以上を占め，「満足」の執務者の割合は 13.3%と 1 割程度であった．一方で，図 7 の (b) より，提案手法では「やや満足」「普通」の執務者の割合はそれぞれ 33.3%，38.7%と 2 つで全体の 7 割程度であり，「満足」の執務者の割合は 27.6%と全体の 3 割程度であった．提案手法と標準手法を比較すると「満足」の執務者の割合が 2 倍近く増加した．これより，提案手法の執務者の満足度向上における有効性を示した．

次に，標準手法と提案手法による消費電力を表 3 に示す．消費電力は照明の光度が最大のときを 100%として各照明の光度の合計から算出した．標準手法の消費電力は 43.0%であるのに対して，提案手法では 40.5%となり，2.5%低下した．また，標準誤差はそれぞれ 0.3%と 0.5%となった．これより，提案手法は標準手法と比較して，平均の消費電力は低下することを示した．

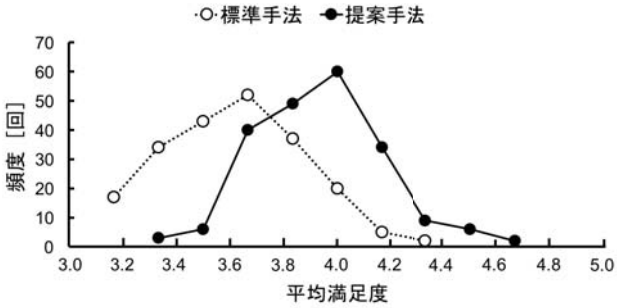


図 6: 平均満足度の分布（210 回のシミュレーション結果）

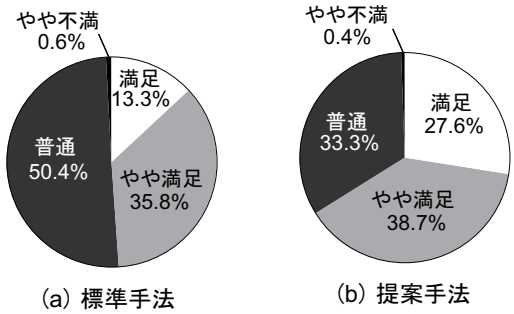


図 7: 各満足度の執務者の割合

表 3: 消費電力 [%]

	標準手法	提案手法
平均	43.0	40.5
標準誤差	0.3	0.5

7. 結論

本研究では，照度と色温度に対する執務者の満足度を考慮した新たな照明制御手法を提案した．提案手法は執務者ごとに作成した満足度の識別モデルにより満足度の評価を行い，確率的山登り法を基にした制御アルゴリズムにより，全執務者の合計満足度の最大化および消費電力の最小化を行う．シミュレーションによる検証実験により，提案手法が標準手法と比較して執務者の合計満足度および「満足」の執務者の割合が向上することを示した．また，平均の消費電力は提案手法の方が低下することを示した．

本実験はシミュレーション上での検証であったため，今後は実環境の被験者実験により実際の満足度を計測し，提案手法の有効性の確認を行う．

参考文献

[1] P.R.Boyce, N.H.Eklund, andS.N.Simpson, Individual Lighting Control: Task Performance, Mood, and Illuminance, Journal Of The Illuminating Engineering Society, Vol.29, pp.131-142 (2000).

[2] 芦辺 麻衣子，三木 光範，廣安 知之, 知的照明システムにおける照度と色温度の個別分散制御，情報処理学会研究報告，バイオ情報学，Vol.2008, No.126, pp.69-72 (2008).

[3] Ryohei Jonan, Mitsunori Miki, Naoki Kawata, Daichi Terai and Hiroto Aida, Implementation to Provide Individual Illuminance and Color Temperature in an Intelligent Lighting System by Estimating the Color Temperature, The 2016 International Conference on Atifical Intelligence (ICAI2016).

[4] I. Kuriki and D.I.A MacLeod, Chromatic adaption after-effects on luminance and chromatic channels, Taylor and Francis, London (1997).

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

ガスセンサシステムにおける伝達関数を用いた ガス識別機械学習モデルの構築

Development of Machine Learning Models for Gas Identification Based on Transfer Functions

今村岳[*1] 吉川元起[*1,2] 鷲尾隆[*3]
Gaku Imamura Genki Yoshikawa Takashi Washio

[*1] 物質・材料研究機構 国際ナノアーキテクトニクス研究拠点
International Center for Materials Nanoarchitectonics, National Institute for Materials Science

[*2] 筑波大学大学院 数理物質科学研究科 物質・材料工学専攻
Materials Science and Engineering, Graduate School of Pure and Applied Science, University of Tsukuba

[*3] 大阪大学 産業科学研究所
The Institute of Scientific and Industrial Research, Osaka University

Various applications of gas sensors have been envisioned in many fields along with the recent development in information and communication technology (ICT). Gas Identification plays a central role in gas sensor applications including artificial olfaction. In the conventional gas identification protocol, however, a strict gas flow control is required to reproduce comparable sensing signals. To eliminate such a severe constraint and identify gas species with an arbitrary gas injection pattern, here we report an analysis approach based on transfer function, which represents the relationship between inputs and outputs (i.e. a gas input pattern and the resultant sensing signals). In this study, we developed machine learning models which can identify gas species from an arbitrary gas injection pattern. Even though the sample gases were randomly injected, we successfully identified solvent vapors by the transfer functions with the classification accuracy of 0.98±0.03. This study provides a versatile data analysis platform which is independent of gas flow control.

1. 序論

モノのインターネット（IoT）に代表されるネットワークシステムの発達に伴い、次世代デバイスの基礎技術としてガスセンサが注目されている。特に、複雑なガスの混合物であるニオイを検知・識別する人工嗅覚の開発はガスセンサの究極の応用であり、このようなネットワークシステムと組み合わせることで食品、環境、安全、医療などの様々な分野での応用が期待されている。ガスセンサを用いてガス種の識別を行う場合、測定により得られるシグナルから、ガス種に固有の特徴を抽出する必要がある。このような特徴を抽出するためには、マスフローコントローラやポンプなどによって流量を精密に制御して測定を行う必要があった。[Imamura 2016] しかし、全ての測定において流量を厳密に制御することは実用上困難であり、ガスセンサシステムの社会実装の妨げとなっていた。

そこで本研究では、制御システムの概念である伝達関数をセンサシグナルの解析に導入し、これを記述子とした機械学習モデルを構築することで、任意の流量制御でのガス識別を可能とする新規データ解析手法の開発を行った。これにより、従来必要であった厳密な流量制御が不要となり、流量がランダムに変化するような場合でも、ガスの識別を行うことが可能となる。さらに、伝達関数に注目することで、異なる流量制御により得られた測定データを相互に比較することができることから。人工嗅覚の実現に必要不可欠な「ニオイのライブラリ」の構築を行うことが可能となる。

連絡先：IMAMURA.Gaku@nims.go.jp

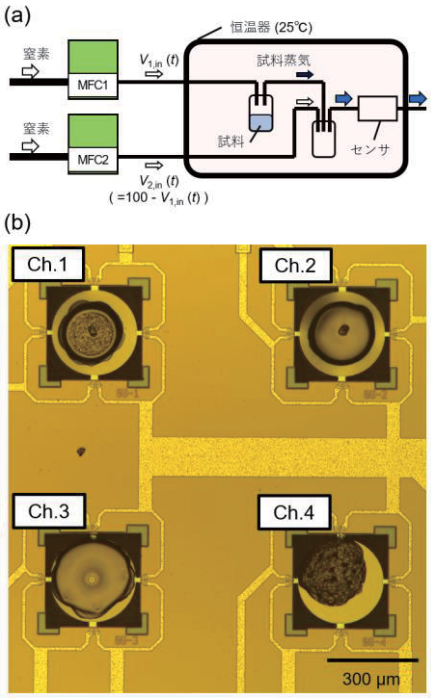


図 1. (a) ガス測定システム。(b) MSS チップ光学顕微鏡写真。

2. 伝達関数

伝達関数は、ある入出力系における入力と出力の関係を示したものである。センサの応答が、あるガス種 g に対して線形な応

答を示すと仮定すると、入力パターン x(t)に対するセンサ出力 y(t)は、伝達関数 $h_g(t)$を用いて以下の式で記述される。

$$y(t) = \int_0^t h_g(\tau)x(t-\tau)d\tau \qquad (1)$$

ここで、$h_g(t)$は入力に依存しないことから、$h_g(t)$に注目することによりガスの識別が可能となる。

フーリエ変換することで、式(1)を周波数空間での表現に直すと、

$$Y(f) = H_g(f)X(f) \qquad (2)$$

となる。ここで、X(f)、Y(f)、$H_g(f)$は、それぞれ周波数空間における入力、出力、伝達関数である。

3. ガス測定

図 1a に本研究で用いた実験系を示す。バイアル瓶にいれた試料の蒸気を、2 つのマスフローコントローラ(MFC)を用いて濃度を変化させてセンサに導入した。濃度の変化は MFC1、MFC2 の総流量を 100 sccm に保ちながら流量の比を変化させることにより行った。試料としてはエタノール、トルエン、ヘキサン、水の 4 つの溶媒を用いた。本研究では、ガスセンサとして膜型表面応力センサ(Membrane-type Surface stress Sensor, MSS)を用いた。MSS は、感応膜と呼ばれる部位がガスを吸着することに伴い生じる表面応力を電気的に読み取ることで動作するセンサである。[Yoshikawa 2011] 本研究では、感応膜として poly(vinylidene fluoride)、polysulfone、poly(4-methylstyrene)、polycaprolactone をチャンネル 1～4 に塗布した MSS センサチップを用いた。(図 1b) 測定は、MSS にブリッジ電圧-0.5 V を印加し、サンプリング周波数 20 Hz で、各溶媒につき 20 秒ずつ 30 回行った。

4. 機械学習モデル

各測定データについて、式(2)にしたがい各チャンネルにおける伝達関数 $H_g(f)$を計算した。MFC の切り替え時間がおよそ 0.5 秒程度であることから、ナイキストの定理にしたがい、伝達関数のうち 1 Hz 以下の周波数成分のみを解析に用いた。(0.05～1 Hz の 20 成分) 周波数成分は複素数で与えられるため、各周波数成分は絶対値と位相の 2 つ変数で表現した。したがて、チャンネル数が 4、解析に用いる周波数成分が 20、周波数

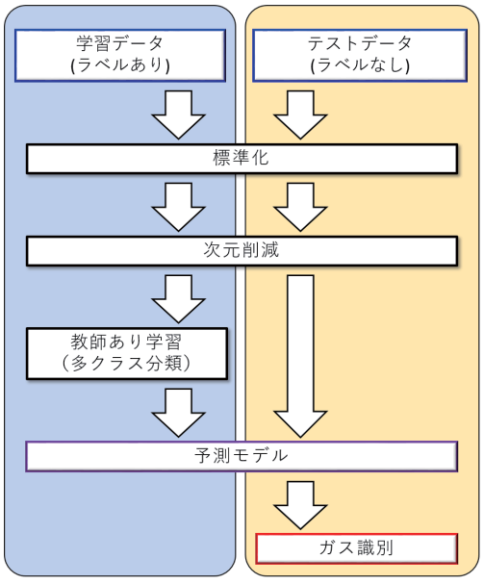


図 2. 識別モデル構築手順。

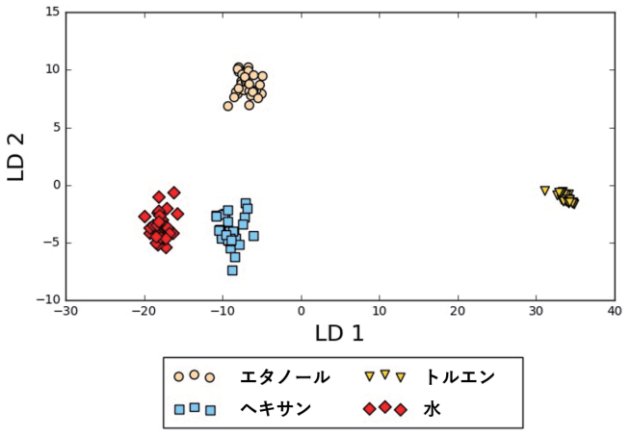


図 3. LDA スコアプロット。

成分の表現が 2 変数であることから、120 次元のデータとして解析を行った。

ガス識別モデルの構築手順を図 2 に示す。全データを学習データとテストデータに分け、学習データで構築したモデルをテストデータにて評価した。データはまず標準化され、次元削減された後に分類器により識別される。ハイパーパラメータの最適化およびモデルの評価は、10×10 の交差検証により行った。

5. 結果・考察

識別モデルの構築に先立ち、得られた $H_g(f)$のデータセットに対して線形判別分析(LDA)を行った。図 3 に結果を示す。このように、伝達関数の違いを反映して、特徴量空間上でガス種ごとにクラスターが形成され、互いに分離することが確認された。

次に、4 つの溶媒蒸気の識別モデルを構築した。本研究では、次元削減として主成分分析(PCA)を用い、分類器としてロジスティック回帰(LR)とサポートベクトルマシン(SVM)の 2 種類を用いた。その結果、LR で 0.94±0.04、SVM で 0.98±0.03 の精度での識別に成功した。

6. まとめ

本研究では、ガスセンサを用いたガス測定において、伝達関数という入力と出力の関係を記述子としたガス識別を行う機械学習モデルの構築を行った。これにより、従来は厳密な流量制御が必要であったガスの識別が、任意の流量制御で簡便に行えることが示された。本研究では MSS をガスセンサとして用いたが、伝達関数に基づく解析法は MSS に限らず、酸化物半導体ガスセンサや水晶振動子などあらゆるガスセンサに適用可能である。伝達関数は、入力となるガスの流量制御に依存しないことから、伝達関数に注目することで、様々な流量制御にて測定されたデータが相互に比較可能となる。したがって、人工嗅覚の実現に必要不可欠な「ニオイのライブラリ」の構築が可能となり、実用的な人工嗅覚の実現が期待される。

参考文献

[Imamura 2016] G. Imamura, K. Shiba, G. Yoshikawa: Smell identification of spices using nanomechanical membrane-type surface stress sensors, Japanese Journal of Applied Physics, the Japan Society of Applied Physics , 2016.

[Yoshikawa 2011] G. Yoshikawa, T. Akiyama, S. Gautsch, P. Vettiger, H. Rohrer: Nanomechanical Membrane-type Surface Stress Sensor, Nano Letters, American Chemical Society, 2011.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

量子回路マッピングの最適化

Minimum Cost Mapping of Quantum Circuits to Quantum Computers

井床　利生 *1　　ルディ　レイモンド *1　　今道　貴司 *1
Toshinari Itoko　　Rudy Raymond　　Takashi Imamichi

*1IBM 東京基礎研究所
IBM Research - Tokyo

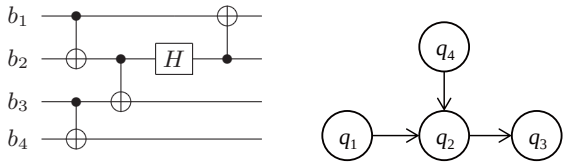
Recent technological progress has brought us closer to quantum computers that can outperform current classical computers. However, such quantum computers in the near future will likely be very noisy and suffer from limited coupling architecture. A quantum algorithm must be compiled into a quantum circuit, most often by adding supplementary quantum gates, to satisfy the coupling restriction of quantum hardware. We propose a novel formulation of mapping quantum circuits to quantum computers by introducing a dependency graph that represents the partial order structure of the circuit essential in the mapping. The formulation enables us to leverage techniques in combinatorial search to find the mapping with minimum cost of additional gates. We obtain better solutions for cost-optimal mapping of standard benchmark circuits.

1. はじめに

近年の量子コンピューターのハードウェア技術の進展により、ノイズ付きで量子ビット数が中小規模の量子コンピューター（近似量子コンピューター）が実現し、量子アルゴリズムを実機で動かせる時代が到来した。誤り耐性を備えた理想的な万能量子コンピューターの実現にはまだ相当の年月を要すると考えられているが、数年内に実現される近似量子コンピューターの精度や規模でも、量子化学やサンプリングなど特定の分野のタスクでは古典コンピューターを上回る計算能力を持つのではないかと期待されている。近似量子コンピューターについては [Preskill 18] を参照されたい。

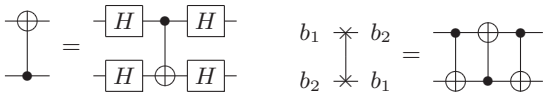
一般に量子アルゴリズムを実装した量子プログラムを量子コンピューター上で実行する場合、量子回路にコンパイルする必要がある。量子回路は、図 1a のようなダイアグラムで表現される。量子ビットに対応する水平線を描き、各量子ビットに左から右へと作用させる順にゲートを配置する。図 1a の例では、2 量子ビットゲートの CNOT（制御ビットを ●、ターゲットビットを $\oplus$ と表記）と 1 量子ビットゲートのアダマールゲート（H と表記）が使われている。本研究では、量子ゲートとして、1 量子ビットゲートおよび CNOT のみを考える。これは任意の量子計算をこれらのゲートのみで構築可能であるという事実に基づく。なお、本研究では量子回路の古典的な組合せ構造にのみ着目するため、量子回路で実現される量子計算の内容には立ち入らない。量子計算の詳細については例えば [Nielsen 10] などを参照されたい。

量子プログラムのコンパイル時には、量子コンピュータの物理的制約を満たすために、与えられた量子回路を物理的に実行可能な等価な量子回路に変換する必要がある。そのような変換を**量子回路マッピング**と呼ぶ。主要な物理的制約として、物理的に隣接する量子ビット間にしか CNOT を配置できないという**接続制約**がある。接続制約は、図 1b のような、量子ビットを節点とし CNOT を実行可能な量子ビット対を枝とした有向グラフ（**接続制約グラフ**）として表現される。枝の始点が制御ビット、終点がターゲットビットに相当する。例えば、図 1a の回路上の量子ビット $b_{1\text{–}4}$ を図 1b の物理的量子ビット



(a) 量子回路　　(b) 接続制約グラフ

図 1: 量子回路 (a)、および、接続制約グラフ (b)



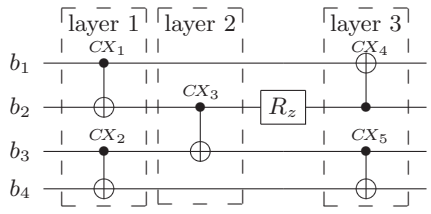
(a) CNOT の方向反転　　(b) スワップゲート

図 2: 接続制約の充足手段

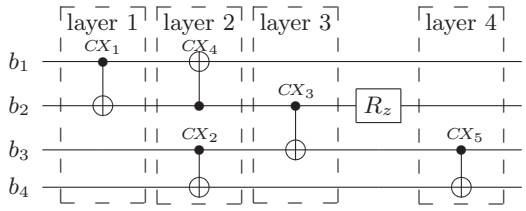
$q_{1\text{–}4}$ に配置した場合、b_3 から b_4 への CNOT と b_2 から b_1 への CNOT はそのままでは実行できない。後者は図 2a のように CNOT の前後にアダマールゲートを挿入し方向を逆転させることで実行可能にできる。前者を実行可能にするには、接続制約グラフ上で b_3 と b_4 配置が隣接するまで量子ビット対のスワップを行う必要がある。そのようなスワップは図 2b に示すスワップゲートによって実現できる。いずれにせよ接続制約を満たすマッピングを行うには、元の回路にゲートを追加する必要がある。しかし、ゲートの追加はノイズおよび回路長の増大に直結する（特に誤り耐性を持たない近似量子コンピューターにおいてノイズの増大は計算結果の誤り率の増加を意味する）ため最小限に抑えることが求められる。その意味で量子回路マッピングにおける追加ゲート数の最小化は量子コンピューターの実効性能に影響を与える重要な技術といえる。

本研究では、現在の近似量子コンピューターにおいて、1 量子ビットゲートに比べ CNOT の誤り率が数倍〜数十倍も大きいことを踏まえ、スワップゲートの追加コストのみに注目し、

連絡先: 井床　利生，IBM 東京基礎研究所，itoko@jp.ibm.com



(a) ある量子回路の三層分割



(b) 等価な量子回路の四層分割

図 3: 等価な量子回路に対する異なる層分割

接続制約の下で最小の追加スワップゲート数（最小スワップ数）を達成する量子回路マッピングを求める問題を扱う。そして当問題に対して、ゲートの実行順序の可換性を考慮した新しい定式化を与えると共に、その定式化に基づく厳密解法を提案する。

2. 背景

量子回路マッピングに関する先行研究の多くは、接続制約グラフの構造を一次元パスや二次元格子に限定したものが多かったが、2017 年に公開された IBM Q systems [IBM Q 17] の接続制約グラフがそのような特殊な構造を持たなかったこともあり、グラフ構造を限定しない問題に対する研究が 2017 年以降相次いで発表された [Bhattacharjee 17, Zulehner 17, Siraichi 18]。しかし、それらの研究はいずれもゲートの実行順序の可換性を考慮しておらず、また、入力回路に対する層分割を固定した定式化に基づいており、最適値が層分割の与え方に依存するという課題があった。ここで量子回路の**層**（*layer*）とは（接続制約がない場合に）並列実行可能な CNOT の集合のことである。

図 3 に等価な二つの回路に対して異なる層分割を行った場合に、異なる最小スワップ数が得られる例を示す（R_z は 1 量子ビットゲートの一種）。図 3a の回路は三層、 図 3b は四層だが、図 4 に示す 2 量子ビットゲートの可換則を考慮する（CX_4 に対して図 4a、図 4b の可換則を順に適用する）と等価であることが分かる。そして、図 3a の層分割の下での最小スワップ数は 2 であるが、図 3b の層分割の下での最小スワップ数は 1 である。

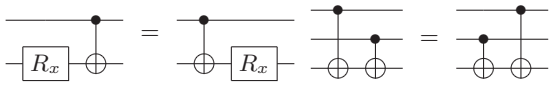
我々は上記課題を克服する定式化を次節で提案する。

3. 定式化

まず定式化に必要な用語を定義する。図 1a のように量子回路マッピングにおいて入力として与えられる回路を**入力量子回路**と呼び、入力量子回路上の量子ビット集合（**入力量子ビット**）を $B = \{b_1, \ldots, b_{|B|}\}$ で表す。また、出力として得られる物理的に実行可能な量子回路を**物理量子回路**と呼び、物理量子回路上の量子ビット集合（**物理量子ビット**）を $Q = \{q_1, \ldots, q_{|Q|}\}$ で表す。入力量子ビット B の物理量子ビット Q への割り当てを**配置**（*layout*）と呼び、$(b_1, b_2, b_3) \mapsto (q_1, q_2, q_3)$、もしくは入力量子ビットの順序を固定して単純に (q_1, q_2, q_3) と表す。因みに、入力量子ビット数と物理量子ビット数は同じと仮定できる（$|B| < |Q|$ の場合は B に補助ビットを追加し $|B| = |Q|$ とできる）ので、配置は順列ともみなせる。図 1b のように物理量子ビットを頂点とし CNOT を実行可能な対を枝としたグラフを**接続制約グラフ**と呼び、$C = (V_C, E_C)$ で表す。ここで C の頂点集合 $V_C = Q$ である。なお、本研究では CNOT の方向反転に要するコストは考慮しないため、以降では接続制約グラフを無向グラフとみなす。



(a) R_z–control　　(b) Control–control



(c) R_x–target　　(d) Target–target

図 4: 量子ゲートの代表的な可換則

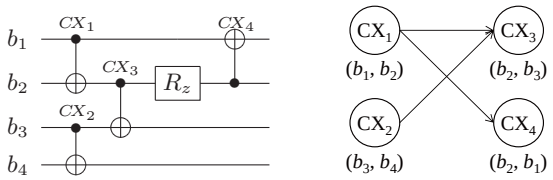


図 5: 入力量子回路（左）とその依存グラフ（右）

一般的に量子回路マッピングは、与えられた入力量子回路に対し、接続制約グラフで表される制約を満たすような物理量子回路への変換を求める問題として定式化される。我々は、前節で見た課題を解決する定式化を行うため、入力量子回路と図 4 に示す量子ゲート可換則から求められる**依存グラフ** $D = (V_D, E_D)$ を定義する。図 5 に示すように、依存グラフ D の頂点集合 V_D は CNOT の集合であり、各 CNOT には作用対象の量子ビット対がラベルとして付与される。また、枝集合 E_D には CNOT の実行順序に対する依存関係、すなわち、$(CX_i, CX_j) \in E_D$ ならば CX_i を必ず CX_j より先に実行する必要がある、という関係が保持される。なお、[Matsuo 11] で上記依存グラフに似たグラフが考えられているが、量子ゲート可換則が考慮されていない点で明確に異なっている。

依存グラフを用いることで、最小スワップ数の量子回路マッピングを求める問題は、次のような組合せ最適化問題として定式化できる。

最小スワップ数量子回路マッピング　接続制約グラフ C および入力量子回路の依存グラフ D が与えられたもとで、C を充足するような、初期配置 l_0 およびゲート系列 I_D で、I_D 中のスワップゲート数が最小となるものを求めよ。

ここで、D に対する**ゲート系列** I_D とは、CNOT およびスワップゲートのリストで、全ての CNOT の順序が D の与える半

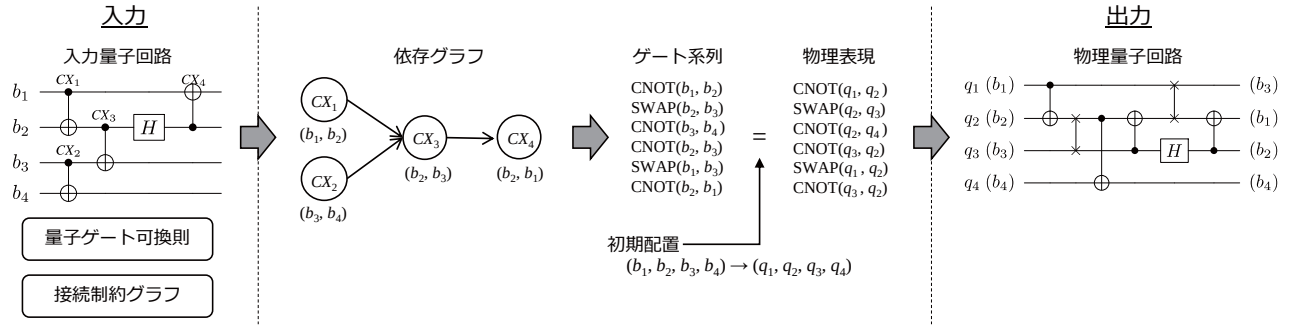


図 6: 量子回路マッピングの流れ

順序関係に矛盾しない（つまりトポロジカル順序をなす）ものとする。また、ゲート系列 I_D の全てのゲート系列の作用量子ビットは入力量子ビット B で表現されるが、初期配置 l_0 を与えることで、作用量子ビットを物理量子ビット Q を用いた表現に変換することもできる。そのような表現を初期配置 l_0 に対する物理表現 $I_D^{ph}(l_0)$ と呼ぶことにする。初期配置 l_0 およびゲート系列 I_D が C を充足するとは、$I_D^{ph}(l_0)$ の全てのゲートの作用量子ビット対が C の枝になっていることを意味する。また、依存グラフの構築の際に 1 量子ビットゲートの情報を記憶しておけば、得られた $I_D^{ph}(l_0)$ から最終出力である物理量子回路を復元することは難しくない。

以上、量子回路マッピングの全体の流れを図 6 にまとめる。

4. アルゴリズム

本節では、最小スワップ数量子回路マッピングの厳密解法を提案する。まず、**状態** (l, R) を、配置 l と残存 CNOT 集合 R のペアとして定義する。但し、**残存 CNOT 集合**は、依存グラフ D を半順序集合と見た時の上方集合（upper set）に限定した V_D の部分集合とする。例えば、図 6 中の依存グラフの残存 CNOT 集合は、次のいずれかである：$\{CX_1, CX_2, CX_3, CX_4\}$、$\{CX_2, CX_3, CX_4\}$、$\{CX_1, CX_3, CX_4\}$、$\{CX_3, CX_4\}$、$\{CX_3\}$、$\{CX_4\}$、$\emptyset$。また、残存 CNOT 集合 R と配置 l に対して、**R からの l に対する残存 CNOT 集合**を、配置 l の下で接続グラフ C 上で実行可能な先頭の CNOT を R から除いた残りの CNOT 集合と定義する。例えば、図 6 の依存グラフにおいて、$\{CX_1, CX_2, CX_3, CX_4\}$ からの配置 (q_1, q_2, q_3, q_4) に対する残存 CNOT 集合は、先頭の CX_1 を実行できるが他は実行できないため $\{CX_2, CX_3, CX_4\}$ となる。状態間の遷移はスワップゲートの挿入によって発生する。例えば、状態 $((q_1, q_2, q_3, q_4), \{CX_2, CX_3, CX_4\})$ から、b_2 と b_3 をスワップし q_3 と q_2 に配置を変えると、状態は $((q_1, q_3, q_2, q_4), \{CX_4\})$ に遷移する。

任意の初期状態から出発し状態 (l, R) に到達するのに必要な最小スワップ数を $f(l, R)$ で表すとする。ここで**初期状態**は、任意の配置 l と、V_D からの l に対する残存 CNOT 集合 R_0 を用いて、(l, R_0) と表される状態とする。すると、最小スワップ数量子回路マッピングの最適値は、あらゆる配置 l に対する $f(l, \emptyset)$ の最小値となる。その値はアルゴリズム 1 で求められる。アルゴリズムはまず初期状態に対する f の値を 0 に設定する。次に一回のスワップで到達可能な状態の f の値を更新し、その次に二回のスワップで到達可能な状態の f の値を更新し、と順に続ける。空の残存 CNOT 集合を持つ状態に到達したら終了する。最適値だけでなく最適解すなわちゲート系列 I_D を得る必要がある場合には、17 行目の直前で $f(l', R') > 1 + f(l, R)$ の場合に、直前の状態 (l, R) から現在の状態 (l', R') を関連付けることで、e（スワップゲート）と $R' \setminus R$（CNOT 集合）を記憶しておけばよい。

アルゴリズム 1 最小スワップ数量子回路マッピングの厳密解法

IN: 量子ビット B をもつ入力量子回路の依存グラフ $D = (V_D, E_D)$ および接続制約グラフ $C = (Q, E_C)$
OUT: C を充足する D のマッピングにおける最小スワップ数

```
1: S ← ∅    // アクティブ状態
2: for all B の Q への配置 l do
3:    R_0 ← V_D からの l に対する残存 CNOT 集合
4:    f(l, R_0) ← 0
5:    S ← S ∪ {(l, R_0)}
6: end for
7: while True do
8:    S' ← ∅
9:    for all 状態 (l, R) ∈ S do
10:      for all 枝 e ∈ E_C do
11:         l' ← 配置 l から e をスワップした後の配置
12:         R' ← R からの l' に対する残存 CNOT 集合
13:         if f(l', R') が未定義 then
14:            f(l', R') ← +∞
15:            S' ← S' ∪ {(l', R')}
16:         end if
17:         f(l', R') ← min{f(l', R'), 1 + f(l, R)}
18:         if R' = ∅ then
19:            return f(l', R')
20:         end if
21:      end for
22:   end for
23:   S ← S'
24: end while
```

5. 実験

前節に示したアルゴリズムの性能および前々節に示した定式化の有効性を確認するための実験を行った。アルゴリズムは量子計算向けソフトウェア開発キットである QISKit [QISKit 17] をベースに Python 言語で実装した。実験はノート PC（Intel Core i5-5300U CPU 2.3 GHz、8 GB メモリ）上で行った。実験に用いた全てのインスタンスに対して、各計算に要した時間は 30 秒以内であった。

表 1 に既存手法 [Shafaei 14, Lye 15] および提案手法を用いて二次元格子接続制約の下で量子回路マッピングを求めた場合

の必要スワップ数を示す。量子回路データセットとしては、比較対象の先行研究で用いられている RevLib [Soeken 12] を採用し、QISKit でサポートされる OpenQASM 形式 [Cross 17] に変換した上で使用した。全回路に対して混合整数計画 (MIP) ベースのヒューリスティクスである [Shafaei 14] と同等かよりよい結果が得られることを確認した。回路 3_17_13 と hwb4_52 では、Pseudo-Boolean Optimization (PBO) を用いた厳密解法である [Lye 15] よりもよい結果が得られた。原因としては、前処理の回路の変換において、3 量子ビット以上のゲートを 2 量子ビット以下のゲートに分解する規則が一意でないことが考えられるが、[Lye 15] に分解規則についての記述がないため断定はできない。

表 1: 二次元格子接続制約下での量子回路マッピングの解法毎のスワップ数

回路	$\|B\|$	格子形状	MIP[a]	PBO[b]	提案手法
3_17_13	3	2×2	6	4	3
4_49_17	4	2×2	13	—	7
4gt11_84	5	2×3	2	1	1
4mod5-v1_23	5	2×3	11	—	7
decod24-v3_46	4	2×2	3	2	2
hwb4_52	4	2×2	9	7	6
rd32-v0_67	4	2×3	2	2	2

[a] MIP [Shafaei 14]. [b] PBO [Lye 15].

加えて、本論文で提案した定式化によって層を固定した定式化よりも最小スワップ数が減少することを確認するために、人工ランダム回路を用いた実験を行った（表 2)。データとしては、R_z、H、CNOT をそれぞれ 25%、25%、50%の確率で 100 個生成したランダム回路 10 セットを用いた。表中の最小スワップ数は 10 セットでの平均値である。アルゴリズムは、両定式化に対してそれぞれの厳密解法を実装して用いた。接続構造によらず本論文で提案した定式化によって、よりよい量子回路マッピングが行えることを確認できた。

表 2: 最小スワップ数の定式化による違い

$\|B\|$	接続構造	層固定定式化	提案定式化
6	一次元パス	32.4	29.6
5	一次元パス	25.9	23.5
6	二次元格子 (2×3)	12.6	11.9
5	ibmqx4 [IBM QX4 17]	10.4	8.0

6. おわりに

本研究では、量子ゲートの可換則を考慮した最小スワップ数量子回路マッピングの新しい定式化とその定式化に基づく厳密解法を提案し、計算機実験によりその有効性を確認した。今後の研究課題としては以下が考えられる。定式化に関しては、目的関数の拡張（例えば、1 量子ビットゲートのコストや回路の層数を考慮する）や、考慮する可換則の拡張（より複雑な三つ以上の量子ゲートが関係するような可換則も考慮する）などが考えられる。アルゴリズムに関しては、今後のハードウェアの量子ビット数の増大に対応できるような性能のよいヒューリスティクスの開発が重要になってくると考えられる。

参考文献

[Bhattacharjee 17] Bhattacharjee, D. and Chattopadhyay, A.: Depth-Optimal Quantum Circuit Placement for Arbitrary Topologies, *arXiv preprint arXiv:1703.08540* (2017)

[Cross 17] Cross, A. W., Bishop, L. S., Smolin, J. A., and Gambetta, J. M.: Open Quantum Assembly Language, *arXiv preprint arXiv:1707.03429* (2017)

[IBM Q 17] IBM Q, : IBM Q (2017), https://www.research.ibm.com/ibm-q/

[IBM QX4 17] IBM QX4, : IBM QX4: Raven (2017), https://github.com/QISKit/ibmqx-backend-information/blob/master/backends/ibmqx4/README.md

[Lye 15] Lye, A., Wille, R., and Drechsler, R.: Determining the minimal number of swap gates for multi-dimensional nearest neighbor quantum circuits, in *Design Automation Conference (ASP-DAC), 2015 20th Asia and South Pacific*, pp. 178–183 (2015)

[Matsuo 11] Matsuo, A. and Yamashita, S.: Changing the gate order for optimal LNN conversion, in *International Workshop on Reversible Computation*, pp. 89–101 (2011)

[Nielsen 10] Nielsen, M. A. and Chuang, I. L.: *Quantum Computation and Quantum Information*, Cambridge University Press (2010)

[Preskill 18] Preskill, J.: Quantum Computing in the NISQ era and beyond, *arXiv preprint arXiv:1801.00862* (2018)

[QISKit 17] QISKit, : Quantum Information Software Kit (2017), https://www.qiskit.org/

[Shafaei 14] Shafaei, A., Saeedi, M., and Pedram, M.: Qubit placement to minimize communication overhead in 2D quantum architectures, in *Design Automation Conference (ASP-DAC), 2014 19th Asia and South Pacific*, pp. 495–500 (2014)

[Siraichi 18] Siraichi, M., Dos Santos, V. F., Collange, S., and Pereira, F. M. Q.: Qubit Allocation, in *CGO 2018-IEEE/ACM International Symposium on Code Generation and Optimization*, pp. 1–12 (2018)

[Soeken 12] Soeken, M., Frehse, S., Wille, R., and Drechsler, R.: RevKit: An Open Source Toolkit for the Design of Reversible Circuits, in *Reversible Computation 2011*, Vol. 7165 of *Lecture Notes in Computer Science*, pp. 64–76 (2012), RevKit is available at www.revkit.org

[Zulehner 17] Zulehner, A., Paler, A., and Wille, R.: Efficient Mapping of Quantum Circuits to the IBM QX Architectures, *arXiv preprint arXiv:1712.04722* (2017)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

シールド工法における制約付GAを用いたセグメント割当

Segment Assignment in Shield Tunneling Method using Constrained Genetic Algorithm

伊原 滉也 *1　加藤 昇平 *1 *2　中谷 武彦 *3　大木 智明 *3
Koya Ihara　Shohei Kato　Takehiko Nakaya　Tomoaki Oki

*1 名古屋工業大学 大学院工学研究科情報工学専攻
Dept. of Computer Science and Engineering, Graduate School of Engineering, Nagoya Institute of Technology

*2 名古屋工業大学 情報科学フロンティア研究院
Frontier Research Institute for Information Science, Nagoya Institute of Technology

*3 清水建設株式会社
Shimizu Corporation

It is expected that artificial intelligence reduce labor and improve productivity in the shield tunneling method. The planning process of the shield tunneling method consists of segment assignment and machine control. Conventionally, skilled engineers assign the segment manually. Automation of this assignment improves productivity. In this paper, we address the segment assignment as a constrained combinatorial optimization problem. To solve the problem, we use the ε constrained genetic algorithm (εGA). However, εGA assumed that solutions have continuous value. So, we proposed ε constrained discrete genetic algorithm (εDGA), that adapt to handle discrete value. We also attempt to verify the effectiveness of εDGA to segment assignment.

1. はじめに

建設業の生産性向上のために情報技術を活用することは急務である．特に，都市部のトンネル工法の 1 つであるシールド工法 [土木 16] では AI による省人化や生産性の向上が期待され，注目を集めている [杉山 17]．シールド工事には計画・調査・施工管理・維持管理など様々なプロセスが含まれるが，本研究では計画に着目し，人工知能技術を用いた自動計画システムの構築を目指す．シールド工法の計画は，主にセグメント割付とシールドマシン制御の 2 つの計画問題を含む．現在，これらは熟練技術者の手作業によって行われており，自動化できれば省人化による業務の効率化が期待できる．そこで研究の初期段階として，本稿ではまずセグメント割付を制約付き組み合わせ最適化問題として解決する．

セグメント割付では解となるセグメント列が満たすべき制約は非常に厳しい．制約が厳しい最適化問題を解くアルゴリズムとして ε 制約遺伝的アルゴリズム（εGA [高濱 06]）がある．εGA は，パラメータ ε に応じて制約を緩和しながら探索を行うことで，目的関数の最適化をある程度行いながら制約を満たす解を探索することができる遺伝的アルゴリズムである．しかし，目的関数と制約がトレードオフの関係にある場合，目的関数の最適化を行うことが制約を満足する解の探索を遅らせることとなるため，実行可能解を見つけることがより難しくなってしまう．したがって，可能ならば実行可能領域内もしくはその近傍点から探索を開始することで，εGA の制約緩和による目的関数最適化が有効に働くことが期待できる．また，εGA はアルゴリズムの一部で解が連続値をとることを前提としている．そこで εGA を離散値に適用した，離散 εGA（εDGA）を提案する．本稿では，初期個体に実行可能領域の近傍解を用いた εDGA でセグメント割付問題を解くことにより，その有効性を検証する．

連絡先: 加藤昇平，名古屋工業大学，名古屋市昭和区御器所町，
052-735-5625，shohey@katolab.nitech.ac.jp

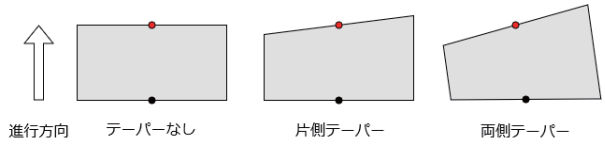


図 1: セグメントの種類の一例

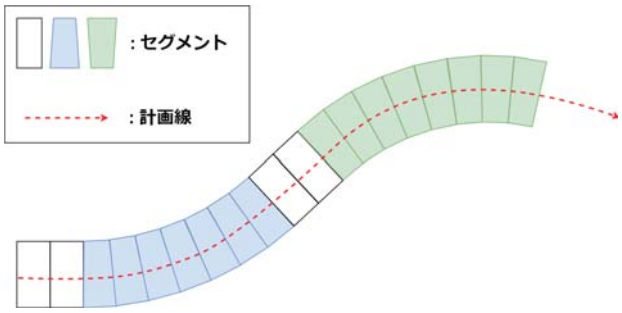


図 2: セグメント割付の例

2. セグメント割付計画問題

制約付組み合わせ最適化問題と本稿で扱うセグメント割付計画問題について説明する．

2.1 シールド工法

シールド工法とはシールドマシンと呼ばれる掘削機の後部でセグメントを組み立て，シールドマシンがそのセグメントをジャッキで押すことで反力を推進力として掘り進める工法である．セグメント割付計画では，図 1 に示すような工事ごとに定められた数種類のセグメントを組みあわせて，図 2 のように直線と曲線からなるトンネルの計画線に対して要求される誤差以内に収まるようにセグメントを割付ける．

2.2 セグメント割付計画問題

セグメントの計画には，次の 2 つの要求がある．

- 割付た全てのセグメントの計画線との誤差をクリアラン

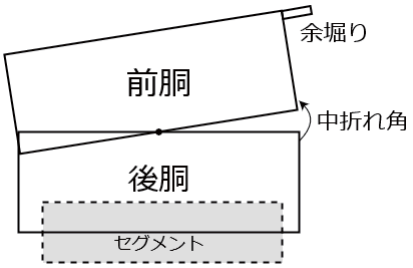


図 3: 本稿で扱うシールドマシン

ス c 以内に収めること．

- 割付けたセグメントを通るシールドマシンの掘削土量を最小にすること．

本稿では，前者を不等式制約，後者の掘削土量を目的関数として扱い，次のような最適化問題（Ps）を定義する．

$$\begin{aligned} &\text{minimize} && f(\boldsymbol{x}) \\ &\text{subject to} && (d_i(\boldsymbol{x}) - c) \leq 0, \\ & && x_i \in \{1, \cdots, k\}, \quad (i = 0, \cdots, n) \end{aligned} \tag{1}$$

ここで，$x_i \in \{1, \cdots, k\}$ は i 番目に割付られたセグメントの種類を表し，決定変数ベクトル $\boldsymbol{x} = (x_1, x_2, \cdots x_n)$ は割付けたセグメントの系列を表す．使用するセグメントは k 種類あるものする．また，$f(\boldsymbol{x})$ はセグメント列 $\boldsymbol{x}$ を配置する際に，シールドマシンが掘削する土量，c は許容するクリアランス量，$d_i(\boldsymbol{x})$ はセグメント列 $\boldsymbol{x}$ において i 番目のセグメントの計画線との誤差を表す．次に，シールドマシン，セグメント，掘削度量について説明する．なお，本稿ではまず 2 次元平面上でのセグメント割付を考える．

2.2.1 シールドマシンと掘削土量

本稿では図 3 のようなシールドマシンを考える．シールドマシンは前胴と後胴に分かれており，前胴の後方と後胴の前方が中点で連結している．前胴と後胴のなす角は中折れ角と呼ばれ，カーブを曲がるために制御される．前胴の前方が掘削面になっており，余堀り量を制御することで，シールドマシン後部が土壁に衝突することなく前進できる．2 次元平面上では，掘削土量はシールドマシンの通過領域の面積に比例するものとする．よって掘削土量を最小化するには，シールドマシンの通過領域を最小化すればよい．

割付られたセグメントと計画線の誤差は図 1 の赤点と計画線の最短距離で計算する．

3. ε 制約遺伝的アルゴリズム（εGA）

εGA [高濱 06] は，制約付き最適化問題を制約のない最適化問題に変換する ε 制約法 [Takahama 05] を遺伝的アルゴリズム（GA）に適用した手法である．この章では，ε 制約法の扱う制約付き最適化問題と，ε 制約法，εGA のアルゴリズムについて説明する．

3.1 制約付き最適化問題

ε 制約法では，次のような制約付き最適化問題（P）を考える．

$$\begin{aligned} &\text{minimize} && f(\boldsymbol{x}) \\ &\text{subject to} && g_j(\boldsymbol{x}) \leq 0, \quad (j = 1, \cdots, q) \\ & && h_j(\boldsymbol{x}) = 0, \quad (j = 1, \cdots, r) \\ & && l_i \leq x_i \leq u_i, (i = 1, \cdots, n) \end{aligned} \tag{2}$$

ここで，$\boldsymbol{x}$ は決定変数ベクトルであり，$f(\boldsymbol{x})$ は目的関数，$g_j(x) \leq 0$ は q 個の不等式制約，$r_j(x) = 0$ は r 個の等式制約を表す．また，f, g, h は実数値関数である．l_i, u_i はそれぞれ，n 個の決定変数の下限と上限である．すべての制約を満足する領域を実行可能領域 $\mathcal{F}$，上下限制約を満足する領域を探索空間 $\mathcal{S}$ とする．

3.2 ε 制約法

ε 制約法は，制約付き最適化問題を直接探索法で解く際に，通常の比較の代わりに ε レベル比較と呼ばれる比較を用いる手法である．これによって制約付き問題が等価な制約のない問題に変換されるため，既存の制約のない最適化手法に ε レベル比較を導入することで，制約付き最適化問題を解くことができる．

3.2.1 制約逸脱度

ε 制約法では，制約をどの程度違反しているか量る尺度として制約逸脱度 $\phi(\boldsymbol{x})$ を導入する．制約逸脱度 $\phi(\boldsymbol{x})$ は次の性質を満たす関数である．

$$\begin{cases} \phi(\boldsymbol{x}) = 0 & (\boldsymbol{x} \in \mathcal{F}) \\ \phi(\boldsymbol{x}) > 0 & (\boldsymbol{x} \notin \mathcal{F}) \end{cases} \tag{3}$$

制約逸脱度は p を正数として次のような定義が可能である．

$$\phi(\boldsymbol{x}) = \max\{\max_j\{0, g_j(\boldsymbol{x})\}, \max_j |h_j(\boldsymbol{x})|\} \tag{4}$$

$$\phi(\boldsymbol{x}) = \sum_j \max\{0, g_j(\boldsymbol{x})\}^p + \sum_j |h_j(\boldsymbol{x})|^p \tag{5}$$

3.2.2 ε レベル比較

ε レベル比較 [Takahama 05] は目的関数値と制約逸脱度の組 (f, ϕ) の集合上の比較である．制約逸脱度が ε 以下の場合と制約逸脱度が同値の場合は目的関数値の大小関係，それ以外の場合は制約逸脱度の大小関係を用いて，(f, ϕ) の大小を決定する．具体的には ε レベル比較 $<_\varepsilon$ $(\varepsilon \in (0, \infty)), \leq_\varepsilon$ $(\varepsilon \in [0, \infty))$ は以下のように定義される．

$$(f_1, \phi_1) <_\varepsilon (f_2, \phi_2) \Leftrightarrow \begin{cases} f_1 < f_2, & (\phi_1, \phi_2 \leq \varepsilon) \\ f_1 < f_2, & (\phi_1 = \phi_2) \\ \phi_1 < \phi_2, & \text{otherwise} \end{cases} \tag{6}$$

$$(f_1, \phi_1) \leq_\varepsilon (f_2, \phi_2) \Leftrightarrow \begin{cases} f_1 \leq f_2, & (\phi_1, \phi_2 \leq \varepsilon) \\ f_1 \leq f_2, & (\phi_1 = \phi_2) \\ \phi_1 < \phi_2, & \text{otherwise} \end{cases} \tag{7}$$

ここで，解 $\boldsymbol{x}_1, \boldsymbol{x}_2$ の関数値を f_1, f_2，制約逸脱度を ϕ_1, ϕ_2 とする．なお，$<_0, \leq_0$ は制約逸脱度を優先する辞書式比較と等価であり，$<_\infty, \leq_\infty$ は目的関数のみの比較と等価である．

3.3 εGA

ε 制約法は，目的関数の値の大小関係のみに基づく最適化アルゴリズムと組み合わせることができる．εGA は適応度の大小関係のみに依存する戦略を生存者選択に用いた GA に ε 制約法を適用した手法である．

元の εGA では，線形・非線形計画問題を対象としており，個体の各遺伝子が実数であることを前提とした突然変異を利用している．そこで本稿では，εGA の突然変異を離散値に対応したものに変更することで，整数計画問題・組み合わせ最適化問題に対応した離散 ε 制約遺伝的アルゴリズム（εDGA）を提案する．

3.4 εDGA

εDGA のアルゴリズムを以下に示す．

1. 初期集団の生成: 初期個体を N 個体生成する．各個体の遺伝子は乱数で与えるか，問題に応じたヒューリスティックを用いて与える．
2. 終了判定: 本稿では最大世代数 T に達したときに実行終了とする．
3. ε レベルの決定: 通常は $\varepsilon = 0$ でよい．しかし，制約が厳しい場合には，ε レベルを制御することで制約を緩和して実行可能領域を一時的に広げることで目的関数の最適化を行う．
4. 親選択: すべての個体を親とし，交配プールにランダムに配置する．
5. 交叉: 適用確率 P_c で親に一様交叉を適用し，子を生成する．
6. 突然変異: 適用確率 P_m で交叉で生成した子に突然変位を適用する．
7. 生存者選択: 親と子の $2N$ 個体から ε 比較によって上位 N 個体を選択し次世代の集団とする．2. へ戻る．

次に，5. の一様交叉と 6. の突然変異，3. の ε レベルの制御について説明する．

3.4.1 一様交叉

一様交叉（uniform crossover [Syswerda 89]) は，染色体と同じ長さのマスクと呼ばれるビット列を乱数で用意し，マスクの各ビットの値によりどちらの親の遺伝子をどちらの子に継承するかを決定する．例えば，ある遺伝子に対応するマスクの値が 0 のときは親 A の遺伝子を子 a に，親 B の遺伝子を子 b に継承し，マスクの値が 1 のときは親 A の遺伝子を子 b に，親 B の遺伝子を子 a に継承させる．本稿ではマスクの各ビットにおける 1 の発生確率を $p_c\,(0 \leq p_u \leq 0.5)$ とした．

3.4.2 突然変位

単純な突然変異を採用する．染色体の各遺伝子を確率 p_m で変化させる．遺伝子 x_i の変化後の値は $[l_i, u_i]$ の離散一様乱数に従って決定する．εGA では，Gauss 突然変異と Cauchy 突然変異 [Yao 99] を採用していたが，最適化初期には大域的な探索を行い，後期には精密な解を探索するために，突然変異のステップ幅を世代数に応じて制御していた．本手法の突然変異においても t 世代目の変化率を $p_m^{(t)}$ とし，この値を世代数に応じて制御することで，探索の規模を調整できる．

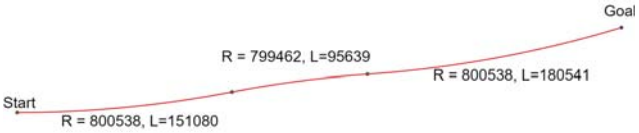


図 4: 対象の計画線 [㎜]

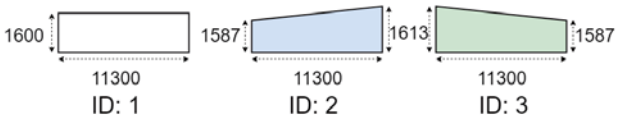


図 5: 使用したセグメントの ID と寸法 [㎜]

3.4.3 ε レベルの制御

高濱ら [高濱 06] は初期値を初期集団の上位 20% 個体の制約逸脱度で決定し，最大世代数 T の 80% 以降に 0 となる，次のような世代数 t のべき乗関数で定義した．ε レベルは，$\phi(\boldsymbol{x}) \leq \varepsilon$ を満たす個体が常に集団に含まれるように，世代とともに減少し，0 になった後にもしばらく最適化を行うことが望ましい．

$$\varepsilon(0) = \phi(\boldsymbol{x}_\theta) \tag{8}$$

$$\varepsilon(t) = \begin{cases} \varepsilon(0)(1 - \frac{t}{T_c})^{cp}, & (0 < t < T_c) \\ 0, & (t \leq T_c) \end{cases} \tag{9}$$

ここで，$\boldsymbol{x}_\theta$ は初期集団の上位 20% の個体であり，$T_c = 0.8T$，cp は ε の収束速度に関するパラメータであり，これの値が大きいほど 0 に近づくのが早くなる．

4. εDGA によるセグメント割付実験

本稿では，セグメント割付計画問題に対する離散 εGA の有効性を検証する．

4.1 実験設定

式 (2) で定義した組み合わせ最適化問題（P_s）を εDGA で解く．対象とした計画線を図 4 に示す．計画線は曲率半径 R [㎜] と長さ L [㎜] との系列で与えられる．今回は $(R, L) = (80058, 151080), (799462, 95639), (800538, 180541)$ の 3 つの曲線からなる計画線を利用した．また，割付に使用したセグメントの種類とそれぞれの寸法を図 6 に示す．それぞれ直進，左折，右折する $k = 3$ 種類のセグメントを利用する．それぞれのセグメントにおいて，1 つあたり 1600[㎜] 掘進することになるため，$\sum L/1600 = 267.0375$ より $n = 267$ 個のセグメントを割り付ける．クリアランス量は $c = 50$[㎜] とした．

4.2 遺伝子表現

解は長さ n の整数型遺伝子を用いる．$x_i \in \{1, 2, 3\}$ は i 番目のセグメントに ID が x_i であるセグメントを割り付けることを意味する．

4.3 適応度評価と制約逸脱度

適応度はシールドマシンがセグメント列を配置するために通過した領域の面積を用いる．このとき，前胴の前面が通過する領域の面積は，前胴の幅と計画線の全長の積で求まり，どのようなセグメント配置をしても変化しないため，この領域を除いた領域の面積を適応度とする．これは，図 3 の余堀りで掘削した領域の面積に相当する．

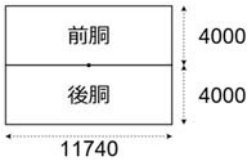


図 6: 使用したシールドマシンの寸法 [㎜]

表 1: 各世代の最優良個体（5 試行平均値）

世代数	適応度 [㎡]	制約逸脱度 [㎜]	違反セグメント数
(貪欲法)	97.48	0	0
10	78.12	0	0
100	78.06	0	0
200	77.96	0	0

制約逸脱度は，式 (5) を採用するが，本問題では等式制約は存在しないため，次のように定義する．

$$\phi(\boldsymbol{x}) = \sum_i \max\{0, (d_i(\boldsymbol{x}) - c)\}^p \tag{10}$$

4.4 初期個体

セグメント割付における実行可能解は，各セグメントと計画線との誤差が c 以下のセグメント列である．計画線との誤差だけを考えるのであれば，貪欲法によって始点から逐次，計画線との誤差が最小のものを選択することで，実行可能解が求まる．セグメントの曲率よりも計画線の曲率の方が大きく，曲線の前で一度計画線から離れておかないと曲がり切れないような問題設定を考えることもできるが，シールド工法では計画線のうち曲率最大の箇所に合わせてセグメントの曲率が決定されるため，そのような問題は考慮しない．

よって本実験では，まずはベースとなる実行可能解を貪欲法により求める．これ N 個体用意し，それぞれに確率 P_I で各遺伝子をランダムに変更する突然変異を適用し，それらを初期集団とする．

4.5 遺伝子操作におけるパラメータ

集団サイズ $N = 500$，最大世代数 $T = 200$，交叉確率 $P_c = 0.95$，一様交叉パラメータ $p_c = 0.35$，突然変異確率 $P_m = 0.5$，突然変異パラメータ $p_m^{(0)} = 0.03$，$p_m^{(t)} = 0.05, (1 \leq t \leq T)$，$\varepsilon$ レベル制御パラメータ $cp = 5$ として最適化を 5 試行実施した．

4.6 実験結果

各世代の実行可能解中の最優良個体を表 1 に示す．貪欲法で求めた解から，約 20%適応度を減少させることができた．面積では約 20[㎡] ほど削減できた．今回の計画線の全長は約 427[m] なので，シールド工事 1[㎞] あたり 46.9[㎡] の面積を削減できたことになる．

5. おわりに

本稿では，シールド工法における計画に着目し，セグメント割付計画問題を制約付き組み合わせ最適化問題として解決した．実行可能領域近傍から探索を開始する手法と連続値を扱う εGA を離散値に適用した εDGA を提案し，実験によりその有効性を確認した．今後はより多くの目的・制約や，シールドマシンの中折れ角や余掘り量の制御も考慮した最適化実験を行っていく予定である．

参考文献

[Syswerda 89] Syswerda, G.: Uniform crossover in genetic algorithms, in *Proceedings of the third international conference on Genetic algorithms*, pp. 2–9Morgan Kaufmann Publishers (1989)

[Takahama 05] Takahama, T. and Sakai, S.: Constrained optimization by ε constrained particle swarm optimizer with ε-level control, in *Soft computing as transdisciplinary science and technology*, pp. 1019–1029, Springer (2005)

[Yao 99] Yao, X., Liu, Y., and Lin, G.: Evolutionary programming made faster, *IEEE Transactions on Evolutionary computation*, Vol. 3, No. 2, pp. 82–102 (1999)

[高濱 06] 高濱徹行, 阪井節子 他：ε 制約遺伝的アルゴリズムによる制約付き最適化, 情報処理学会論文誌, Vol. 47, No. 6, pp. 1861–1871 (2006)

[杉山 17] 杉山博一, 和田健介, 大木智明, 中谷武彦, 安井克豊：人工知能によるシールドマシン操作に関する予備的検討, 土木学会第 72 回年次学術講演会 (IV-338) (2017)

[土木 16] 土木学会：2016 年制定 トンネル標準示方書 [シールド工法編]・同解説, JSCE Publications (2016)

[1N1] [General Session] 2. Machine Learning

座長:原 聡（大阪大学）

Tue. Jun 5, 2018 1:20 PM - 3:00 PM Room N (2F Sakurajima)

[1N1-01] Learning of Relative Spatial Concepts from Utterances based on MCMC sampling

○Rikunari Sagara[1], Zhixiang Gu[1], Ryo Taguchi[1], Koosuke Hattori[2], Masahiro Hoguro[2], Taizo Umezaki[1,3] （1. Nagoya Institute of Technology, 2. Chubu University, 3. The University of Tokyo）

1:20 PM - 1:40 PM

[1N1-02] The Method of Machine Learning Considering Tamper of Training Data

Tenshi Yanagimachi[1], ○Yoshiteru Ishida[1] （1. Toyohashi University of Technology）

1:40 PM - 2:00 PM

[1N1-03] Prediction with LSTM and Analysis of Werewolf

○Manami Kondoh[1], Taku Hasegawa[1], Naoki Mori[1], Keinosuke Matsumoto[1] （1. Osaka Prefecture University）

2:00 PM - 2:20 PM

[1N1-04] Analysis of cognitive satisficing value function

○Akihiro Tamatsukuri[1], Tatsuji Takahashi[2] （1. Graduate School of Tokyo Denki Univerity, 2. Tokyo Denki University）

2:20 PM - 2:40 PM

[1N1-05] Social reinforcement learning with shared reference satisficing

○Noriaki Sonota[1], Takumi Kamiya[2], Yu Kono[3], Tatsuji Takahashi[1] （1. School of Science and Engineering, Tokyo Denki University, 2. Graduate School of Tokyo Denki Univerity, 3. DeNA Co., Ltd.）

2:40 PM - 3:00 PM

©The Japanese Society for Artificial Intelligence

MCMC サンプリングを用いた発話からの相対位置概念学習

Learning of Relative Spatial Concepts from Utterances based on MCMC sampling

相良陸成[*1] 谷志翔[*1] 田口亮[*1] 服部公央亮[*2] 保黒政大[*2] 梅崎太造[*1*3]

Rikunari Sagara Zhixiang Gu Ryo Taguchi Koosuke Hattori Masahiro Hoguro Taizo Umezaki

[*1] 名古屋工業大学 Nagoya Institute of Technology

[*2] 中部大学 Chubu University

[*3] 東京大学 The University of Tokyo

This paper presents a method for learning relative spatial concepts and phoneme sequences which represent spatial concepts and objects from utterances without knowledge of words. First, phoneme sequences recognized by a general speech recognizer are divided into words on the basis of NPYLM. Then, parameters of the relative spatial distributions are estimated from the segmented words and location information by MCMC sampling. In the experiments, the result showed that the parameters were estimated correctly by the proposed method. Moreover, phoneme sequences which represent spatial concepts and objects were learned successfully by the proposed method.

1. はじめに

近年，人間の日常生活を支援するサービスロボットへのニーズが増加している．このようなロボットは，使用される環境に特有の単語とその意味を学習できることが望ましい．この課題を解決するために，単語の意味をロボットの感覚・運動系の信号と対応付けて学習させる研究が行われている[田口 10][中村 15]．

また，位置概念は人間の日常生活において重要な役割を果たしているため，サービスロボットが位置概念を理解できることは，人との協調を実現するために重要である．谷口らは，地図生成と位置・音声言語・画像を統合したモデルによる位置概念の逐次的な学習手法[谷口 17]を提案している．ただしこの手法では，前後左右などの相対的な位置概念（相対位置概念）を学習できない．相対位置概念を表す単語は，対象の他に少なくとも 1 つの基準となる物体（参照物体）に依存する[Landau 93]．参照物体は明示されない場合があるため，ロボットが位置概念を学習する場合は，配置された各物体の相対位置関係から参照物体を推定しながら学習を進める必要がある．谷らは，参照物体を推定しながら相対位置概念を学習する手法を提案した[谷 17]．ただしこの研究では，相対位置概念の名称をテキストにより教示しており，自然な発話からの学習については実現されていない．そこで本研究では，入力として発話音声を用いて，相対位置概念と位置や物体を表す単語を学習する手法を提案する．

2. 問題設定

本研究で想定する教示場面をに示す．教示環境において，教示者とロボット及び複数の物体の位置を定める．これらの物体は，用意された物体からランダムに選択される．教示者は配置された物体の中から参照物体を 1 つ選択し，参照物体からの相対位置をロボット視点で発話により教示する．発話は位置を表す単語（位置単語），物体を表す単語（物体単語），その他の単語（文法単語）から成るとする．教示者とロボット及び物体の位置を変更して，この教示を繰り返す．ロボットは教示者と物体の位置関係（位置情報）と発話から，相対位置概念と，物体単語及び位置単語を学習する．ただし，ロボットは事前に単語知識を持たないとする．このため単語を学習するには単語境界を推定する必要がある．また，ロボットは教示環境に配置された物体の種類を誤りなく認識可能であるものとして，各物体に割り当てられる ID（物体 ID）を取得できるとする．なお，物体数と位置概念数は事前に与えられるものとする．

この問題設定では，どの物体が参照物体であるかはロボットに与えられない．そのため相対位置概念を学習する際には，配置された物体の中から参照物体を推定する必要がある．

連絡先： 相良 陸成，名古屋工業大学大学院工学研究科，名古屋市昭和区御器所町，sagara@umelab.jp

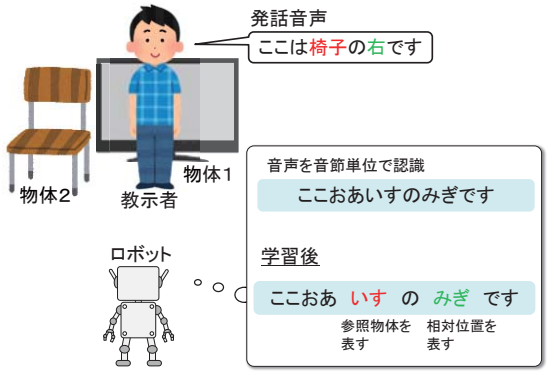


図 1 教示場面

3. 提案手法

提案手法は，単語分割と概念学習により構成される．図 2 にデータフローを示す．単語分割では発話を単語列に変換し，概念学習では単語列と位置情報から，相対位置の分布と各概念の単語分布を推定する．

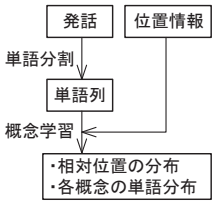


図 2 提案手法

3.1 単語分割

単語分割では，音声認識誤りを吸収しながら，単語の事前知識なしで発話を単語に分割する．中村らが用いた繰り返しアルゴリズム[中村 15]と同様に，(i)音声認識，(ii)教師なし単語分割，(iii)言語モデル更新を繰り返し行う．に単語分割アルゴリズムのデータフローを示す．ただし中村らの用いたアルゴリズムとは異なり，音声認識の結果としてラティスを出力する．これにより，音響尤度をより正確に考慮した単語分割を行うことができる[相良 17]．また，単語分割と同時に概念学習を行うことの有効性が報告されている[中村 15]．本研究では，単語分割と概念学習のそれぞれの性能を個別に評価するため，単語分割の際に概念学習を同時に行わないこととした．

アルゴリズムについて述べる．まず各発話を音声認識する．初期状態の言語モデルには，日本語の各音節が単語として登録されている．音声認識結果は，音声認識スコアを重みとした Weighted Finite-State Transducer (WFST) 形式の単語ラティスとして出力する．この単語ラティスを音節ごとにノードを分解し，スコアを音節ごとに等分する．ただし，初期状態の言語モデルを用いて得られた単語ラティスは既に音節に分割されている．各発話の音節ラティスを入力とし，NPYLM を用いて言語モデルと単語分割を学習する Neubig らの手法[Neubig 10]により，単語分割を行う．その後，生成された単語列を言語モデル作成用コーパスに追加する．このコーパスから単語 3-gram の言語モデルを作成し，この言語モデルを用いて再度音声認識を行う．ここまでの処理を指定回数繰り返し，最後の音声認識結果から第一候補の単語列を抽出して，単語分割の結果とする．

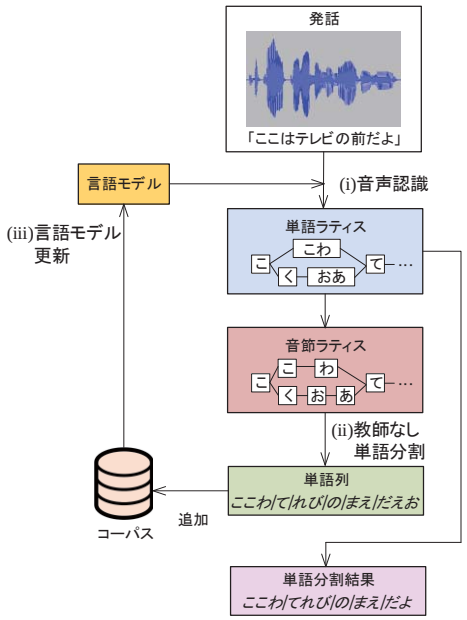


図 3　単語分割アルゴリズム

3.2　概念学習

表 1　概念学習の入力例

n	単語列	(l_{n1}, θ_{n1})	(l_{n2}, θ_{n2})
1	ここわ|てれび|の|みぎ|だね	(1.5[m], -87[°])	(1.2[m], 65[°])

単語分割により得られた単語列と，配置された物体との相対位置を入力とする．表 1に入力例を示す．これを用いて，位置の分布と，位置概念と物体概念の単語分布を学習する．場面$\boldsymbol{n}$における物体$\boldsymbol{k}$からの相対位置$\boldsymbol{x}_{nk}$は，角度θ_{nk}と距離$\boldsymbol{l}_{nk}$から成る．図 4に示すように，角度θ_{nk}は物体$\boldsymbol{k}$とロボットを結ぶ線分と，物体$\boldsymbol{k}$と教示者を結ぶ線分が成す角であり，距離$\boldsymbol{l}_{nk}$は物体$\boldsymbol{k}$と教示者の距離である．

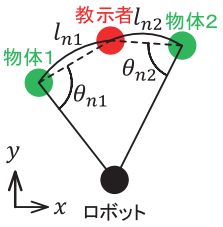


図 4　距離と角度

図 5に概念学習のグラフィカルモデルを示し，表 2に概念学習に用いる変数を示す．このモデルは，位置分布の推定と各概念の単語分布の推定を統合したモデルである．相対位置$\boldsymbol{x}_{nk} = (x_{nk}, y_{nk})$は式(1)で示すように生成される．場面$\boldsymbol{n}$で選ばれた参照物体の物体概念のインデックスを$\boldsymbol{C}_n^o$，位置概念のインデックスを$\boldsymbol{C}_n^r$とする．物体$\boldsymbol{k}$が参照物体の時（$k = \boldsymbol{C}_n^o$），相対位置を極座標を用いて距離$\boldsymbol{l}_{nk}$と角度$\theta_{nk}$で表し，距離と角度は正規分布$\mathrm{N}(\cdot)$とフォン・ミーゼス分布$\mathrm{vM}(\cdot)$から生成される．参照物体ではないときは一様分布$\mathrm{U}(\cdot)$から生成される．

$$\boldsymbol{x}_{nk} \sim p\left(\boldsymbol{x}_{nk} \middle| \mu, \lambda, \nu_{C_n^r}, \kappa_{C_n^r}, e\right) = \begin{cases} \mathrm{N}\left(l_{nk} \middle| \mu, \lambda^{-1}\right) \mathrm{vM}\left(\theta_{nk} \middle| \nu_{C_n^r}, \kappa_{C_n^r}\right) & (k = \boldsymbol{C}_n^o) \\ \mathrm{U}(x_{nk} | -e, e)\mathrm{U}(y_{nk} | -e, e) & (\text{otherwise}) \end{cases} \quad (1)$$

パラメータμ, λ, ν_sは式(2)から式(4)で示すように，共役事前分布の正規分布とガンマ分布$\mathrm{Gam}(\cdot)$及びフォン・ミーゼス分布から生成される．またκ_sは式(5)で示すように対数正規分布$\mathrm{logN}(\cdot)$から生成される．ただしsは位置概念のインデックスである．

$$\mu \sim p(\mu|\mu_0, \lambda_0) = \mathrm{N}(\mu|\mu_0, \lambda_0) \quad (2)$$
$$\lambda \sim p(\lambda|a_0, b_0) = \mathrm{Gam}(\lambda|a_0, b_0) \quad (3)$$
$$\mu_s \sim p(\nu_s|\nu_0, \kappa_0) = \mathrm{vM}(\nu_s|\nu_0, \kappa_0) \quad (4)$$
$$\kappa_s \sim p(\kappa_s|m_0, \sigma_0) = \mathrm{logN}(\kappa_s|m_0, \sigma_0) \quad (5)$$

i番目の単語w_{ni}は式(6)で示すように生成される．i_n^r, i_n^oはそれぞれ，単語列$\boldsymbol{w}_n$内の位置単語と物体単語のインデックスである．i_n^r, i_n^oにより単語を選択することを本研究では「単語選択」と呼ぶ．単語w_{ni}が位置単語の場合，物体単語の場合，文法単語の場合に応じて，それぞれの単語分布$\boldsymbol{\phi}_{C_n^r}^r, \boldsymbol{\phi}_{C_n^o}^o, \boldsymbol{\psi}$をパラメータとした多項分布$\mathrm{Mult}(\cdot)$から単語が生成される．

$$w_{ni} \sim p\left(w_{ni} \middle| \boldsymbol{\phi}_{C_n^r}^r, \boldsymbol{\phi}_{C_n^o}^o, \boldsymbol{\psi}, i_n^r, i_n^o\right) = \begin{cases} p\left(w_{ni} \middle| \boldsymbol{\phi}_{C_n^r}^r\right) = \mathrm{Mult}\left(w_{ni} \middle| \boldsymbol{\phi}_{C_n^r}^r\right) & (i = i_n^r) \\ p\left(w_{ni} \middle| \boldsymbol{\phi}_{C_n^o}^o\right) = \mathrm{Mult}\left(w_{ni} \middle| \boldsymbol{\phi}_{C_n^o}^o\right) & (i = i_n^o) \\ p(w_{ni}|\boldsymbol{\psi}) = \mathrm{Mult}(w_{ni}|\boldsymbol{\psi}) & (\text{otherwise}) \end{cases} \quad (6)$$

単語分布$\boldsymbol{\phi}_s^r, \boldsymbol{\phi}_k^o, \boldsymbol{\psi}$と単語のインデックスは$i_n^r, i_n^o$は式(7)から式(11)で示すように，ディリクレ分布$\mathrm{Dir}(\cdot)$と多項分布から生成される．ただしkは物体概念のインデックスである．

$$\boldsymbol{\phi}_s^r \sim p(\boldsymbol{\phi}_s^r|\boldsymbol{\beta}^r) = \mathrm{Dir}(\boldsymbol{\phi}_s^r|\boldsymbol{\beta}^r) \quad (7)$$
$$\boldsymbol{\phi}_k^o \sim p\left(\boldsymbol{\phi}_k^o|\boldsymbol{\beta}^o\right) = \mathrm{Dir}\left(\boldsymbol{\phi}_k^o|\boldsymbol{\beta}^o\right) \quad (8)$$
$$\boldsymbol{\psi} \sim p(\boldsymbol{\psi}|\boldsymbol{\beta}^\psi) = \mathrm{Dir}(\boldsymbol{\psi}|\boldsymbol{\beta}^\psi) \quad (9)$$
$$i_n^r \sim p(i_n^r|\boldsymbol{\gamma}_n) = \mathrm{Mult}(i_n^r|\boldsymbol{\gamma}_n) \quad (10)$$
$$i_n^o \sim p(i_n^o|\boldsymbol{\gamma}_n) = \mathrm{Mult}(i_n^o|\boldsymbol{\gamma}_n) \quad (11)$$

位置概念と物体概念のインデックス$\boldsymbol{C}_n^r, \boldsymbol{C}_n^o$は式(12)，式(13)で示すように多項分布から生成される．ただし$\boldsymbol{O}_n$は配置された物体を表し，$\boldsymbol{\pi}^{o*}$は$\boldsymbol{\pi}^o$の成分のうち配置されていない物体に対応する値を 0 としたベクトルである．またパラメータ$\boldsymbol{\pi}^r, \boldsymbol{\pi}^o$は式(14)，式(15)で示すようにディリクレ分布から生成される．

$$\boldsymbol{C}_n^r \sim p(\boldsymbol{C}_n^r|\boldsymbol{\pi}^r) = \mathrm{Mult}(\boldsymbol{C}_n^r|\boldsymbol{\pi}^r) \quad (12)$$
$$\boldsymbol{C}_n^o \sim p(\boldsymbol{C}_n^o|\boldsymbol{\pi}^o, \boldsymbol{O}_n) = \mathrm{Mult}(\boldsymbol{C}_n^o|\boldsymbol{\pi}^{o*}) \quad (13)$$
$$\boldsymbol{\pi}^r \sim p(\boldsymbol{\pi}^r|\boldsymbol{\alpha}^r) = \mathrm{Dir}(\boldsymbol{\pi}^r|\boldsymbol{\alpha}^r) \quad (14)$$
$$\boldsymbol{\pi}^o \sim p(\boldsymbol{\pi}^o|\boldsymbol{\alpha}^o) = \mathrm{Dir}(\boldsymbol{\pi}^o|\boldsymbol{\alpha}^o) \quad (15)$$

本研究ではギブスサンプリングを用いてモデルのパラメータを推定する．ただしκ_sについては事後分布の数値解析が困難であるため，対数正規分布$\mathrm{logN}(\kappa_s|m_0, \sigma_0)$を提案分布として用いてMetropolis-Hastings法によりサンプリングを行う．

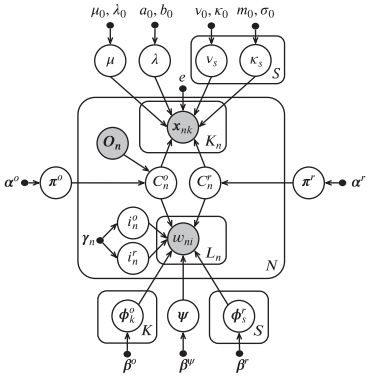


図 5　グラフィカルモデル

表 2 概念学習に用いる変数

C_n^r	場面nの位置概念のインデックス
C_n^o	場面nの参照物体の物体概念のインデックス
$\boldsymbol{\pi}^r$	各位置概念の生成確率
$\boldsymbol{\pi}^o$	各物体概念の生成確率
$\boldsymbol{x}_{nk}$	場面nの配置物体kからの相対位置
$\boldsymbol{O}_n$	場面nにおいて配置された物体を表すベクトル
μ	距離の平均
λ	距離の分散
ν_s	相対位置概念sの平均角度
κ_s	相対位置概念sの集中度
w_{ni}	場面nのi番目の単語
$\boldsymbol{\phi}_s^r$	位置概念sの単語分布
$\boldsymbol{\phi}_k^o$	物体概念kの単語分布
$\boldsymbol{\psi}$	文法単語の単語分布
i_n^r	場面nの位置単語のインデックス
i_n^o	場面nの物体単語のインデックス
$\mu_0, \lambda_0, a_0, b_0$ $\nu_0, \kappa_0, m_0, \sigma_0$ $\boldsymbol{\alpha}^r, \boldsymbol{\alpha}^o, \boldsymbol{\gamma}_n$ $\boldsymbol{\beta}^r, \boldsymbol{\beta}^o, \boldsymbol{\beta}^\psi$	ハイパーパラメータ

4. 実験と考察

単語分割と概念学習に分けて評価を行う.

4.1 音声データの作成

学習に使用する物体数を 16, 位置概念数を 4 とし, 各概念を表す単語数は 1 とした. 使用する物体単語と位置単語の一覧をそれぞれ表 3 (a)と(b)に示す. 発話内容は, 物体単語 X と位置単語 Y を決めた後に, 20 種類からランダムに選択した言い回しに X, Y を当てはめて作成した. 使用する言い回しの例を表 3 (c)に示す. ただし単語の境界を縦棒"|"で表す. 本実験では物体単語と位置単語の全組み合わせについて, 発話内容を 4 つずつ作成した. 発話内容の総数は 256(=16×4×4)通りである.

作成したそれぞれの発話内容を日本人男性 1 名が 1 回ずつ発話し, 合計 256 発話の音声を収録した. 発話内容の例を表 3 (d)に示す. 音声認識には Julius-4.4.2[Lee 01]と Julius ディクテーションキット v4.4 の DNN 音響モデルを用いた.

表 3 発話内容の生成

(a) 物体単語の例

概念	単語
テレビ	てれび
本棚	ほんだな
椅子	いす
机	つくえ

(b) 位置単語の一覧

概念	単語
前	まえ
後	うしろ
右	みぎ
左	ひだり

(c) 言い回しの例

ID	単語列
1	X | の | Y
2	X | の | Y | だよ
3	X | の | Y | だね
4	X | の | Y | です
5	X | の | Y | にきました
6	X | の | Y | にいるよ
7	X | の | Y | にいるね
8	X | の | Y | にいます
9	ここわ | X | の | Y
10	ここわ | X | の | Y | だよ

(d) 発話内容の例

ID	単語列
1	ここわ | てれび | の | まえ | だよ
2	ほんだな | の | ひだり | に | いるね

4.2 単語分割の評価

(1) 実験条件

単語分割アルゴリズムの中で用いる教師なし単語分割には latticelm v0.4 を使用した. 教師なし単語分割の結果は, latticelm の 1000 回目のサンプリング結果を利用した. また, 言語モデルの作成には, SRILM (SRI International により提供される言語モデル作成用ツールキット) の ngram-count を用いた. 今回は音声認識と言語モデル更新の繰り返し回数を 30 回とした.

(2) 評価手法

単語分割結果の単語境界が, 表 3 (c)で定めたものと一致することを期待する. 単語分割結果には音節認識誤りが生じている可能性があり, 単語分割結果と正解の単語列の単語分割の位置を直接比較できない. そのため, 単語分割結果と正解の単語列のそれぞれの音節列を DP マッチングし, 得られた音節間の対応関係を用いて単語分割の位置を比較する. 発話ごとに, 以下の 2 つの条件を満たすか調べる.

過分割: 本来分割されるべきではない物体単語か位置単語の中に分割が存在している.

未分割: 分割すべき位置で 2 つの単語に分割されていない. ただし単語「の」と他の単語が分割されていない場合には未分割としない. また, 物体単語と単語「の」の組と, 位置単語と単語「の」の組の双方が分割されていない場合には未分割とする.

(3) 実験結果

単語分割結果を表 4 に示す. 結果を見ると, 表 3(c)で定めた, 正解の単語列に近いことが確認できる. 過分割を赤字, 未分割を緑字で示す. 単語列内の物体単語と位置単語について, 256 発話中 49 発話 (19.1[%]) において過分割が発生し, 17 発話 (6.6[%]) において未分割が発生した.

表 4 単語分割結果の例

正解の単語列	単語分割結果
ここわ | てれび | の | まえ | だね	ここわ | てるび | の | まえ | だね
ここのなまえわ | てれび | の | みぎ	ここのなまえわ | ててび | の | みぎ
ほんだな | の | ひだり | です	ほおんだな | の | ひだり | で | す
ここわ | ほんだな | の | ひだり	ここわ | ほ | おんだな | の | ひ | だり
いす | の | みぎ | にいます	にすのみぎ | に | い | まあす

(4) 考察

同じ単語であっても, 発話により異なる分割結果となる例が存在した. 例えば, すべての「ほんだな」が「ほ | おんだな」と過分割されたのではなく, 過分割のない「ほおんだな」となるものも存在した. これは 3-gram を学習したことにより, 単語の出現確率が前後の単語に依存し, 「ここわ」の後には「ほ」が出現しやすいなどの誤りを学習したからだと考えられる. 「ここわ」の後には物体単語が出現し, その後には「の」が出現する, という規則を学習できれば, このような誤りは生じない. このような学習は, 概念学習の結果を用いて物体単語と位置単語を特定し, 物体単語と位置単語をそれぞれ一つのクラスみなしたクラス n-gram を学習することにより実現できると考えられる.

4.3 概念学習の評価

(1) 実験条件

入力する単語列には, 単語分割の実験で得られた単語列を用いる. 位置情報は, 各物体からのロボットの相対位置をシミュレーションにより生成する. 本実験では教示環境に 3 個の物体を配置する. 発話により示される参照物体からのロボットの相対位置は, 表 5 の真値を用いて生成した. またそれ以外の物体からのロボットの相対位置はランダムに生成した. 1 回の実験では, 256 個の学習データを用いて学習した.

本実験では，提案手法（手法 A）と提案手法の一部の処理を除いた手法（手法 B,C,D）を比較して，提案手法の有効性を示す．手法 B,C,D はそれぞれ，単語選択を除いた手法，距離分布の推定を除いた手法，物体単語の単語分布の推定を除いた手法，である．手法 B では，全ての単語が概念を表すとみなす．各手法について，乱数の種を変えて 10 回ずつ実験した．

(2) 実験結果

参照物体の正解率の 10 回分の平均を図 6 に示す．ただしエラーバーは標準偏差を示す．提案手法を用いた場合に最も高くなることがわかる．また，提案手法を用いた場合の位置分布の推定値を調べた．表 5 に平均角度と集中度の真値と推定値の平均と標準偏差を示す．提案手法により，データの生成分布に近い値が得られることを確認できる．

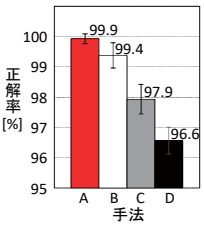


図 6 参照物体正解率

表 5 提案手法による位置分布パラメータの推定

(a) 平均角度

位置概念	真値	推定値
前	0.0	0.6±2.6
後	180.0	177.0±1.3
左	90.0	90.9±1.7
右	-90.0	-91.3±2.7

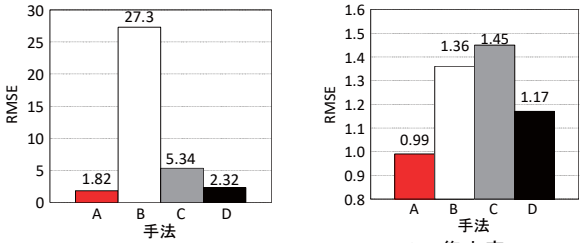
(b) 集中度

位置概念	真値	推定値
前	14.0	11.9±1.3
後	14.0	15.2±1.4
左	14.0	15.8±2.2
右	14.0	14.5±1.6

各手法での位置分布のパラメータの推定値から，式(16)により誤差 RMSE(Root-Mean-Square Error)を算出した．ただし，実験回数をZ，位置概念数をS，位置概念sのパラメータの真値をx_s，実験zでの位置概念sのパラメータの推定値を$\hat{x}_{zs}$とする．

$$\mathrm{RMSE} = \sqrt{\frac{1}{ZS}\sum_{z=1}^{Z}\sum_{s=1}^{S}(x_s - \hat{x}_{zs})^2} \qquad (16)$$

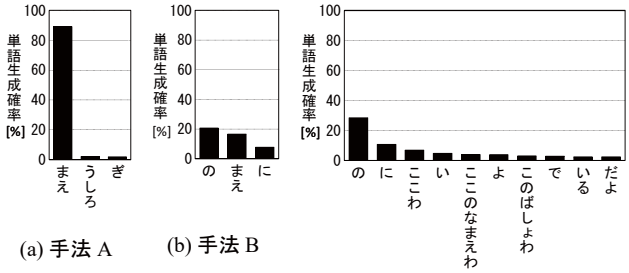
結果を図 7 に示す．平均角度と集中度の双方において，提案手法を用いた場合に最も誤差が小さくなることが確認できる．



(a) 平均角度　(b) 集中度

図 7 位置分布パラメータの推定誤差

また，単語分布の推定における単語選択の有効性を評価する．単語選択を行わない手法 B と，提案手法を比較した．概念「前」の推定された単語分布を図 8 に示す．単語選択を行うことで，概念に対応する単語「まえ」の確率を高く推定できるようになることがわかる．また，提案手法では図 9 に示すように文法単語の単語分布が正しく学習された．



(a) 手法 A　(b) 手法 B

図 8 概念「前」の単語分布　図 9 文法単語の単語分布

(3) 考察

単語選択を除いた場合，文法単語も各場面の位置概念の選択に影響する．これにより各場面の位置概念の選択を誤り，平均角度がほぼ等しい位置概念が推定され，正しく学習されない場合が存在した．実験では 10 回のうち 2 回がこれに該当した．

距離分布を推定しない場合，物体と教示者を結ぶ線分との角度θ_{nk}の値が近い 2 つの物体のうち一方が参照物体である場合，角度のみから参照物体を推定することは困難である．物体単語を用いることができれば参照物体を推定することができるが，単語分割に誤りがある場合には，単語列からも参照物体を推定することができず，参照物体正解率が低下する．

物体単語の単語分布を推定しない場合，教示環境においてほぼ同じ位置にある 2 つの物体が存在する際に，位置情報のみから参照物体を推定することが困難となる．提案手法とは異なり，単語列の情報により参照物体が推定されないため，参照物体正解率が低下したと考えられる．

以上より，提案手法の有効性が示された．

5. まとめ

本研究では，発話音声を用いて相対位置概念と位置や物体の概念を表す単語を学習する手法を提案した．実験により，位置分布と単語分布の推定は，実験に用いた手法の中で，提案手法を用いた場合に最も精度が高くなることを確認した．

本研究では，ロボットは物体の種類を誤りなく認識可能であるとして物体 ID を与えた．しかし，実際のロボットに応用する際には，ロボットは物体の認識を誤る可能性がある．そのため，今後は物体の認識確率を統合したモデルを用いることを検討したい．また，本研究では概念数を既知としたが，これを未知とした問題設定に対する手法についても今後検討したい．

参考文献

[Landau 93] B. Landau, R. Jacknedoff: “what” and “where” in spatial language and spatial cognition, Behavioral and Brain Sciences, Vol. 16, pp. 217-265, 1993.

[Lee 01] A. Lee, T. Kawahara, K. Shikano: Julius --- an open source real-time large vocabulary recognition engine, In Proc. European Conference on Speech Communication and Technology (EUROSPEECH), pp. 1691-1694, 2001.

[Neubig 10] G. Neubig, M. Mimura, S. Mori, T. Kawahara : Learning a Language Model from Continuous Speech, Proc. Interspeech, 2010.

[谷 17] 谷志翔, 加藤有祐, 田口亮, 服部公央亮, 保黒政大, 梅崎太造：MCMC サンプリングによる相対位置概念の学習，第 35 回日本ロボット学会学術講演会, 2I1-05, 2017.

[相良 17] 相良陸成, 谷志翔, 田口亮, 服部公央亮, 保黒政大, 梅崎太造：発話を入力とした相対位置概念の学習，計測自動制御学会システム・情報部門学術講演 2017 講演論文集，pp.359-364, 2017.

[田口 10] 田口亮, 岩橋直人, 船越孝太郎, 中野幹生, 能勢隆, 新田恒雄：統計的モデル選択に基づいた連続音声からの語彙学習，人工知能学会論文誌, Vol. 25, No. 4, pp. 5491-5501, 2010.

[谷口 17] 谷口彰, 萩原良信, 谷口忠大, 稲邑哲也：ノンパラメトリックベイズモデルと SLAM の統合による地図と場所概念の逐次学習，人工知能学会全国大会, 3D1-OS-37a-2, 2017.

[中村 15] 中村友昭, 長井隆行, 船越孝太郎, 谷口忠大, 岩橋直人, 金子正秀：マルチモーダル LDA と NPYLM を用いたロボットによる物体概念と言語モデルの相互学習，人工知能学会論文誌，Vol. 30, No. 3, pp. 498-509, 2015.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

訓練データの改ざんを考慮した機械学習手法

The Method of Machine Learning Considering Tamper of Training Data

柳町 天使　　石田 好輝
Tenshi Yanagimachi　Yoshiteru Ishida

豊橋技術科学大学
Toyohashi University of Technology

Big data is increasingly used as training data for machine learning. However, large-scale data such as big data is not always appropriate as training data at all times. Particularly when collecting data from Web services such as SNS, unspecified number of people using the service can indirectly tamper with data. In this research, we propose a learning method and verify its effectiveness so as to obtain a learning result close to the case without tampering even in an environment in which part of the training data has been tampered with. In this method, learning is divided into two stages, and the reliability of the training data is estimated using the first stage learning result, thereby assisting the exclusion of tampered data by human beings.

1. はじめに

近年，あらゆる分野で AI（artificial intelligence）の活用が広がっている．AI の実現方法には様々なものがあるが，主に用いられているのはニューラルネットワークを用いて機械学習を行う形式のものである．機械学習では一般的に，訓練データが多いほど学習後の性能が高くなる傾向にある．そのため，ビッグデータのような大規模なデータを訓練データとして用いることも多い [Wu 16]．

ビッグデータは多くの訓練データを用意できるという点で機械学習と相性が良い．しかし，そのような大規模データを用いることで発生する問題もある．特に SNS のような Web サービスからデータを集める場合，サービスを利用する不特定多数の人間が間接的にデータを改ざん可能になる．この性質を悪用された事例として，Microsoft が Twitter 上で公開していたチャットボット Tay が不適切な発言を繰り返すようになったというものがある [Mizoroki 16]．また Google 翻訳でも同様の問題により，本来の訳語とは全く関係のない語に翻訳される不具合が起きている [インターネットコム編集部 17]．このような問題に対して，現在はフィルタリングによる対策が行われている [Lee 16]．しかし，人間の作るフィルターでは望まない入力や出力を全て除外することは難しい．また，AI の活用が広がる中で，今後は自動車の自動運転などミスが許されないタスクにも AI が用いられることが考えられる．よって訓練データの改ざんが行われることを前提とした機械学習手法の確立が求められる．

ラベルにノイズが含まれる環境での機械学習については多くの先行研究が存在する．しかし，想定する状況において先行研究の手法を用いる場合いくつかの解決すべき問題がある．第一に適切な手法がタスクの種類に依存すること．第二に訓練データとは別にノイズの定義が必要であること．第三にノイズの定義が不完全なとき，ノイズの除去も不完全になってしまうこと．そこで本研究では次の二点を満たす機械学習手法の開発を目標とした．一点はタスクに依存せず用いることのできる手法であること．そしてもう一点は，同様の処理を繰り返すことで最終的にノイズのない環境と同程度の学習結果を得られることである．上記の目的を達成するため，1 つの手法の提案と有用性の検証を行った．この手法は，半教師あり学習のように学習を 2 段階に分け，1 段階目の学習結果を用いて訓練データの信頼度を推定することで，改ざんされたデータの除外を試みるものである．

連絡先: 柳町 天使，豊橋技術科学大学 大学院工学研究科

2. 関連研究

2.1 ラベルノイズの存在下における分類

ニューラルネットワークを用いた機械学習の分野において，ラベルノイズの存在する環境下における学習手法の提案は数多く行われている．Frénay and Verleysen[Frénay 14] はこれらの手法を特徴によって次の 3 種類に分類している．

- noise-robust methods（ノイズロバストな手法）
- data cleansing methods（データ浄化による手法）
- noise-tolerant methods（ノイズ耐性のある手法）

3 種類の手法は，ノイズの特性を仮定することで対策を行っている．ノイズロバストな手法では，ノイズの影響は過学習に陥った場合を除いて無視できるものと仮定している．そして過学習自体を回避することでノイズの影響の排除を試みている．データ浄化による手法では，ノイズの付加されたラベルと正常なラベルを判別するためノイズの定義が得られる環境を仮定している．ノイズ耐性のある手法では，ネットワークの構造を工夫することでノイズに対して学習結果が鋭敏に反応しないようにしている．しかし結果的に正常なラベルに対する学習も鈍くなる傾向がある．

また，Jindal, Nokleby, and Chen[Jindal 16] は巨大かつ信頼性の低いデータセットを訓練データとする場合の学習手法を提案している．この手法ではノイズモデルを学習することで正しい分類を行うことを試みている．

これら先行の手法に共通する特徴は，訓練データにどのようなノイズが付加されるのか予想可能な環境での学習であるという点である．本研究において想定する，不特定多数の人間が意図的に改ざんを行う環境ではどのようなノイズが訓練データに付加されるかを予想することが困難である．そこで本研究では，人間がラベルの正常な訓練データをある程度用意することで改ざんされたデータを判別できるニューラルネットワークを学習させる．

2.2 Ugly Duckling Theorem

Watanabe, Knowing and guessing[Watanabe 69] は Ugly duckling theorem（みにくいアヒルの子の定理）として分類問題に関する定理を示している．この定理は複数の対象において全ての特徴量を同等の重みで扱う限り，対象の分類は行えないというものである．機械学習では特徴選択や特徴抽出の基準，各特徴量の適切な重み等を訓練データから学習することで取得する．そのため正常な環境では Ugly duckling theorem で示されるような分類不可能な状態には陥らない．しかし，今回想定するような訓練データに初めから誤ったデータが含まれている環境では適切な基準や適切な重みが得られない．よって分類不可能な状態を回避するためには改ざんされた訓練データとは別の，信頼できる訓練データが必要となる．

2.3 半教師あり学習

本研究では改ざんを考慮した学習手法として，半教師あり学習を参考とした手法を提案する．半教師あり学習はラベル付けされたデータに加えて，ラベルの付加されていないデータを訓練データとして用いることで学習結果の性能を高めることを目的とした手法である [Nigam 98]．このラベル付けされたデータとラベルの付加されていないデータという区別を，提案手法ではラベルの信頼できるデータと信頼できないデータという区別に置き換えて考える．提案手法では信頼できるデータで学習した結果を用いて信頼できないデータのラベルの正しさを推測することで，改ざんの影響を少なく抑える．

3. 手書き数字認識タスク

3.1 タスク概要

本稿では提案手法の有効性の検証のため，タスクとして手書き数字画像の認識タスクを用いる．このタスクは，人間が手書きした「0」～「9」のアラビア数字を認識し適切に分類するというものである．以降に学習のため用いるデータセット，ネットワーク構造，そして訓練データに対するラベルノイズの付加方法について詳細を示す．

3.2 MNIST データセット

訓練データおよびテストデータには MNIST データセット [LeCun 98] を用いる．MNIST データセットは訓練データ 60,000 枚，テストデータ 10,000 枚からなる手書き数字データで，1 枚は高さと幅がそれぞれ 28 pixel のグレースケール画像データである．MNIST データセットに含まれる手書き数字画像の例を図 1 に示す．

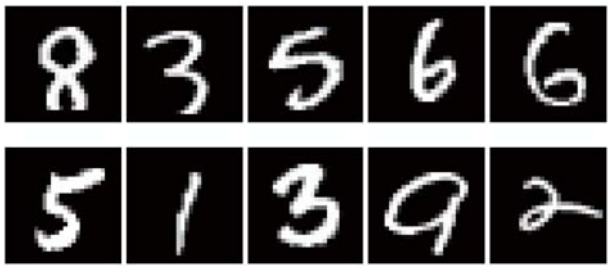


図 1: MNIST データセットに含まれる手書き数字画像の例

3.3 ネットワーク構造

学習用のニューラルネットワークには 1 層の中間層に softmax 層を合わせたものを使用する．ネットワークの構造を図 2 に示す．また，ネットワークの出力値の定義を式 1 に表す．

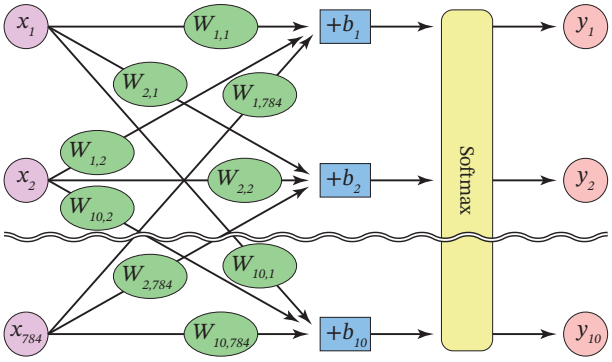


図 2: ニューラルネットワーク構造

$$y_i = softmax(\sum_j W_{i,j}x_j + b_i) \quad (1)$$

y... 出力値

x... 入力値（画像 1 pixel の色情報，0～255）

W... 結合強度

b... バイアス

i... ラベルインデックス（1～10）

j... 画素インデックス（1～784）

3.4 ノイズの付加

本稿において訓練データへのノイズの付加は次のように行う．まず，対象となるデータ群から無作為に一定枚数選出する．次に，選出したデータに対応付けられたラベルを正常なものから 1 つ値を増加させる．つまり正常な「1」のラベルは必ず「2」に書き換えられ，「9」のラベルは「0」に書き換えられる．ランダムな値に書き換えずラベルの変化に法則性を持たせることは，悪意を持った人間の意図的な改ざんを再現することを意図している．

4. 提案手法

初めに提案手法に用いる各用語の定義について示す．次に，提案手法による学習方法について説明を行う．

4.1 用語定義

4.1.1 作成者

タスクを解決するためのニューラルネットワークを作成する人間．訓練データに関してラベルの正しさを判断する基準を持つ．

4.1.2 信頼データ・非信頼データ

改ざんによるラベル誤りが存在する可能性のあるデータを非信頼データとする．そのため，学習の初期状態では全ての訓練データが非信頼データとなる．また，作成者によってラベルが正しいと判断された，もしくは正しいラベルが付け直されたデータを信頼データとする．

4.1.3 振り分けニューラルネットワーク（振り分け NN）

信頼データのみを訓練データとして学習を行ったニューラルネットワーク．非信頼データを後述の仮信頼データ・仮非信頼データ・曖昧データに分類するために用いる．ネットワークの構造は後述の最終ニューラルネットワークと同一のものとする．

4.1.4 仮信頼データ・仮非信頼データ・曖昧データ

非信頼データを振り分けニューラルネットワークの出力値を基準に分類したもの．仮信頼データは十分ラベルが正しいと予想されるもの．仮非信頼データはラベルが誤りであると予想されるもの．曖昧データはその段階で判断の付けられないものとして分類する．それぞれに振り分ける具体的な基準値はタスクごとに設定する．

4.1.5 最終ニューラルネットワーク（最終 NN）

信頼データと仮信頼データを合わせたものを訓練データとして学習を行ったニューラルネットワーク．実際にタスクを処理するために用いる．ネットワークのノード数，階層数といった構造は処理するタスクにより適切なものを用いるが，提案手法は最終ニューラルネットワークがどのような構造であっても利用できることを目標としている．

4.2 学習方法

提案手法による学習方法の概要を次のリストに示す．提案手法ではまず，振り分けニューラルネットワークの学習を行うために信頼データの確保を行う．次に振り分けニューラルネットワークによる非信頼データの分類を行う．振り分けニューラルネットワークによる非信頼データの分類は，ニューラルネットワークの出力値を基準として行う．本稿における以降の実験では，振り分けニューラルネットワークの出力が 0.5 を超過するものを仮信頼データに，0.1 未満のものを仮非信頼データに，その他のものを曖昧データに振り分けている．その後，仮非信頼データと曖昧データから一定数のデータを選択，作成者が正しいラベルに修正し信頼データに追加する．訓練データ全体からではなく仮非信頼データ，曖昧データから修正を行うことで，振り分けニューラルネットワークの学習を効率的に進める．提案手法において重要なことは，信頼データが作成者によってラベルの正しさを保証されたデータのみで構成されていること，そして振り分けニューラルネットワークが信頼データのみを元に訓練されることである．これにより振り分けニューラルネットワークは作成者の示す基準によって対象となるデータの正しいラベルを学習する．最終的に振り分けニューラルネットワークが正常だと判断した仮信頼データと信頼データを合わせて訓練データに用いることで，最終ニューラルネットワークは学習を行う．

1. 訓練データを信頼データと非信頼データに分割，信頼データはラベルを修正
2. 信頼データを元に振り分けニューラルネットワークを学習
3. 振り分けニューラルネットワークを用いて非信頼データを仮信頼データ・仮非信頼データ・曖昧データに分類
4. 仮非信頼データおよび曖昧データから一定数のデータを選択，ラベルを修正し信頼データに追加
5. 残った仮信頼データ・仮非信頼データ・曖昧データを合わせ，新たな非信頼データとして定義
6. （2）～（5）を 1 サイクルとして任意の回数実行
7. 信頼データと仮信頼データを合わせて訓練データとして最終ニューラルネットワークを学習

5. 改ざん率に対する認識精度の検証

5.1 概要と目的

訓練データが改ざんされた環境において提案手法によるラベル修正を行った場合，改ざんのない環境と同程度の学習結果が得られるかを検証する．そのために，一定数の訓練データにノイズを付加し学習を行った際の最終的な認識精度を記録した．

5.2 条件設定

実験条件の概要を表 1 に示す．訓練データの改ざん率を 0～100%の間で変化させる．このときの最終ニューラルネットワークの認識精度を確認する．

表 1: 改ざん率に対する認識精度の検証における条件設定

訓練データ	信頼データ（1,000 枚）＋仮信頼データ
テストデータ	MNIST テストデータ（10,000 枚）
ラベル改ざん率	0～100%（10%刻み）
初期の信頼データ数	10 枚
1 サイクル毎の信頼データ追加数	30 枚

5.3 結果

テスト用データセットを用いて認識精度を確認した結果を図 3 に示す.「提案手法」「ラベルの修正をしない場合」それぞれのグラフは，各条件において 5 回試行した平均を表している．また,「改ざんのない環境での平均認識精度」は訓練データにノイズの付加されていない環境において，用いるニューラルネットワークを愚直に学習させた場合の平均的な認識精度を参考として示したものである．図より，提案の手法では訓練データの 8 割が改ざんされた環境であっても改ざんのない環境と同程度の認識精度を維持できていることを確認した．

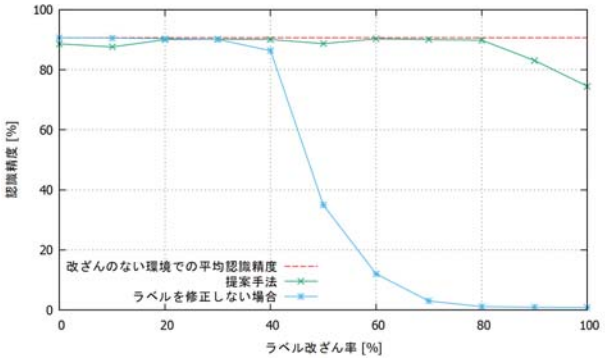


図 3: 無作為なラベル修正と提案手法との認識精度の変化の比較

6. 判断回数に対する認識精度の検証

6.1 概要と目的

提案手法において，作成者によるラベル判断回数を少なく抑えつつ，最終ニューラルネットワークの認識精度を向上できているかを検証する．そのために，作成者によるラベル判断回数を増加させながら，最終ニューラルネットワークの認識精度の変化を記録した．

6.2 条件設定

実験条件の概要を表 2 に示す．本実験では元となる訓練データの 1 割にラベルの誤りを付加している．

6.3 結果

テスト用データセットを用いて認識精度を確認した結果を図 4 に，ラベル修正回数 10～310 回の区間について図 5 示す．それぞれのグラフは「ランダム修正＋仮信頼データの追加なし」

表 2: 判断回数に対する認識精度の検証における条件設定

訓練データ	信頼データ（10〜1,000 枚）＋仮信頼データ
テストデータ	MNIST テストデータ（10,000 枚）
ラベル改ざん率	10%
初期の信頼データ数	10 枚
1 サイクル毎の信頼データ追加数	30 枚

「ランダム修正＋仮信頼データの追加あり」「提案手法による修正＋仮信頼データの追加なし」「提案手法による修正＋仮信頼データの追加あり」の各条件において５回試行した平均を表している．また，ランダム修正とは訓練データ全体から無作為に選んだデータのラベルを修正する方法を表し，仮信頼データの追加なし（あり）とは最終ニューラルネットワークの訓練データとして仮信頼データを信頼データに追加するか否かを表す．図より「提案手法による修正＋仮信頼データの追加あり」の場合が最も早く改ざんのない環境と同程度の認識精度（約９０％）に達していることが分かる．

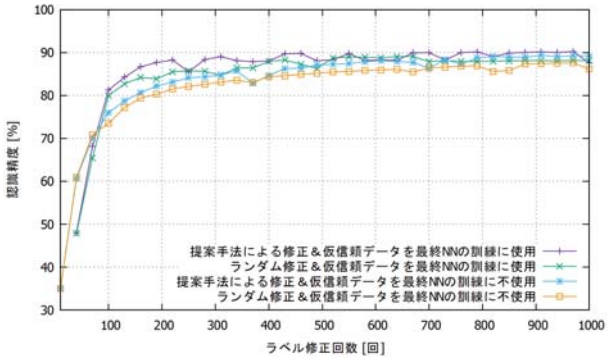


図 4: ラベル判断回数を基準とする認識精度の推移の比較

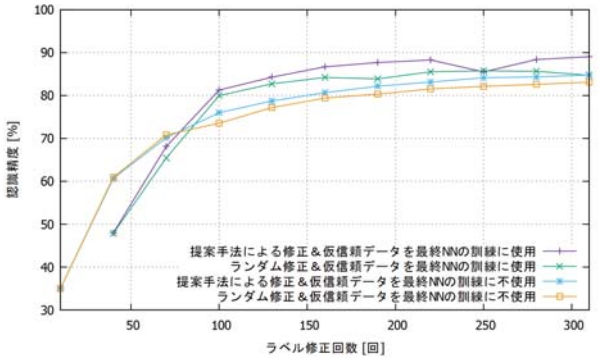


図 5: ラベル判断回数を基準とする認識精度の推移の比較（ラベル修正回数 10〜310 回区間）

7. 考察

改ざん率に対する認識精度の検証の結果より，提案手法によってラベル修正を十分な回数繰り返すことで，訓練データが改ざんされていない環境と同程度の学習結果を得られることが示された．また，判断回数に対する認識精度の検証の結果より，無作為にラベル修正を行う方法と比較して，一定以上の学習結果を得るために必要なラベル修正回数を少なく抑えられていることが示された．以上のことから，提案手法はラベル修正作業に関する作成者の負担を少なく抑えながら，訓練データに対する改ざんのない環境に近い学習結果を得ることが可能であると考える．

8. おわりに

訓練データの改ざんを考慮し，作成者と振り分けニューラルネットワークとでラベルの正誤判断とデータの網羅的検証の役割を分担することで，改ざんのない環境下と同程度の学習結果を得られた．今後は本手法を翻訳等の複雑なタスクに用いて同様の結果が得られるかを確認すること，そして手法をより効率化し作成者の負担をさらに低減できるよう改良を行うことが目標となる．

参考文献

[Frénay 14] Frénay, B.: Verleysen, M.: Classification in the Presence of Label Noise: a Survey, IEEE Transactions on Neural Networks and Learning Systems, 25(5), 845-869, 2014.

[Jindal 16] Jindal, I.: Nokleby, M.: Chen, X.: Learning Deep Networks from Noisy Labels with Dropout Regularization, Proceedings of The 16th IEEE International Conference on Data Mining, 967-972, 2016.

[LeCun 98] LeCun, Y.: Cortes, C.: Burges, C. J.: MNIST handwritten digit database, Yann LeCun, Corinna Cortes and Chris Burges, http://yann.lecun.com/exdb/mnist/, 1998.

[Lee 16] Lee, P.: Learning from Tay ’s introduction - The Official Microsoft Blog, Microsoft: https://blogs.microsoft.com/blog/2016/03/25/learning-tays-introduction/, 2016.

[Mizoroki 16] Mizoroki, S.: Kantrowitz, A.: Microsoft の人工知能は、なぜ虐殺や差別を「支持」するようになったのか……, BuzzFeed Japan: https://www.buzzfeed.com/jp/sakimizoroki/microsofts-ai-chatbot-into-a-neo-nazi-jp, 2016.

[Nigam 98] Nigam, K.: McCallum, A.: Thrun, S.: Mitchell, T.: Learning to Classify Text from Labeled and Unlabeled Documents, Proceedings of The 15th National Conference on Artificial Intelligence, 1998.

[Watanabe 69] Watanabe, S.: Knowing and guessing; a quantitative study of inference and information, Wiley, 1969.

[Wu 16] Wu, X.: Ito, K.: Iida, K.: Tsuboi, K.: Klyen, M.: りんな：女子高生人工知能, 言語処理学会 第 22 回年次大会 発表論文集, 306-309, 2016.

[インターネットコム編集部 17] インターネットコム編集部: Google 翻訳、頼りすぎるのは危険？―「イタズラ」で誤訳の恐れ、なお残る [インターネットコム], internetcom K.K.(Japan): https://internetcom.jp/202511/google-translate-caution, 2017.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

LSTMを用いた人狼予測と人狼ゲーム分析

Prediction with LSTM and Analysis of Werewolf

近藤 まなみ *1 Manami Kondoh　長谷川 拓 *1 Taku Hasegawa　森 直樹 *1 Naoki Mori　松本 啓之亮 *1 Keinosuke Matsumoto

*1大阪府立大学 工学研究科
Graduate School of Engineering, Osaka Prefecture University

In recent years, Werewolf has attracted attention in the field of Artificial Intelligence(AI). Werewolf is a kind of communication game and it is classified as incomplete information game. Since Werewolf has unknown information, it is one of good strategy to judge unknown information based on the prediction. Information that player can know is limited, and fake may be mixed in it. In this paper, it is aimed to predict under uncertain information by learning the tendency of players from limited information in Werewolf. In order to consider the time series of Werewolf, LSTM was used. In addition, Werewolf was analyzed using prediction model made by learning.

1. はじめに

近年，不完全情報ゲームの一種である人狼ゲームが人工知能 (Artificial Intelligence, AI) の分野で注目を集めている．特に，対人間を想定した AI エージェントの構築が期待されているが，人狼ゲームは状態が膨大である，運や確率に依存するなどの不完全情報ゲームとしての難しさに加え，駆け引きや説得などコミュニケーションゲームとしての性質も有するため，ゲームに勝つための戦略と自然な対話が可能な会話力が必要となるが，それらを兼ね備えたエージェントの構築には様々な課題がある．

本研究では，戦略の観点で強い人狼エージェントの構築を目指しており，ゲームを有利に進める方法の一つとして未知情報の獲得に着目している．人狼ゲームでは様々な情報が不確定であるが，そのうちの一つである「役職」は知ることができればゲームを有利に進められうる情報の一つである．本論文では人狼の推定に焦点を当て，既知情報のみから未知情報である人狼の予測を試みている．音楽や言語などの分野で著しい成果を得ている深層学習は，近年ゲーム環境に適用した例も報告されている [1][2]．本論文では人狼ゲームにおいて既知情報から人狼予測に繋がる特徴を抽出するために，深層学習の一種である LSTM（Long Short-Term Memory) [3] を用いる．また，学習の結果得られた人狼予測モデルを用いて，人狼予測における有用な情報や重要なフェーズについて分析する．

2. 人狼ゲーム

人狼ゲームは，情報の少ない多数派 (村人陣営) と情報の多い少数派 (人狼陣営) に分かれて，相手陣営のプレイヤをゲームから排除することで自陣の勝利を目指すゲームである [4]．村人陣営は人狼を全滅させること，人狼陣営は人間を人狼と同数以下にすることが勝利判定条件となっている．村人陣営は誰が人狼であるかを知らないためプレイヤ同士の会話などから人狼を見破る必要があり，人狼は村人に見破られないよう振舞わなければならない．したがって，プレイヤ同士の騙し合いや駆け引き，信頼や説得が重要な要素となるゲームである．

人狼知能プロジェクト [5] では，「人間と自然なコミュニケーションを取りながら人狼をプレイできるエージェントの構築」を目指しており，人狼エージェントが競い合う人狼知能大会を開催している．本論文では，第 3 回人狼知能大会プロトコル部門におけるゲームを対象としている．以下に，ゲームの概要を示す．

2.1 進行

プレイヤ同士が会話をする「Talk」，各プレイヤ処刑したいプレイヤに投票する「Vote」，特殊能力を持つプレイヤが能力を行使する「Action」の 3 つのフェーズが，1 日ごとにこの順に実行される．各フェーズ終了時にどちらかの陣営が勝利条件を満たしていればゲームを終了し，満たしていなければ死亡者をゲームから排除して次のフェーズあるいは次の日へ進む．

2.2 役職

各プレイヤはゲーム開始時に役職がランダムに与えられる．人狼同士はお互いを知ることができるが，基本的には自分以外がどの役職であるかは開示されない．本論文では，村人陣営の「村人」「占い師」，人狼陣営の「人狼」「狂人」，計 4 種の役職を扱う．占い師は divine(占い) 能力を持ち，プレイヤを選択することでそのプレイヤが人狼であるかどうかを知ることができる．人狼は attack(襲撃) 能力を持ち，プレイヤを選択することでそのプレイヤを襲撃することができる．襲撃されたプレイヤは死亡する．村人と狂人は特殊能力を持たない．

2.3 設定

本論文では，人狼知能プロジェクト [5] で公開されているプラットフォーム ver 0.4.9 によるゲームを扱う．ゲームの流れとしては，Talk フェーズ，Vote フェーズ，Action フェーズがこの順で進行するが，ゲーム開始時のみ占い師の divine が実行されてから Talk フェーズが始まる．

また，本ゲームではプレイヤが発言できる内容が限られている．発言はターン制で 1 日最大 20 ターンとなっており，1 ターンにつき各プレイヤは 1 回ずつ発言が可能である．表 1 に本論文におけるゲームで扱われる発言の種類を示す．

3. 提案手法

3.1 概要

本論文では，エージェントの行動や思考を推定・学習するために，深層学習を用いている．一般的に人狼ゲームでは，情報

連絡先: 近藤まなみ，大阪府立大学 工学研究科，大阪府堺市中区学園町 1-1，080-6164-1518，kondoh@ss.cs.osakafu-u.ac.jp

表 1: 発言一覧

ESTIMATE	他プレイヤへの役職の推測を言う.
COMINGOUT	自分の役職を宣言.
DIVINATION	占う対象を宣言.
DIVINED	占った結果を言う.
VOTE	投票対象を宣言.
AGREE	特定の発言に賛成する.
DISAGREE	特定の発言に反対する.
Skip	様子を見る
Over	発言を終える
REQUEST	他プレイヤに行動・発言を要求する.

の価値や量，環境が時間とともに変化するため，ゲームの状態は時系列的に変化する．したがって、時系列特性を考慮したネットワークを使用する必要がある．再帰型ニューラルネットワーク (Recurrent Neural Network, RNN)[6] の一種である LSTM は，通常の RNN ネットワークよりも長期間にわたって時系列特性を考慮することができる．人狼ゲームでは同じ日の情報だけでなく過去の情報を使用するため，LSTM は学習の方法として適していると考えられる．実際に，単一のエージェントによるゲームにおける投票先の予測に関して，会話から投票につながる特徴を見つけるのに LSTM が有用であることは証明されている [7].

本論文では，ゲーム内での既知情報を LSTM の入力値とすることで，未知情報である人狼を予測する．

3.2 ゲームログ

3.2.1 概要

学習のためのデータには，ゲームログを使用する．ゲームログとは過去の対戦内容を記録したログであり，本論文では人狼知能プロジェクトで一般公開されている，第 3 回人狼知能大会プロトコル部門決勝 5 人対戦のログを使用する．このログは 15 種のエージェントから無作為に選ばれた 5 種によるゲームで，全部で 12728 件が公開されている．

ゲームログにはエージェントの名前，役職，ゲーム内での会話などすべての情報が記述されている．実際のゲームを考慮すると，既知情報のみが入力情報として用いることができるため，ゲーム中のプレイヤにとって実際に利用可能な情報のみを使用するものとする．更に実際の入力値としては，発言と投票のすべてのパターンに与えたパターン ID を使用する．ただし「AGREE」,「DISAGREE」の場合は，例えば「4 AGREE Day : 1 ID : 5」であれば,「Day : 1，ID : 5」ではなく，1 日目に 5 番目にあった発言を当てはめてパターン ID が与えられるものとする．

3.2.2 リメイクログ

人狼ゲームでは多様な戦略をとることが可能であり，そのパターンは多岐にわたる．そのため学習データに用いるログの数が多いほど，多くのパターンに対応できると想定される．

提案手法では各発言に個別のパターン ID が与えられているが,「1 番が 2 番を人狼だと思う」と「2 番が 1 番を人狼だと思う」には関連性のないパターン ID が与えられており,「人狼だと思う」という意味的な同一性や,「1 番が 2 番」「2 番が 1 番」という対称性は考慮されていない．例えば，同一内容で各プレイヤのインデックスのみ異なるゲームが 2 つあったとき，意味的な出力は同一になることが望ましい．

そこで，ゲームでの内容は変えずに既存ログの中身を書き換えてリメイクすることで，ログの数を増やす手法を用いる．

表 2: 実験パラメータ

パラメータ	実験 1	実験 2
入力次元	575	759
epoch	600	
中間ノード	800	
最適化手法	Adam	
誤差関数	Soft_max_entropy	

まず，既存ログでの各プレイヤインデックスをランダムに与えなおす．発言や行動のプレイヤインデックスもそれに対応して書き換える．また，各プレイヤはターン開始前に自分の発言を決めてから一斉に発言する．ターン内での発言順はランダムだが，各プレイヤが他のプレイヤの発言を得るのは，ターン終了後となっている．よってターン内の発言は全プレイヤにとって等価であるため，この順番を入れ替えてもゲームには影響がないことになる．したがって，プレイヤインデックスをランダムにしてターンごとの発言をシャッフルすることで，ログに多様性を持たせながらも対称性を考慮し，ゲーム内容を改変せずにリメイクすることができる．

3.3 学習

人狼を予測するために，LSTM を用いた予測モデルを作成する．1 日目は会話のみ，2 日目以降は前日の投票と会話情報を入力していく．会話や投票情報は 1 つ 1 つ入力され，1 日のすべてのデータが入力されると，予測値と実際の値とを比較して学習を進める．なお実際の値 (教師情報) には，人狼であるプレイヤのインデックスが用いられる．1 日が終わるたびに予測モデルを更新し，ゲームが終わったときに予測モデルの状態をリセットする．これが 1 ゲームの学習の流れとなる．

4. 実験

4.1 実験概要

本実験では，村人 2 人，占い師，人狼，狂人各 1 人で構成されている 5 人対戦のゲームを用いた．なお人狼ゲームの性質上，5 人対戦のゲームは 1 日または 2 日で終了する． ベースラインとしては，自分が狼であるという COMINGOUT または占い師による占い結果を全面的に信用したときに人狼が的中する確率を用いた．例えば，占い師が「3 番は人狼だった」と言えば 3 番を人狼と仮定し,「2 番は人間だった」と言えば 2 番以外を人狼と仮定する．2 日目の予測においては，死亡したプレイヤは予測候補から除外した．全 12728 件のゲームログは，訓練用 8000 件，評価用 4728 件に分けた．訓練時は 1epoch あたり 100 ゲームを 1 セットとしてランダムに学習させた．

まず，訓練用の既存ログ 8000 件のみを用いて実験した．全 12727 件のゲームで利用されているパターン ID は 1〜573 であり，それにパディング (0) と未知のパターンに割り当てるための ID を追加し，合計 ID 数は 575 とした．以降，これを実験 1 とする．

また，3.2.2 で述べた手法と既存ログ 8000 件を用いて，各ログに対して 4 件のリメイクログを新たに作成することで，合計 32000 件のリメイクログを用意した．このリメイクログと既存ログ，合計 40000 件を訓練データとして実験した．以降，これを実験 2 とする．

各実験のパラメータを表 2 に示す．

4.2 実験結果

図 1 に，各実験における訓練中の Accuracy の推移を示す．図 1 から，実験 2 よりも実験 1 の方がログの種類が少ないた

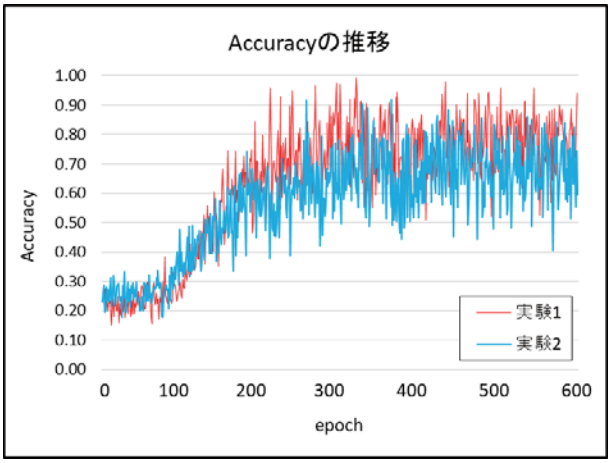


図 1: Accuracy の推移

表 3: 各ログの予測精度

テストログの予測精度			
	モデル 1[%]	モデル 2[%]	ベースライン [%]
1 日目	62.18	58.71	33.97
2 日目	75.29	76.32	47.36
全体	66.98	65.16	38.87
リメイクテストログの予測精度			
	モデル 1[%]	モデル 2[%]	ベースライン [%]
1 日目	54.57	57.74	33.97
2 日目	66.14	73.10	47.36
全体	58.80	63.37	38.87

め，高い Accuracy が得られていることがわかる．

続いて，実験 1，実験 2 で得られた予測モデルをそれぞれモデル 1，モデル 2 とし，テスト用ログ 4728 件に適用した．また，テスト用 4728 件から各ログに対して 1 件ずつリメイクログを生成することで，テスト用リメイクログを新たに 4728 件生成した．このリメイクログに対しても，各モデルを適用した．ただし，リメイクテストログで新たに生成された発言のパターンで，モデル 1，モデル 2 が持つパターン ID に含まれていないものはすべて，未知のパターンに割り当てるための ID を与えるものとした．(実験 1：574，実験 2：758)

それぞれのログに対して予測モデルを適用し，人狼を予測した結果を表 3 に示す．学習時はモデル 2 よりもモデル 1 の Accuracy が高かったが，テストログに対してはどちらのモデルにおいてもほぼ同程度の精度が得られていることがわかる．一方リメイクテストログに関しては，より多くのパターンのログを学習したモデル 2 の方が高い精度が得られた．

5. 分析

モデル 1 とテストログを用いて，ゲーム内容について議論する．実験結果より，人狼ゲームの会話および投票情報から人狼を予測することは可能であることが言えた．そこで，入力する情報量を制限することで，どのような情報が人狼予測のうえで重要とされているかを確認する．ゲームの 1 日目のみを対象として，入力する情報の長さを変えて予測した．図 2 に，各条件での予測精度を示す．ただし，奥行きは単位をターンとした入力する情報の長さ，横軸は入力を開始するターンを示している．例えば横軸が 3，奥行きが 10 の場合は，「3 ターン目から 12 ターン目までの情報」を入力している．なお，20 ターン目まで会話が続かず Talk フェーズが途中で終わっている場合は入力に含まれない．図 2 から，1，2 ターン目が含まれる場合の予測精度は高いが，3 ターン目以降から入力した場合は大幅に予測精度が下がっていることがわかる．よって，1，2 ターン目に人狼を推定するうえで有用な情報が含まれていると考えられる．

ここで，各ターンに含まれる発言の割合を図 3 に示す．なお AGREE，DISAGREE は，1%に満たない割合で含まれているターンがある．図 3 から，1 ターン目には COMINGOUT，2 ターン目には DIVINED の割合大きいことが言える．COMINGOUT は主に占い師と狂人が使用する傾向が強く，その時点で「COMINGOUT したエージェントは人狼ではない」という判断がなされていると推測される．また DIVINED に関しては，その内容は真偽を問わず (真偽自体も考慮すべき点として) ゲーム進行において最も重要な情報の一つであるため，予測モデルもこの情報を人狼を推測するうえで必要な情報として扱っていると推測できる．しかし，1，2 ターン目のみを入力とした場合の予測精度は 32.5%となっており，1，2 ターン目の情報は重要であるがそれのみで予測できるわけではないと考えられる．一方，1 ターン目から入力した際，入力の長さが 7 ターン以上であれば予測精度は常に 60%を超え，それ以上入力の長さを大きくしても予測精度に大きな変化が見られなかった．このことから，会話の後半の情報はそれほど重要ではないと考えられ，実際に 7 ターン目以降は発言内容の 9 割が意味を持たない Skip，Over であることから，この結果は妥当だと言える．

以上から，人狼予測の上で有用な会話情報として「COMINGOUT」「DIVINED」があること，ただしその情報のみでは予測が困難なこと，会話後半の情報は予測のうえで重要ではないことを示すことができた．

6. 考察

人狼予測に関して，表 3 からベースラインを超える精度が得られているため，LSTM による予測は得られる情報からルールベースで仮定するよりも有用である．実際のゲームのプレイを考慮したときも，予測モデルを用いることで論理的な分析や考察，多岐にわたるパターンに対応した推論，手動でそれらを記述するコストを要せず，自動的に人狼を予測することができる．提案手法は未知情報の予測だけでなく，エージェント構築の一助にもなりうる．

また提案手法を用いた予測モデルの作成において，件数が限られたログを用いてより多様なパターンに対応できる予測モデルを作成するためには，ゲームの内容を変えずに新たなログを作成する手法が有効であることが証明された．

予測モデルを用いたゲームに関する分析では．5 人対戦の 1 日目のゲームにおいて人狼予測として必要な情報やその長さについて検討した．本論文では限定的な条件について議論したが，対戦人数や日数が変わった場合，あるいは入力する内容に制限をかけて予測精度を観察するなど，予測モデルを用いた多様なゲーム分析が可能であると考えられる．

7. 結論

本論文では，複数エージェントが混在したゲーム環境で LSTM を用いて未知情報の予測を試みた．その結果，未知情報の一種である人狼の予測が可能であることを示した．分析においては，ゲーム内で重要とされる情報を示した．予測モデル

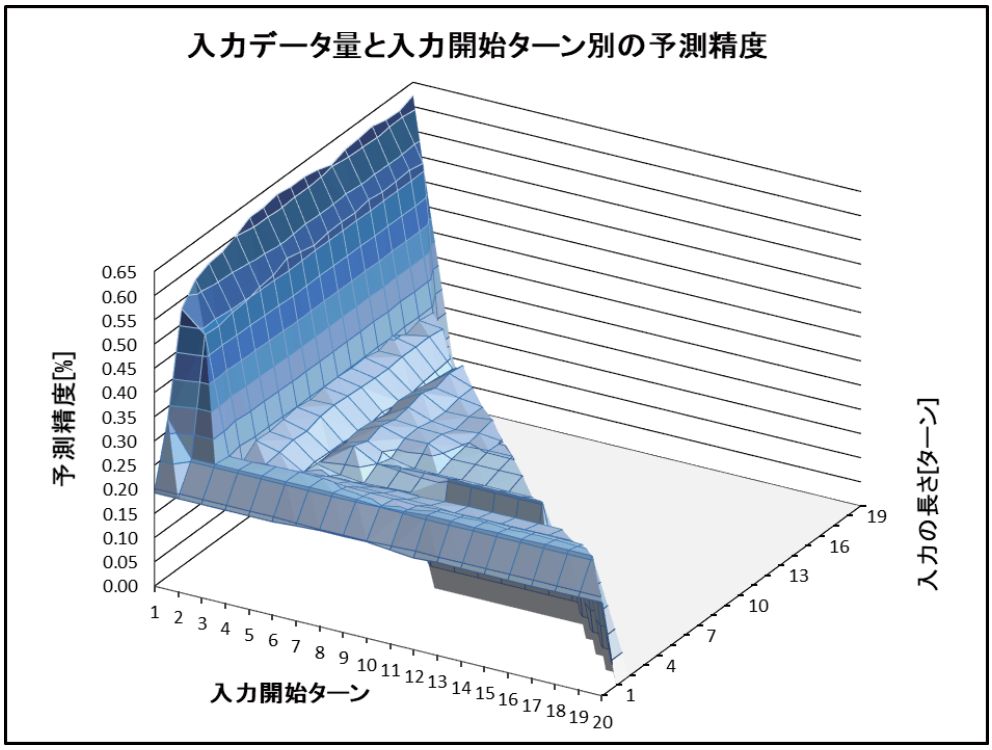


図 2: 入力データ量と入力開始ターン別の予測精度

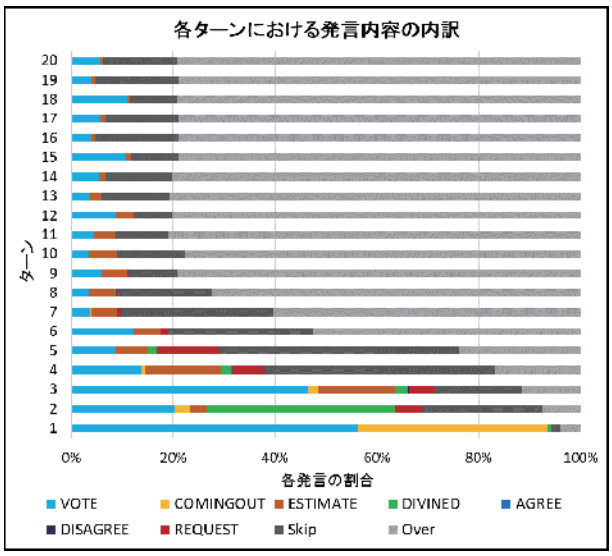


図 3: 各ターンにおける発言内容の内訳

の利用は，ゲームに有用な情報を得るためのみではなく，ゲーム解析の一助となる可能性があることが分かった．

しかし本論文では，5 人という小規模なゲームを対象としており，より人数が多いゲームでの検証がなされていない．例えば人狼知能大会で規定されている 15 人でのゲームは，5 人でのゲームに比べて会話やゲーム日数が長くなり，役職の種類や人狼の数が増えるなど，より情報や環境が複雑性を増す．そのため，入力情報の制限や入力手法の再検討が必要と考えられる．また，予測モデルを実際のエージェントへ適用することも課題の一つとして挙げられる．

謝辞

本研究は一部，日本学術振興会科学研究補助金基盤研究 (C) (課題番号 26330282) および特別研究員奨励費 (課題番号 16J10941) の補助を得て行われたものである．

参考文献

[1] 隅山淳一朗, 橋山智訓, 田野俊一. ぷよぷよにおける人間のプレイデータの特徴量抽出. 第 31 回ファジィシステムシンポジウム, 2015.

[2] Vlad Firoiu, William F. Whitney, Joshua B. Tenenbaum. Beating the world's best at auper smash bros. with deep reinforcement learning. *Cornell University Library*, 2017.

[3] F. A. Gers, J. Schmidhuber, and F. Cummins. Learning to forget:continual prediction with lstm. *Technical Report IDSIA 01-99*, 1999.

[4] 鳥海不二夫, 片上大輔, 澤博隆, 葉通将, 篠田孝祐, 狩野芳伸. 人狼知能 だます・見破る・説得する人工知能. 森北出版株式会社, Mar. 2016.

[5] 人狼知能プロジェクト. http://aiwolf.org/.

[6] Wojciech Zaremba. Recurrent neural network regularization. *Under review as a conference paper at ICLR 2015*, 2015.

[7] Manami Kondoh et al. Agent of werewolf game applying deep learning predictions. *The 6th Asian Conference on Information Systems*, 2017.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

認知的満足化価値関数の分析：保証付き満足化と有限 regret

Analysis of cognitive satisficing value function: Guaranteed satisficing and finite regret

玉造 晃弘 *1　　高橋 達二 *2
Akihiro Tamatsukuri　　Tatsuji Takahashi

*1東京電機大学大学院先端科学技術研究科
Graduate School of Advanced Science and Engineering, Tokyo Denki University

*2東京電機大学理工学部
School of Science and Engineering, Tokyo Denki University

As the domains of reinforcement learning become more complicated and realistic, standard optimization algorithms may not work well. In this paper we introduce a simple mathematical model called *RS* (reference satisficing) that implements a satisficing strategy that look for actions with values above the aspiration level. We apply it to K-armed bandit problems. If there are actions with values above the aspiration level, we theoretically show that *RS* is guaranteed to find these actions. Also, if the aspiration level is set to an "optimal level" so that satisficing practically ends up optimizing, we prove that the regret (the expected loss) is upper bounded by a finite value. We confirm these results by simulations, and clarify the effectiveness of *RS* through comparison with other algorithms.

1. はじめに

強化学習の対象範囲が現実世界に拡大するに伴って探索空間は急激に膨張しており，真に最適な行動は現実的に不可能な場合が多い．そこで我々は，ある基準を超えた価値を持つ行動が見つかるまで探索を続け，そのような行動が見つかり次第探索を止め，その行動で満足する，という満足化（satisficing）[Simon 56] の戦略に着目した．我々は，先行研究では価値関数のレベルで満足化を組み込んだ満足化価値関数 *RS* というモデルを提案し，シミュレーションにより経験的に有効性を確認した [高橋 16].

本論文で，我々はこの *RS* を最も簡単な強化学習問題である K 本腕バンディット問題に適用した場合についての理論的解析を試みる．具体的には最初に満足化の理論的保証を示す．つまり，十分な回数を試行すれば満足化基準を超える行動を安定して選択できるようになるという性質を理論的に示す．次に regret の有限性を示す．一般的に K 本腕バンディット問題のアルゴリズムの性能は regret と呼ばれる期待損失をどれだけ小さくできるかで表される．regret は試行回数に対して少なくとも対数オーダーであることが理論的に知られている [Lai 85]. 一方，*RS* では報酬分布の一部の情報を利用できると仮定すれば，満足化の結果が最適行動の選択（つまり最適化）を意味するようになり，regret は無限大に発散せず有限の値で抑えられる (上に有界になる) という注目すべき性質を示す．これらの性質については，シミュレーションによっても成立を確認する．また，*RS* と他のアルゴリズムとの比較も行う．

2. K 本腕バンディット問題

本論文では報酬確率にベルヌーイ分布を仮定した 2 値の K 本腕バンディット問題を扱う．エージェントには未知の報酬確率 $\{p_1, p_2, \ldots, p_K\}$ に従って，報酬 0 または 1 をもたらす，K 種類の行動 $\{a_1, a_2, \ldots, a_K\}$ があるとする．アルゴリズムの性能を評価する指標として期待損失を表す regret がある．最大の報酬確率をとる行動の添え字を i^* とする (i.e. $p_{i^*} = \max_i p_i$) と，n step 目 (n 回目の試行) の終了時点での regret は次のように定義される．

$$\mathrm{regret}(n) = \sum_{i=1}^{K} (p_{i^*} - p_i) E[n_i(n)]. \tag{1}$$

ここで $n_i(n)$ は n step 目の終了時点までの行動 a_i の選択回数である (step 数を明示しない場合は単に n_i と書く)．$E[\cdot]$ は期待値である．行動 a_i の基本的な価値付けは次で定義される報酬平均 E_i である．

$$E_i = n_i^1 / (n_i^1 + n_i^0). \tag{2}$$

ここで n_i^r は，行動 a_i を行って報酬 r を得た回数である．行動 a_i を選択した回数 n_i は $n_i = n_i^1 + n_i^0$ を満たし，$n = \sum_{i=1}^{K} n_i$ である．一般に価値関数が最も高くなる行動を選ぶ方法を greedy 法という．単に過去の知識を greedy に利用する「利益追求」だけでなく他の行動の価値も試すための「探索」も必要となる．

3. 満足化のモデル

3.1 素朴満足化ポリシー (PS)

満足化は最適化と違い，全ての行動を探索して最適な行動を決める必要がない点で探索のコストを下げることができる．これを強化学習のポリシーとして定式化すると，一つでも行動の報酬平均が基準 R を超えていれば greedy に知識利用を，そうでなければ (全ての行動の報酬平均が基準を下回っていれば) ランダムに選択して探索を，行うこととなる．これを素朴満足化ポリシー (PS: policy satisficing) と呼ぶ．

3.2 満足化価値関数 (RS)

基準との比較は行動 a_i の報酬平均 E_i と満足化の基準 R との差 $\delta_i = E_i - R$ が使われる．

正の δ_i が存在すれば，エージェントは満足してそのような a_i を選択し，そうでなければ不満足である．そこで基準満足

連絡先: 高橋達二, 東京電機大学理工学部, 350-0394 埼玉県比企郡鳩山町石坂, 049-296-5416, tatsujit@mail.dendai.ac.jp

化価値関数 (RS: reference satisficing) を次のように定義する [高橋 16, Oyo 17].

$$RS_i = n_i\delta_i = n_i(E_i - R). \tag{3}$$

エージェントは最大の RS_i 値を持つ行動 a_i を選択するものとする．この形式は，次の 2 つの合理的な満足化行動を統合している．不満足の時は楽観的探索を行う．つまり全ての行動について $\delta_i < 0$ であれば，より選択回数 n_i が小さい行動がまだ試す価値のあるものとして優先される．満足であれば RS は悲観的知識利用を行う．δ_i を正とする行動が複数あれば，より確かなものを求めて選択回数 n_i が大きいものが優先される．

3.3 満足化基準の決め方

基準 R はエージェントの内的な必要性またはその環境についての知識に依存する．R の値が最適行動と次善行動の 2 つの間であれば，R を超える満足化は単純に最適化である．このように最適化は満足化の特別な場合を見なすことができる．この時の R を「最適切基準」と呼ぶ．報酬確率の最大値を p_1，2 番目の値を p_2 とすれば，もっとも単純には次のように設定すれば R は最適切基準となる：

$$R = (p_1 + p_2)/2. \tag{4}$$

なお，あらかじめ最適切基準を設定することは K 本腕バンディット問題の答えを最初から知っていること同じことではないか，という疑問が出てくるかもしれない．しかし，報酬確率の最大値と次に大きい値の間の 1 点の値が分かったとしても通常はどの行動が最適なのかその情報だけでは直ちには分からず，それを効率的に知る方法は決して自明ではない．

4. 理論的な解析

RS の基本的な性質について理論的な解析を行う．

4.1 満足化の理論的な保証

以降の証明では記述を明確にするため，step 数 s と選択行動 a_i を明示した記号を用いる．いずれも s step 目の終了時点での値を表すものとして，報酬平均は，$E(a_i, s) = n_i^1(s)/n_i(s)$，$RS$ の式は，$RS(a_i, s) = n_i(s) \cdot \big(E(a_i, s) - R\big)$ と書ける．

命題 1.（満足化の理論的な保証）行動 a_i の報酬確率を p_i とする（$i = 1, 2, \ldots, K$）．報酬確率が満足化基準 R 以上の行動の集合を A_U，小さい集合を A_L とする．つまり，$I_U = \{i \mid p_i \geq R\}$，$I_L = \{i \mid p_i < R\}$ として，$A_U = \{a_i \mid i \in I_U\}$，$A_L = \{a_i \mid i \in I_L\}$ とする．ただし，A_U は空集合でないと仮定する．このとき，RS では次が成り立つ．

> 「十分な回数を試行すれば必ず満足化基準 R より報酬確率の大きい行動の集合の中から行動を選択し，この状態は安定である.」

この内容は次のように定式化できる．$P(A)$ を事象 A が起きる確率として，

$$P\Big(\arg\max_{a_i} RS(a_i, s) \in A_U\Big) = 1 \ \ (s \to \infty). \tag{5}$$

Claim を二つ示したのちに，命題 1 を証明する．以降では $N_j = \Big\{s \;\Big|\; \arg\max_{a_i} RS(a_i, s) = a_j\Big\}$ とし，行動 a_j が選択される step の集合を表す．$\#N$ で集合 N の個数を表す．

Claim A.

$$\begin{aligned} &i \in I_L \text{のとき}, \\ &P\big(\#N_i = \infty \Leftrightarrow RS(a_i, s) \to -\infty \ \ (s \to \infty)\big) = 1. \end{aligned} \tag{6}$$

証明. (Claim A) $i \in I_L$ のとき，$RS(a_i, s) \to -\infty \ \ (s \to \infty)$ を仮定する．もし $\#N_i < \infty$ となれば，ある番号以上の s において $RS(a_i, s)$ が定数となり矛盾するため，$\#N_i = \infty$ が成立．

逆に $\#N_i = \infty$ のとき，大数の法則より任意の正の数 ϵ に対し，ある S があり，任意の S より大きい整数 $s \in N_i$ に対し，$P\big(|E(a_i, s) - p_i| < (R - p_i)/2\big) > 1 - \epsilon$ とできる．$|E(a_i, s) - p_i| < (R - p_i)/2$ ならば，$RS(a_i, s) = n_i(s) \cdot \big(E(a_i, s) - R\big) < n_i(s) \cdot \big(p_i + (R - p_i)/2 - R\big) = n_i(s) \cdot (p_i - R)/2 < 0$ となる．$s \to \infty$ とすれば，$n_i(s) \cdot (p_i - R)/2 \to -\infty$ となるため，$P\big(RS(a_i, s) \to -\infty \;\big|\; \#N_i = \infty\big) > 1 - \epsilon$. したがって，$\epsilon$ は任意より $P\big(RS(a_i, s) \to -\infty \;\big|\; \#N_i = \infty\big) = 1$. □

Claim B.

$$\text{ある } i \in I_U \text{について } P(\#N_i = \infty) = 1. \tag{7}$$

証明. (Claim B) 任意の $i \in I_U$ に対して $\#N_i < \infty$ であるとする．このとき，任意の $i \in I_U$ に対して，ある番号以上の s について $RS(a_i, s)$ は定数である．またこのとき，いずれかの $j \in I_L$ について $\#N_j = \infty$ となる．Claim A により，$P\big($ ある $j \in I_L$について $RS(a_j, s) \to -\infty \;\big|$ 任意の $i \in I_U$に対して$\#N_i < \infty\big) = 1$ となる．ところが，$RS(a_j, s) \to -\infty$ であることと，任意の $i \in I_U$ に対して $RS(a_i, s)$ がある番号以上で定数であることは互いに矛盾するため，$P\big($ ある $j \in I_L$について $RS(a_j, s) \to -\infty$, 任意の $i \in I_U$に対して$\#N_i < \infty\big) = 0$ でもある．したがって，確率の積の公式より P(任意の $i \in I_U$に対して$\#N_i < \infty) = 0$ でなければならない. □

証明.（命題 1）Claim B より，ある $k \in I_U$ について $\#N_k = \infty$ と仮定してよい．大数の法則より任意の正の数 ϵ に対し，ある S があり，任意の S より大きい整数 $s \in N_k$ に対し，$P\big(|E(a_k, s) - p_k| < (p_k - R)/2\big) > 1 - \epsilon$ とできる．$|E(a_k, s) - p_k| < (p_k - R)/2$ ならば，

$RS(a_k, s) = n_k(s) \cdot \big(E(a_k, s) - R\big) > n_k(s) \cdot \big(p_k + (R - p_k)/2 - R\big) = n_k(s) \cdot (p_k - R)/2 \geq 0$ となる．

よって，$P\big($十分大きい s について $RS(a_k, s) > 0\big) > 1 - \epsilon$. ϵ は任意であるから $P\big($十分大きい s について $RS(a_k, s) > 0\big) = 1$. ここで，もし，いずれかの $i \in I_L$ について，$\#N_i = \infty$ となれば，Claim A より $RS(a_i, s) \to -\infty$ と仮定してよい．ところがこれは，十分大きいすべての s について $RS(a_k, s) > 0$ となる条件と矛盾する．これは，任意の $i \in I_L$ に対して $P(\#N_i < \infty) = 1$ を意味する．したがって，

ある $k \in I_U$ について $P(\#N_k = \infty) = 1$ でかつ すべての $i \in I_L$ について $P(\#N_i < \infty) = 1$ が示せたから， 式 (5) が明らかに従う. □

4.2 regret の理論解析

基準 R を最適切な範囲に設定した RS では regret は有限な値で抑えられることを示す.

命題 2. RS の regret の有限性

全ての行動で報酬確率 p_i が最大となるものを p_1，報酬確率が 2 番目のものを p_2 とする．更に $R = (p_1 + p_2)/2$ となるように R を設定しておく（最適切基準）．

このとき，RS では次が成り立つ．

「$\mathrm{regret}(s) < f(s)$ となる step 数 s の単調増加な関数 $f(s)$ が存在して，$f(s) \to M$（$s \to \infty$）M: 定数 となる．すなわち，$\mathrm{regret}(s) < M$ である．」

以下の証明は RS の類似モデルである TOW（Tug-of-war）モデルを扱っている [Kim 15] の方法を手掛かりにした．ただし，TOW と比べても RS は一般の強化学習への適用が可能など RS の方が優れている点は多い．[Kim 15] では 2 本腕で報酬確率の分散が同じケースに限定して regret が有限であることを示している．つまり，$p_1 = 1 - p_2$ という非常に限られた問題のみ扱っており一般性がない．また，天下りなパラメータが与えられているなどの問題があった．ここでは一般化して，K 本腕でかつ等分散性を仮定しない証明を行う．

証明. （命題 2）$p_1 > p_2 > p_i$ $(i \neq 1, 2)$ とし，$RS(a_i, s) = n_i(s) \cdot \big(E(a_i, s) - R\big)$ $(i = 1, 2, \ldots, K)$ とする．$RS(a_i, s)$ の期待値 E と分散 V は $E[RS(a_i, s)] = n_i(s)\ (p_i - R)$, $V[RS(a_i, s)] = n_i(s)\sigma_i^2$ ただし $\sigma_i^2 = p_i(1 - p_i)$ ．また，

$$\begin{aligned} RS(a_i, s) &= n_i(s) \cdot \big(E(a_i, s) - R\big) \\ &= (X_{i,1} - R) + (X_{i,2} - R) + \cdots + (X_{i,n_i(s)} - R) \end{aligned} \tag{8}$$

と書けることに注意しておく．ただし，$X_{i,j} = 1 \text{ or } 0$ で行動 a_i が j 回目に選択された時の報酬を示す．

$\Delta RS_i(s) = RS(a_1, s) - RS(a_i, s)$ $(i \neq 1)$ と定義すると $E[\Delta RS_i(s)] = n_1(s)(p_1 - R) - n_i(s)(p_i - R) = \{(p_1 - p_i)/2\}(n_1(s) + n_i(s))\{(p_1 + p_i)/2 - R\}(n_1(s) - n_i(s))$. また $V[\Delta RS_i] = n_1(s)\sigma_1^2 + n_i(s)\sigma_i^2$. ここで $(p_1 + p_2)/2 = R$ より，$E[\Delta RS_i(s)] = \{(p_1 - p_i)/2\}(n_1(s) + n_i(s)) + \{(p_i - p_2)/2\}(n_1(s) - n_i(s))$. 命題 1 より step 数 s が十分に大きければ確率 1 で $n_1(s) \to s$ となることから，$E[\Delta RS_i(s)] = \{(p_1 - p_i)/2\}s + \{(p_i - p_2)/2\}s = \{(p_1 - p_i)/2\}s$，$V[\Delta RS_i(s)] \leq (n_1(s) + n_i(s))\sigma_i^2 \leq s\sigma_{1,i}^2$ ． ただし $\sigma_{1,i} = \max(\sigma_1, \sigma_i)$.

式 (8) より $\Delta RS_i(s)$ は中心極限定理により，期待値 $E[\Delta RS_i(s)]$，分散 $V[\Delta RS_i(s)]$ の正規分布に従う．$\Delta RS_i(s) < 0$ となる確率は，$Q(E[\Delta RS_i(s)]/\sqrt{V[\Delta RS_i(s)]})$ である．ここで $Q(x)$ は標準正規分布の裾確率を表す Q-関数である．即ち，$Q(x) = (1/\sqrt{2\pi}) \cdot \int_x^\infty \exp(-t^2/2)\, dt$ である．$(n + 1)$ step 目において行動 a_i を選択する確率 $P[s = n + 1, I = i]$ は，

$$\begin{aligned} P[s = n + 1, I = i] &= P[RS(a_j, n) < RS(a_i, n)\ \ (\forall j \neq i)] \\ &< P[\Delta RS_i(n) < 0] \qquad (9) \\ &= Q(\phi_i \sqrt{n}). \qquad (10) \end{aligned}$$

ここで $\phi_i = (p_1 - p_2)/(2\sigma_{1,i})$ と置いた．Chernoff 限界 $Q(x) \leq (1/2)\exp(-x^2/2)$ を用いて regret の上界を評価する．

$$\begin{aligned} E[n_i(n)] &= \sum_{t=0}^{n-1} P[s = t + 1, I = i] \\ &< \frac{1}{2} + \int_0^{n-1} \frac{1}{2} \exp\Big(-\frac{\phi_i^2}{2} t\Big)\, dt \\ &= \frac{1}{2} - \frac{1}{\phi_i^2}\left(\exp\Big(-\frac{\phi_i^2}{2}(n-1)\Big) - 1\right). \qquad (11) \end{aligned}$$

したがって regret は

$$\mathrm{regret}(n) < \sum_{i=1}^{K} (p_1 - p_i)\left\{\frac{1}{2} - \frac{1}{\phi_i^2}\left(\exp\Big(-\frac{\phi_i^2}{2}(n-1)\Big) - 1\right)\right\} \tag{12}$$

$$\to \sum_{i=1}^{K} (p_1 - p_i)\Big(\frac{1}{2} + \frac{1}{\phi_i^2}\Big) \quad (n \to \infty). \tag{13}$$

□

5. シミュレーションによる検証

証明した性質をシミュレーションで検証した．基準 R は式 (4) のように最適切に設定した．いずれも 1000 回シミュレーションして平均を求めた．パフォーマンスの指標としては，regret の他に，各 step において最適な行動を選んだ比率「正確さ」（accuracy）を用いる．つまり，t step 目の accuracy は，accuracy = （t step 目で報酬確率 p_1 である行動 a_1 を選択した回数）／シミュレーション回数（ここでは 1000 回）となる．最適切に設定した RS であれば報酬確率の差が小さい場合でもその差を検出できるか試すため 2 本腕の場合で報酬確率 $p_1 > p_2$ として $(p_1, p_2) = (0.51, 0.49), (0.501, 0.499)$ で調べた $(R = 0.5)$．結果は図 1 のとおり．regret の図の上部の点線は命題 2 で示した上界を示す．$(0.501, 0.499)$ のように差が 0.002 しかなくても 100 万 step 経過すればほぼ accuracy が 1 になることが分かる．また regret は命題 2 で求めた上界を超えていないことが確認できる．

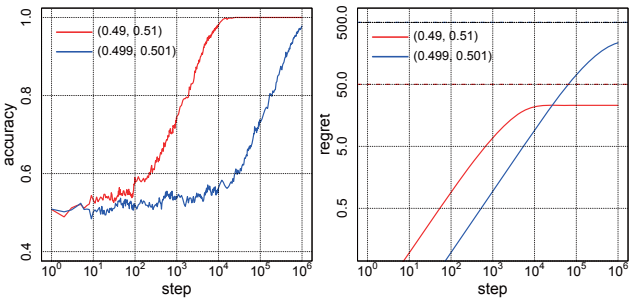


図 1: $K = 2$ (凡例の数値は報酬確率の値) の RS の accuracy (左) と regret (右) の時間発展

次に命題 1 と命題 2 は一般の K 本腕で示したので $K = 10$ でも成立を確認するためシミュレーションした． 今度は報酬確率は $[0, 1]$ の乱数で生成した．結果は図 2 のとおり．$K = 10$ でも accuracy が 1 に近づくことや，regret が命題 2 で示した上界 (式 (13) の値．図 2 の regret の上部にある点線) を超えていないことが分かる．なお，$K = 10$ の regret の上界が $K = 2$ に比べて実際の regret よりもかなり上にある．これは，命題 2 の証明中の式 (9) にあるように行動 a_i が選択される確率を報酬確率が最大の行動 a_1 とだけ比較することで評価しているため，行動の数が多くなるほど報酬確率が最大でない行動の選択確率が過大評価されるためであり，改善は可能であろう．

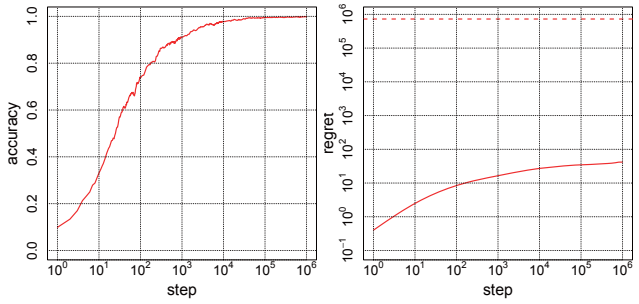


図 2: $K = 10$（報酬確率はシミュレーションごとに乱数で生成）の RS の accuracy（左）と regret（右）の時間発展

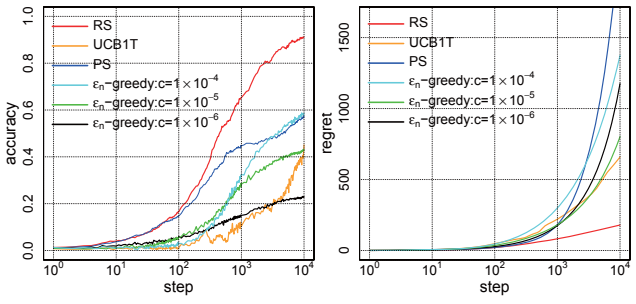


図 3: $K = 100$ の RS，UCB1T，PS，ϵ_n-greedy の比較 (左：accuracy，右：regret)

6. 他のアルゴリズムとの比較

6.1 UCB1-Tuned

UCB（upper confidence bound） [Auer 02] は，regret が理論限界である対数オーダーとなることが保証されている．UCB1 を性能向上させた UCB1-Tuned（UCB1T）と RS を比較する．

$$\mathrm{UCB1T}(a_i) = E_i + \sqrt{\frac{\ln n}{n_i} \min\{\frac{1}{4}, V_i(n_i)\}}\,. \qquad (14)$$

$V_i(n_i) = v_i + \sqrt{2 \ln n / n_i}$ で v_i は行動 a_i の報酬の分散である．

6.2 ϵ_n-greedy

RS と同じく報酬確率に関する情報を利用したアルゴリズムとしては ϵ_n-greedy があり，regret は対数オーダーとなる [Auer 02]．パラメータを $c > 0$ かつ $0 < d < 1$ とし，K 本腕において数列 $\epsilon_n \in (0, 1]$，$n = 1, 2, \ldots$ を次式で定義する．

$$\epsilon_n = \min\Big\{1, \frac{cK}{d^2 n}\Big\}. \qquad (15)$$

a_n が報酬平均最大の行動ならば，確率 $1 - \epsilon_n$ で a_n を選択し，確率 ϵ_n で無作為に選択する．p_1 を報酬確率の最大値とし，d は $\Delta_i = p_1 - p_i$ として $0 < d \leq \min_{i \neq 1} \Delta_i$ を満たす必要があり，設定は簡単ではない．

6.3 シミュレーションによる性能比較

UCB1T，PS，ϵ_n-greedy，RS の性能を $K = 100$ で比較した．性能の指標は accuracy と regret とし，報酬確率は $[0, 1]$ から乱数で選び，1,000 回シミュレーションして平均を求めた．ϵ_n-greedy のパラメータ c を決めるのが難しいが，10,000 step 時点での regret が最小になるのは試行錯誤の結果 $c = 1 \times 10^{-5}$ 付近と経験的に分かったため，$c = 1 \times 10^{-6}, 1 \times 10^{-5}, 1 \times 10^{-4}$ の結果を比較対象とした．d は p_2 を 2 番目に大きい報酬確率として $d = p_1 - p_2$ とし，PS と RS の基準 R は $(p_1 + p_2)/2$ とした．

結果は図 3 のとおり．accuracy は RS が最も速く 1 に近づく．regret については PS は R を超える報酬確率を持つ行動が見つからない限りランダムに行動を選択するため増加のスピードが速い．RS の regret は有限であり，UCB1T や ϵ_n-greedy は対数オーダーで発散するため，RS の方が低く抑えられている．最適切に基準 R を設定した RS は UCB1T，PS，ϵ_n-greedy よりパフォーマンスが良いことが分かる．ϵ_n-greedy と同じく報酬確率に関する情報が事前に必要とはいっても，パラメータ c のようなものなしに有限の regret を達成し，accuracy も良い RS は有用なアルゴリズムといえるだろう．

7. 結論

本論文では，満足化のモデルである RS について K 本腕バンディット問題に適用した際の理論的な分析を行った．基準を満たす行動があれば必ずそれを見つけ出すことや，満足化が最適化に一致する場合は有限の regret が成立することを理論的に示し，またシミュレーションでも成立を確認した．また，他の最適化アルゴリズムと比較し，RS の性能が優れていることを明らかにした．本論文では事前に設定している満足化基準の R をオンラインで推定するアルゴリズムを開発し，理論的な分析を行うことは今後の課題である．RS には本論文で挙げた以外にも多くの優れた点がある．例えば満足化を達成する速さは満足化基準を満たす行動の占める割合に依存し，行動数（つまり問題の規模）にはほぼ依存しないというスケーラビリティがある [Oyo 17]．また RS は特定の課題の形式に依存しない単純な価値関数であるので，一般化することでバンディット問題だけでなく他の強化学習の課題に適用可能である [高橋 16]．RS の更なる応用としては複数のエージェントに複数の基準 を与えて探索を行う並列化などが考えられる．これは最適化問題の判定問題への変換としての理論的な意味を持つ．

参考文献

[Auer 02] Auer, P., Cesa-bianchi, N., and Fischer, P.: Finite-time analysis of the multiarmed bandit problem, *Machine Learning*, Vol. 47, No. 2-3, pp. 235–256 (2002)

[Kim 15] Kim, S. J., Aono, M., and Nameda, E.: Efficient decision-making by volume-conserving physical object, *New Journal of Physics*, Vol. 17, No. 8, 083023 (2015)

[Lai 85] Lai, T. L. and Robbins, H.: Asymptotically efficient adaptive allocation rules, *Advances in Applied Mathematics*, Vol. 6, No. 1, pp. 4–22 (1985)

[Oyo 17] Oyo, K. and Takahashi, T.: Optimization through satisficing with prospects, in *AIP Conference Proceedings*, Vol. 1863, 360013 (2017)

[Simon 56] Simon, H. A.: Rational choice and the structure of the environment, *Psychological Review*, Vol. 63, No. 2, pp. 129–138 (1956)

[高橋 16] 高橋 達二, 甲野 佑, 浦上 大輔：認知的満足化—限定合理性の強化学習における効用, 人工知能学会論文誌, Vol. 31, No. 6, pp. AI30-M-1–11 (2016)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

満足化基準値共有を用いた社会的強化学習

Social reinforcement learning with shared reference satisficing

其田 憲明 *1 Noriaki Sonota　神谷 匠 *2 Takumi Kamiya　甲野 佑 *3 Yu Kono　高橋 達二 *1 Tatsuji Takahashi

*1東京電機大学理工学部 School of Science and Engineering, Tokyo Denki University

*2東京電機大学大学院 Graduate School of Tokyo Denki Univerity

*3株式会社ディー・エヌ・エー DeNA Co., Ltd.

People and animals learn not only through individual trial-and-error, but also from other individuals. It is known that vertebrates cleverly utilize learning strategies such as copy-when-uncertain and copy-successful-individuals. These strategies can be applied to social reinforcement learning, although their formalizations are yet to be established. We propose a social reinforcement learning algorithm with a very narrow information sharing. The algorithm exploits RS value function that models the satisficing principle for exploration and exploitation.

1. はじめに

強化学習では, エージェントが試行錯誤を通じて未知の環境において収益を最大化する行動系列を学習する. 試行錯誤における環境の探索と知識の活用にはトレードオフが存在し, エージェントは両者のバランスを調整しながら学習を行うが, 実環境のような連続状態空間を扱う場合に適切な探索と知識活用を行うことは非常に困難である.

一方で, 人間はある目的水準を満たすことを目的とした場合に満足化原理 [Simon56] と呼ばれる, 現状が非満足状態であれば探索を行い, 満足状態であれば知識活用を行うように意思決定を行うことで, 探索空間の広大な未知の環境であっても目的とする基準を満たすような行動を可能としている. この満足化原理を反映した意思決定手法として, 満足化価値関数 (reference satisficing: RS) が考案された. RS は多腕バンディット問題をはじめとした様々なタスクにおいて少数の探索で素早く満足する行動系列を獲得でき, 適切な基準値を与えられると最適な行動系列を獲得できることがわかっている [高橋 16]. 適切な基準値が不明な場合 RS は動的に基準値を獲得する必要があるが, 効果的な基準値の決定手法は未だ考案されておらず RS の大きな課題となっている.

また, 人間含む脊椎動物は社会的な学習を巧みに行なっており, 社会的学習の戦略として行為の成否が不確実な場合や, 成功している個体がわかっている場合に他の個体の模倣をすることが知られている [Laland 04]. このような社会的学習の性質を利用した複数のエージェントによる群学習は, 単体のエージェントによる学習よりも素早く学習が進められることがわかっている. 本研究では, 複数のエージェントが探索により獲得した情報のうち, 推定された価値から最も良いものを新しい基準値として共有することにより, 社会的な環境における基準値の動的獲得と社会性の表現が可能であるか検討する.

2. 満足化価値関数と満足化方策

強化学習において満足化価値関数 RS は, 状態行動対 s_i, a_j に対する試行量 $\tau(s_i, a_j)$ と行動価値 $Q(s_i, a_j)$, 満足化基準値 $R(s_i)$ から以下の式のように定義され, RS による評価値を最大化するような行動を選択する方策を満足化方策と呼ぶ.

$$RS(s_i, a_j) = \tau(s_i, a_j)(Q(s_i, a_j) - R(s_i)) \tag{1}$$

$$a^{\text{select}} \leftarrow \arg\max_{a_k} \Big(RS(s_i, a_k)\Big) \tag{2}$$

$\tau(s_i, a_j)$ は以下の式で定義され, γ_τ は試行量割引率, α_τ は試行量学習率を表す.

$$\tau(s_i, a_j) = \tau_{\text{curr}}(s_i, a_j) + \tau_{\text{post}}(s_i, a_j) \tag{3}$$

$$\tau_{\text{curr}}(s_i, a_j) \leftarrow \tau_{\text{curr}}(s_i, a_j) + 1 \tag{4}$$

$$\tau_{\text{post}}(s_t, a_t) \leftarrow \tau_{\text{post}}(s_t, a_t) + \alpha_\tau\Big(\gamma_\tau(s_{t+1}, a_{t+1}) - \tau_{\text{post}}(s_t, a_t)\Big) \tag{5}$$

満足化方策では, 推定価値が満足化基準に達しているか否かによって探索と知識利用を切り替える. 基準値を満たす行動が存在しなければ非満足となり楽観的探索を行い, 基準値を満たす行動が存在すれば満足し知識の悲観的活用を行うことで, 少数の探索によって満足な行動系列を素早く学習できる. しかし, 未知の環境に対する適切な基準値の推定は困難で, 探索によって得た知識から動的に獲得する必要がある.

3. 社会的な満足化基準決定

脊椎動物は不確かなものや, 成功している個体の行動の真似をするといった習性が見られる. 人間社会においてもスポーツなどを始めとした様々な分野において, 新たな世界記録保持者が誕生すると今までの記録が次々と抜かれてしまい, 全体のレベルが押し上げられることがある.

強化学習も同様に, エージェント単体で学習を行う場合よりも複数エージェント間で価値を共有し学習を行うことで単体エージェントに比べ効率的に学習できることがわかっている [飯間 06]. しかし価値の共有のみでは, 他のエージェントと同様に行動できるがさらに良い行動を求めて探索することが難しく, 結果として最適な行動を学習できない可能性がある. そこで本研究では, 価値をそのまま共有するのではなく, より良い行動系列が存在するというメタ情報として共有することで, 意思決定における満足化基準を動的に更新しエージェントに探索を促す社会的な満足化基準の決定手法を提案する.

連絡先: 高橋達二, 東京電機大学理工学部, 350-0394 埼玉県比企郡鳩山町石坂, 049-296-5416, tatsujit@mail.dendai.ac.jp

3.1 行動価値の共有

独立した環境上で駆動するエージェント間の行動価値 Q の共有手法として, K 体のエージェント $(0...K)$ の中の最良行動価値 $Q^{\text{best}}(s,a)$ で各エージェントの行動価値を更新する手法が存在する (式 (6)). 他にも各エージェントの情報を残すように $Q^{best}(s,a)$ と自身の $Q(s,a)$ を平均する手法がある.

$$Q(s,a) \leftarrow Q^{\text{best}}(s,a), (\forall s,a) \tag{6}$$

3.2 メタ情報の共有による満足化基準の動的更新

提案手法では式 (6) 式を参考に, 独立した環境上で駆動する各エージェントが 1 試行で得た結果から各状態 s の最良の行動価値である $\max_a Q^{\text{best}}(s,a)$ を全てのエージェントの基準値 $R(s)$ として共有し, 以下の式のように動的に更新する.

$$R(s) \leftarrow \max_a Q^{\text{best}}(s,a), (\forall s) \tag{7}$$

この基準値 R の動的更新によって社会的な行動学習を行えるか, 決定論的バンディット問題によって評価する.

4. 決定論的多腕バンディット問題

決定論的バンディット問題では, 確率的バンディットとは異なり, マシンを選択すると既定の報酬値を確実に獲得できる. また, 獲得できる報酬が多いマシンほど, 線形的に数が少なくなる. 決定論的多腕バンディット問題を用いた理由として, 得られる報酬が決定論的であるため既に探索した行動と未探索の行動の区別や, 最適報酬と非最適報酬の割合などの報酬分布の操作が容易であることが挙げられる.

4.1 シミュレーション設定

報酬 R と対応するマシンの台数 x の関係 (R,x) がそれぞれ, $(0.0,10),(0.1,9),(0.2,8),...,(0.9,1)$ となるように設定した. 合計 55 台のマシンから方策に従いマシンを選択し, 対応した報酬を受け取る. これを 1 エピソードとして 1000 エピソード行い, 累積報酬が最大となる方策を獲得することを目的とした. 提案手法を用いたエージェントを RS エージェントペアと呼び, 比較対象として, 最適基準値 RS, UCB1-Tuned, ϵ-greedy 単体,ϵ-greedy のペア, そして greedy エージェントを用いた. greedy エージェントを除く各エージェントの行動価値 Q は, 初期値を 0 とし, 獲得報酬の平均値である. RS エージェントペアは, 満足化基準値 R の初期値を 0 として 1 回の試行毎に自身の最良行動価値 $Q^{best}(s)$ を相手に通知し, より高い方を基準値 R として更新した. 最適基準値 RS は基準値を 0 から更新する RS ペアと適切な基準を初期から所持する RS との性能比較をするためであり, このタスクで得られる最大報酬である 0.9 と次に大きい 0.8 の間である 0.85 を基準値とした.

行動決定手法として代表的である ϵ-greedy は, ϵ の初期値を 1.0 に設定し, 単体の場合は 1 エピソード毎に 0.0025 ずつ減衰させ, 400 エピソード終了時点で ϵ を 0 になるように設定した. ペアの場合は, 同じ環境下でエージェントが行動するため行動価値 Q を共有し, ペアで行動するため ϵ を 1 エピソード毎に 2 倍の 0.005 ずつ減衰させ, 200 エピソード終了時点で 0 になるように設定した. greedy エージェントは各行動を 1 度試行した上で最高報酬を選び続けた場合と RS ペアの成績を比較をするため, 各状態の行動価値の初期値を 1.0 に設定した.

4.2 結果と考察

図 1 と図 2 に, 1000 回のシミュレーションを平均した結果を示す. 図 1 は期待損失である, regret の推移を表したグラフである. また, RS ペアに関してはエージェント数で平均したものをグラフに利用している. ϵ-greedy 単体と ϵ-greedy ペアを比較すると, ϵ-greedy ペアは ϵ-greedy 単体の 2 倍の速さの ϵ 減少で regret の上昇をほぼ抑えられている. このことから ϵ-greed ペアは単体よりも 2 倍に近い速さで学習を行うことに成功していると考えられるが, RS ペアはさらに regret を半分程度に抑えることに成功している. そして, RS ペアと greedy エージェントの regret が一致しているため, RS ペアは各腕を 1 回ずつ試行した上で最高報酬となる腕を選択していることがわかる. RS ペアと最適基準値 RS を比較すると, 最適基準値 RS は RS ペアよりも regret を低く抑えられている. これは RS ペアは各行動を最低でも 1 度は試行する必要があるのに対し, 最適基準値 RS は報酬 0.9 を得られる行動を発見した時点で満足するためであると考えられる. そして, RS ペアと最適基準値 RS の regret の上昇が停止するタイミングがほぼ一致しているが, これは最適基準値 RS が 55 回目に 0.9 の腕を引く可能性が存在しているためである.

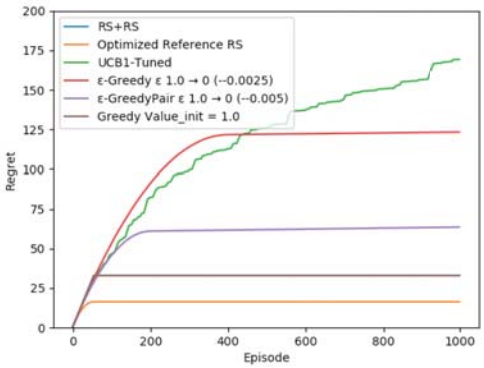


図 1: regret の推移 (バンディット)

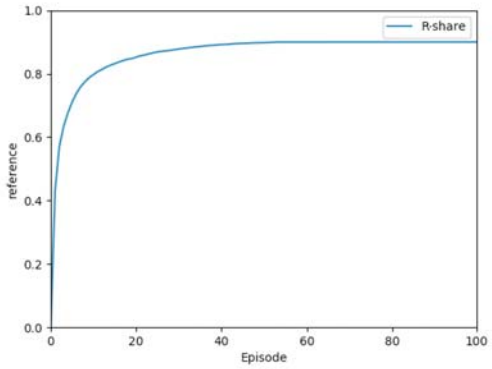


図 2: RSpair 基準値の推移 (バンディット)

図 2 は,RS ペアの共有基準値の推移を表したものだが, 最適基準値 R_{opt} となる範囲である $0.8 < R_{opt} < 0.9$ には 20 エピソード時点で到達しており, 60 エピソードを超えたあたりで最適基準値の 0.9 に到達している. 以上から, RS ペアは最適基準値 RS よりも劣るものの, ϵ-greedy ペアよりも良い成績で最適行動を見つけることに成功しているため, お互いの最良行動価値から基準値を更新する方法は効果的であると考えられる.

次に探索領域の変化と情報共有を行うエージェント数の変化が成績にどのような変化をもたらすかを検証する.

5. 決定論的ツリーバンディット問題

社会的な学習において, 同一環境下で学習を行うエージェントの数や, 探索領域の変化が学習効率に影響を与えると予想される. 決定論的バンディットの性質を維持したまま, エージェント数の変化と探索領域の変化の関係性を観測するため, 満足化方策を用いた先行研究である [牛田 16] で用いられたツリーバンディットと組み合わせた, 決定論的ツリーバンディット問題を行なった.

決定論的ツリーバンディットを用いた理由として, 決定論的多腕バンディットと同様に既に探索した行動と未探索の行動の区別が容易であることに加え, 遅延報酬を考慮した行動系列の複雑さ, 探索領域の変化を層の深さとして容易に管理できることが挙げられる.

5.1 シミュレーション設定

最適累積報酬が得られる行動系列の不確定性, 可変式である層に対応するため, 各ノードのバンディットの設定は, [0.1, 0.2, 0.3, 0.5], [0.1, 0.2, 0.8, 0.9], [0.1, 0.3, 0.4, 0.6], [0.1, 0.3, 0.6, 0.7], [0.3, 0.5, 0.6, 0.8], [0.4, 0.5, 0.6, 0.7] のうちからランダムに一つずつ当てはめる. 始点から終点にたどり着くまでを 1 エピソードとして 5000 エピソード行い, 累積報酬が最大となる方策を獲得することを目的とした. Q 値の更新に用いる学習率 α を 0.1, 割引率 γ を 1.0 に設定した. そして, 信頼度 τ の更新に用いる試行量学習率 α_τ0.1, 試行量割引率 γ_τ を 0.9 に設定した. エージェント数による成績の差を比較するために, RS エージェントに関してはエージェント数を 1, 2, 3, 4, 5 とした 5 通りのグループを用意し, 1 エピソード終了毎に自身の最良行動価値 $Q^{best}(s), (\forall s)$ をグループに通知し, 最も高いものを $R(s), (\forall s)$ として更新した. 探索領域の変化が各グループの成績にどう変化を及ぼすか観測するため, 2 層と 5 層のツリーバンディットを行なった.

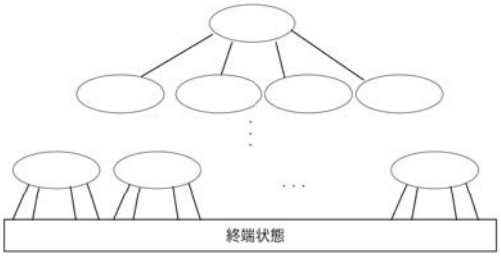


図 3: ツリーバンディットの概要

5.2 結果と考察

図 4 以降に 1000 回の結果を平均した結果を示す. また, 図 6 と図 9 は始点における基準値 R の推移である. そして, RS グループに関してはエージェント数で平均した物をグラフに利用している.

図 4 から 2 層の場合, エージェント数が 2 体以上であると最適累計報酬が得られる最適行動系列を発見することに成功しているが, 1 体の場合は失敗している. これは図 6 と RS アルゴリズムの性質からエージェント数が 1 体のみの場合, 始点の選択肢は全て最低 1 回ずつ選択され, 最初に 2 回以上選択された行動以外は基準値を満たすことができなくなる. そのため, 唯一基準を満たしている行動が非最適行動である場合, 最適行動系列の発見が不可能になる事態に陥ったと考えられる. また, 5 層の図 7 からは, 探索領域に拡大に伴い, エージェント数が多いグループほど最終的に得られる報酬が大きくなるが, 図 7 と図 8 から反対に初期の探索段階での獲得平均報酬は少なくなっているため, regret の上昇が大きくなっている.

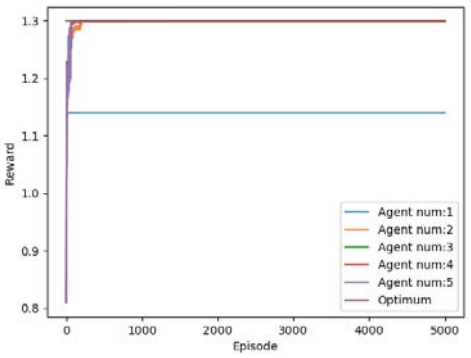


図 4: 獲得平均報酬 (2 層)

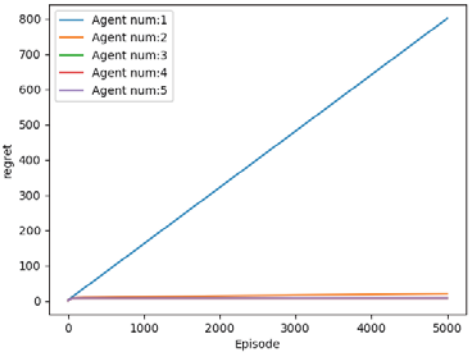


図 5: regret 推移 (2 層)

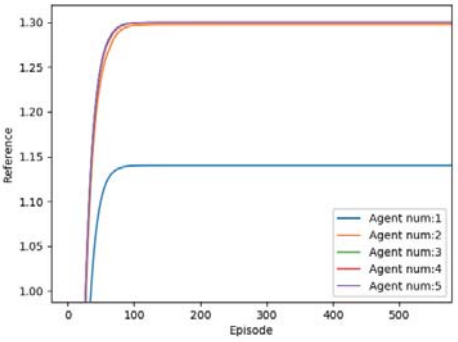


図 6: 基準値 R の推移 (2 層)

一方, 図 6 と図 9 から探索領域が拡大されるに従ってグループのエージェント数が多いほど素早く, より高い基準値に設定されていたことがわかった. これは, エージェント数が多いほど初期段階で得られる報酬が確率的に大きくなるからであると考えられる. これらから, エージェント数が多いほど基準値が高く設定されるため, 図 8 などに見られるように序盤の regret が大きく上昇していると考えられる. このことから, 探索領域が大きくなるに従って同一環境下で探索するエージェント数が多くなるほど, 最終的により良い結果が得られていたため, エージェント数が多いほど社会的学習が効率よく行われることがわかった. しかし, エージェント数が増えるほど序盤の regret が大きく上昇されるため, 低く抑えるための工夫が必要であると考えられる.

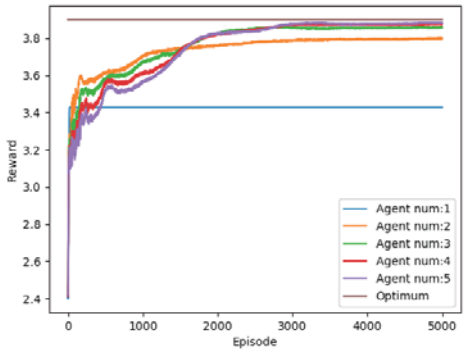


図 7: 獲得平均報酬 (5 層)

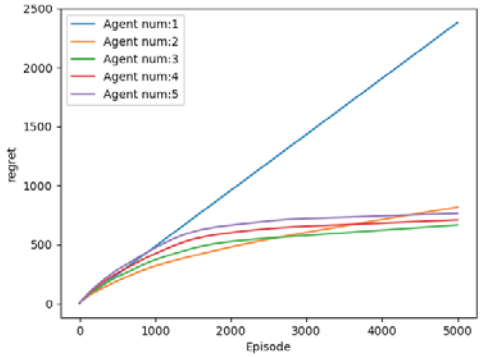


図 8: regret 推移 (5 層)

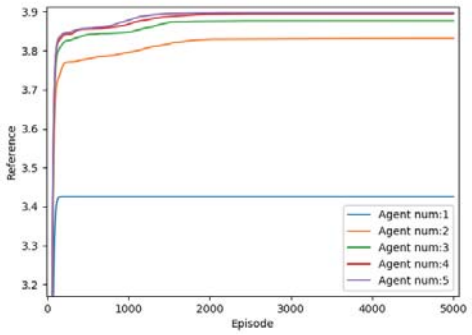


図 9: 基準値 R の推移 (5 層)

6. 総合考察

基準値の動的獲得の面に関して，1 体で学習を行なった場合は早期に基準値の更新が行われなくなった．それに対して 2 体以上のエージェントで学習を行なった場合, 基準値を社会的に更新することに成功しており，エージェント数が増えるほど，より高く適切な基準値に設定することに成功していた．

また, 獲得平均報酬の推移から 1 体で学習を行う場合は基準値の更新が早期に行われなくなるため, より良い行動を発見することが出来ずに局所解で満足することが見られた．それに対して，2 体以上のグループで行う社会的学習において, 他者のより良い成績から自身の既知である行動よりも報酬を得られる行動を探索することで, グループ全体でより高い報酬を得ることに成功している．これら結果を得られた主な要因としては, エージェント数の変化によって一度のエピソードで選ばれる行動が増えることで, 確率的に設定される基準値が高くなること, そしてエージェント数が多いほど基準値がより高い値に素早く設定されるため, より多い報酬を得るための探索に素早く移ることができるためであると考えられる．

以上から，人間社会の競技などにおける新たに良い成績が記録されると, そのほかの競技者の探索によって過去の成績を次々と抜いていき, 全体のレベルを向上させるといった社会的な学習を行うことに成功していると考えられる．

しかし, 今回は決定論的なタスクのみを扱っていること, エージェント数が多くなるに従って序盤の regret の上昇が大きくなっていることから, 確率的にタスクへの適応に向けたより良い基準値共有手法の発見, そして今回情報共有を行っていない試行量と行動価値 Q を共有する方法を模索することで改善できるのではないかと考えられる [柄谷 85].

7. 結論

本研究ではグループ内での最高成績を満足化基準値として共有することで, RS エージェントグループが社会的に基準値の動的獲得を行うことが出来るのか, そしてエージェント数の変化と探索領域の変化が成績にどう変化をもたらすかを検証した．RS エージェントグループはグループ内での最高成績から社会的に基準値を更新し, さらに良い行動を探索をすることで最終的により良い行動を発見することに成功していた．これらの結果により最小限の情報共有 (基準値 R) を利用した, 満足化による社会的な最適行動の探索・学習側面をシミュレーションによって端的に示すことができた．しかし, エージェント数が増えるに従って序盤の regret が大きく上昇する現象が見られたため, 今回情報共有を行っていない試行量と行動価値 Q を利用することで, さらに良い社会的学習手法を模索することが可能であると考える．

参考文献

[Laland 04] Laland, K.N.:Social learning strategies, Learning & Behavior, 2004, 32(1), 4-14 (2004)

[Simon56] Simon, H.A.:Rational choice and the structure of the environment, Psychological Review, Vol. 63, No.2, pp. 129-138 (1956)

[飯間 06] 飯間　等, 黒江康明:エージェント間の情報交換に基づく群強化学習法, 計測自動制御学会論文集, Vol. 42, No. 11, 1224/1251(2006)

[牛田 16] 牛田有哉, 甲野佑, 浦上大輔,　高橋達二:探索割合を自立調整する強化学習手法-満足化基準の動的獲得-, JSAI 2016 (2016 年度人工知能学会全国大会 (第 30 回)) 予稿集, 1M2-3 (2016)

[高橋 16] 高橋達二, 甲野佑, 浦上大輔：認知的満足化-限定合理性の強化学習における効用, 人工知能学会論文誌, Vol. 31, No. 6, pp. 111 (2016)

[柄谷 85] 柄谷 行人：ブタに生れかわる話, 批評とポスト・モダン, pp. 257260. (1985)

[1N2] [General Session] 2. Machine Learning

座長:岡本 昌之（トヨタ自動車株式会社）

Tue. Jun 5, 2018 3:20 PM - 5:00 PM Room N (2F Sakurajima)

[1N2-01] Sequential User Profiling from Newspapers’ Access Log

○Wataru Kudo[1], Fujio Toriumi[1] （1. The University of Tokyo）

3:20 PM - 3:40 PM

[1N2-02] A Nonparametric Delayed Feedback Model for Conversion Rate Prediction

○Yuya Yoshikawa[1], Yusaku Imai[2] （1. STAIR Lab, Chiba Institute of Technology, 2. CyberAgent, Inc）

3:40 PM - 4:00 PM

[1N2-03] Learning Style-sensitive Word Vector via Unsupervised-manner

○Reina Akama[1], Kento Watanabe[1], Sho Yokoi[1,2], Sosuke Kobayashi[3], Kentaro Inui[1,2] （1. Tohoku University, 2. RIKEN AIP, 3. Preferred Networks, Inc.）

4:00 PM - 4:20 PM

[1N2-04] Multiplex Network Embedding with Layer Vectors

○Ryuta Matsuno[1], Tsuyoshi Murata[1] （1. Tokyo Institute of Technology）

4:20 PM - 4:40 PM

[1N2-05] Quantification of contribution of features to EEG classification using the efficient estimation of Shapley Value based on a hierarchy of EEG features

○Kazuki Tachikawa[1], Yuji Kawai[1], Jihoon Park[1], Minoru Asada[1] （1. OsakaUniversity）

4:40 PM - 5:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

新聞記事のアクセスログを用いたユーザ属性の逐次推定

Sequential User Profiling from Newspapers' Access Log

工藤 航　　鳥海 不二夫
Wataru Kudo　　Fujio Toriumi

東京大学
The University of Tokyo

With the spread of social media and e-commerce websites, the technology of user profiling from users' action history has attracted a lot of interest. Users' action history can be acquired both in the passive way and in the active (interactive) way, and previous studies have found out how to presume the users' profile from their action history which is acquired passively. The purpose of this study was to find out the best way to interact with users for efficient user profiling. First, we constructed a CNN (Convolutional Neural Network) model which presumes user's profile. Next, we proposed three ways to interact with users for efficient user profiling. Two ways of the three were discovered to be effective to streamline the user profiling.

1. はじめに

近年，ソーシャルメディアや EC サイトなどの普及に伴い，蓄積された膨大なデータを用いた研究が盛んに行われている．その一例として，各種のサービスにおけるユーザの行動履歴からユーザの性別や年齢といった属性を推定する手法の研究が挙げられる．属性未知のユーザに対する属性推定は，社会科学などの学術的な分野，および企業のマーケティング戦略のような商業的な分野に大きく貢献することが期待できる．

属性推定に用いる行動履歴の取得方法として，ユーザとの対話的なやり取りの中でユーザの反応を記録する方法が考えられる．EC サイトやマルチメディアにおけるコンテンツのリコメンドに対するユーザの反応を取得することも，対話的な情報取得の一例と言える．

本研究では，対話的な情報取得が行える状況の下で，ユーザから引き出す情報を属性推定という目的に応じて能動的に選択することによって，受動的に情報が蓄積される場合に比べて効率的に推定を行うことができるという可能性に着目する．本研究では，まずユーザが読んだ新聞記事のタイトルからユーザの属性を推定できるモデルを構築する．次に，構築したモデルを用いて記事の入力に対し逐次的な推定を行うことで推定の効率を評価し，効率的な推定を行うためのユーザとの対話戦略について明らかにする．

2. データ概要

本研究で用いるデータの概要を表 1 に示す．本研究では，ユーザが読んだ記事のタイトルからユーザの性別・年齢・職業を推定するモデルを構築する．性別は { 女性，男性 } の 2 種類，年齢は {20 代以下，30 代，40 代，50 代，60 代以上 } の 5 種類，職業は { 会社員，主婦，学生，無職，自営業 } の 5 種類とした．

表 1: データ概要

データ提供	日本経済新聞社
対象ユーザ	日経電子版に登録されたユーザ
対象期間	2017/5/21 から 2017/8/18 まで
ユーザ数	1,606,192
記事数	104,896
行動履歴	ユーザが読んだ記事のタイトル
推定する属性	性別，年齢，職業

3. 属性推定モデルの構築

3.1 手法

本研究では，テキストの意味的な特徴からユーザ属性を推定するモデルを構築するべく，Kim[Kim 14] が提案した畳み込みニューラルネットワーク (CNN) を参考にしたモデルを用いた．まず，ユーザが読んだ記事のタイトルというテキスト情報に対し，工藤ら [Kudo 05] が開発した形態素解析エンジン MeCab を用いて単語に分ける．一つ一つの単語に対し，Mikolov ら [Mikolov 13] が提案した手法を用いて鈴木ら [鈴木 16] が日本語版 Wikipedia の本文全体から学習を行った word2vec モデルを用いて単語の埋め込みを行う．これらの処理を経て行列化された個々のユーザに関するテキスト情報を CNN の入力とする．

比較対象としては，ランダムに推定を行った場合の期待される結果のほかに，Lilleberg[Lilleberg 15] が提案したサポートベクターマシーン (SVM) を参考にした手法を採用した．表 2 に，各手法の特徴を示す．

表 2: 各手法の特徴

	特徴抽出方法	意味	時系列性
CNN	畳み込み	○	○
SVM	ベクトル加重和	○	×

連絡先: 工藤航，東京大学大学院システム創成学専攻 鳥海研究室，東京都文京区根津 1-24-5，09030938349，kudo@torilab.net

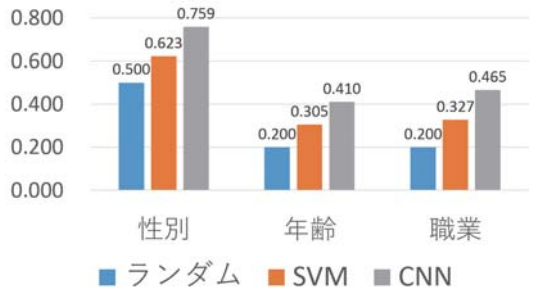


図 1: 正解率の比較

3.2 結果

各手法によって性別・年齢・職業という 3 種類の属性に対し推定を行ったときの正解率を図 1 に示す．機械学習を用いることで正解率を高められること，及び CNN を用いることで最も精度良く推定を行えることがわかった．

3.3 考察

図 1 に示したとおり，全ての属性において，推定の正解率は CNN(畳み込みニューラルネットワーク) > SVM(サポートベクターマシーン) > ランダム という結果になった．このことから，ユーザの読む記事のタイトルの意味的な特徴からユーザの属性を推定することが可能であると示された．また，CNN のモデルが最高の性能を示したことから，本研究の属性推定問題に対して記事のタイトル中の単語の時系列性を考慮すること，および単語の意味的な特徴を抽出する方法として畳み込みを用いることの有効性が示された．

4. 効率的な属性推定

4.1 記事の優先度を測る 3 つの指標

ユーザから対話的に情報を取得して効率的な属性推定を行うためには，推定の手がかりになりそうな記事を優先的に選択し，ユーザの反応を取得していく必要がある．そこで，属性推定という目的に応じて各記事の優先度を比較するための数値的な指標を 3 つ提案した．

指標 1 (被アクセスエントロピー)

読者の属性分布に偏りがある記事ほど属性推定の手がかりになりやすいと考えられる．そこで，各記事の読者の属性分布のエントロピーを計算し，指標 1 (被アクセスエントロピー) と定義する．分布の偏りが大きいほどエントロピーの値が小さくなるため，被アクセスエントロピーの値が小さい記事から優先的に選択していくことによって推定の効率化を図る．

指標 2 (推定出力エントロピー)

各記事のタイトルをモデルに入力することで，属性の各分類ラベルへの所属確率を表す推定出力を得ることができる．この推定出力の偏りが大きい記事ほど属性推定の手がかりになりやすいと考えられる．そこで，推定出力の確率分布のエントロピーを計算し，指標 2 (推定出力エントロピー) と定義する．推定出力エントロピーの値が小さい記事から優先的に選択していくことにより，推定の効率化を図る．

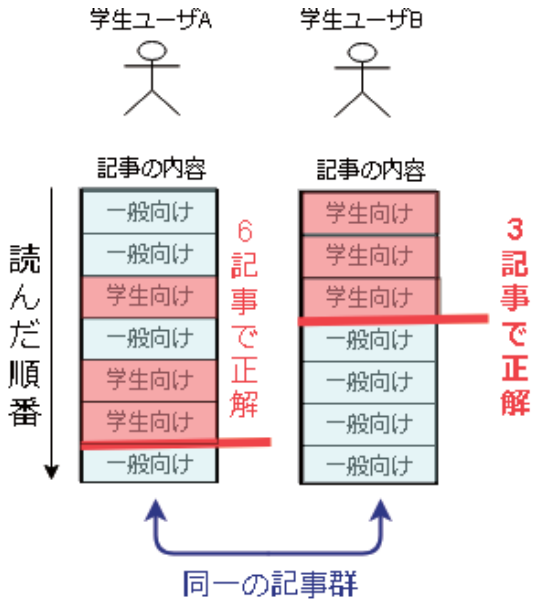


図 2: 同一の記事を読んだ 2 人の学生ユーザに対する推定効率の違い

指標 3 (正解ラベル確率上昇度)

ユーザが読んだ記事から属性推定を行う場合，記事の入力に対して逐次的に推定を行うことによって，一つ一つの記事がもたらした推定への影響を測ることができる．ここで，属性が既知であるユーザに対して逐次推定を行った際，各ユーザの正解ラベルの確率を大きく上昇させた記事ほど推定への貢献度が高いと考えることができる．

そこで，属性既知の多数のユーザに対して逐次推定を行い，各記事がもたらした正解ラベル確率の上昇度を全て記録する．それらの上昇度について記事ごとに総和を計算したものを指標 3 (正解ラベル確率上昇度) と定義し，新たな別のユーザに対して推定を行う際に指標 3 の値が大きい記事から優先的に選択することによって推定の効率化を図る．

4.2 3 つの指標がもたらす推定効率の評価・比較

図 2 のように，2 人のユーザが同一の記事を読んだとしても，読む順番が異なれば正解に到達できるまでに必要な記事数は異なる．すなわち，推定の効率はユーザが記事を読む順番に依存すると考えられる．ここで，ユーザに記事タイトルを提示してユーザが読むかどうかを記録するという方法で行動履歴を取得する際，属性推定の手がかりになりそうな記事から優先的に選択して提示することによって推定の効率化が期待できる．

本研究では，4.1 節で述べた 3 つの指標に従った順番で記事を選択し，記事選択ごとに各ユーザの推定結果を更新していく逐次推定を行った．そして推定効率の評価基準として，記事選択のステップごとの属性推定の正解率の推移を採用した．図 3 で示すように，正解率がより速く上昇する推定の方が効率の良い推定であると評価できる．

そこで，推定効率の数値的な評価基準を得るために，図 4 のように正解率の推移曲線の積分値を計算し「効率面積」と定義する．効率面積が大きい推定の方が効率の良い推定であると評価できる．

提案した 3 つの指標がもたらす推定の効率を評価・比較す

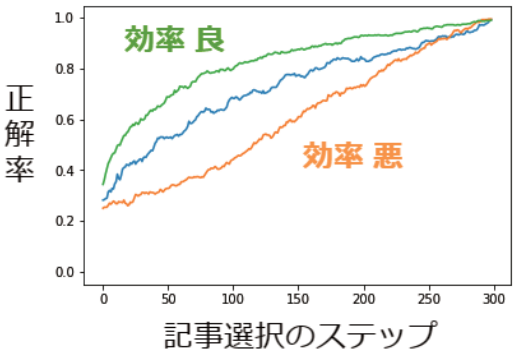


図 3: 正解率の推移

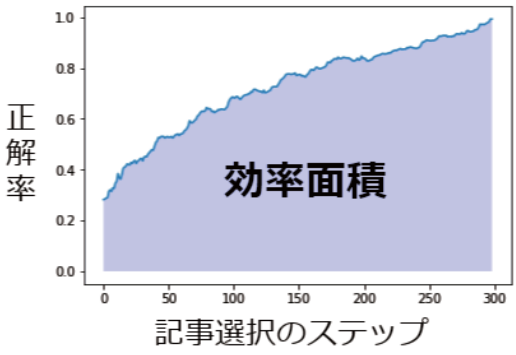


図 4: 効率面積の定義

るために，設定の異なる 2 つの実験を行った．1 つ目の実験と結果について 4.2.1 項，2 つ目の実験と結果について 4.2.2 項で述べる．

4.2.1 実験 1 (ユーザが読んだ記事の並べ替え)

1 つ目の実験は，各ユーザが読んだ記事を 3 つの指標の値によって並べ替えて入力を行う実験である．「指標によって並べ替えられた順番通りにユーザが記事を読んだと仮定したときに，推定効率が高くなるのはどの指標を用いた場合なのか」ということが明らかになる．この実験の結果から，個々の記事における「ユーザがその記事を読んだ際の推定への貢献度」を各指標が正しく予測できるかどうかという評価を得ることができる．

図 5 に，ユーザが読んだ順番で入力を行った場合，ユーザが読んだ記事をランダムに並べ替えて入力を行った場合，及び 3 つの指標によって並べ替えて入力を行った場合の推定の効率面積を示す．

図 5 より，読んだ順番に入力した場合とランダムに並べ替えた場合は同程度の効率を示すということ，そして提案した 3 つの指標によって効率的に推定を行えることが明らかになった．また，特に指標 2 (推定出力エントロピー)，指標 3 (正解ラベル確率上昇度) を用いることで効率の良い推定を行えることがわかった．

4.2.2 実験 2 (ユーザが読んでいない記事を含めた並べ替え)

2 つ目の実験は，1 つ目の実験に比べより現実的な状況を想定したものである．

ユーザが読んだ記事と読んでいない記事からなる候補記事群を 3 つの指標によって並べ替えて順に選択していく．選択された記事が実際にユーザが読んだものであった場合はその記事

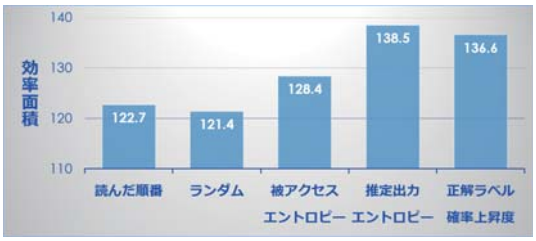


図 5: 効率面積の比較 (ユーザが読んだ記事を並べ替えた場合)

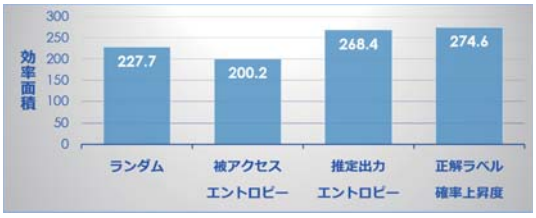


図 6: 効率面積の比較 (ユーザが読んだ記事と読んでいない記事からなる候補記事群を並べ替えた場合)

を入力し，各ラベルの所属確率の更新を行う．ユーザが読まなかった記事を選択してしまった場合は，確率に変化は起こらない．従って，効率の良い推定を行うためにはユーザの読む確率が高い記事を選択する必要がある．

この実験では，各指標によって推定への貢献度が高い記事を優先的に選択できるかということに加え，ユーザの読む確率が高い記事を優先的に選択できるかということも含めた総合的な推定効率化についての評価を得ることができる．

図 6 に，ランダムに並べ替えて選択を行った場合，及び提案した 3 つの指標によって並べ替えて選択を行った場合の推定の効率面積を示す．

4.2.1 項で行った実験とは異なり，指標 1 (被アクセスエントロピー) を用いた場合はランダムに並べ替えて選択を行った場合よりも推定効率が下回った．また，指標 3 (正解ラベル確率上昇度) を用いた場合の推定効率が指標 2 (推定出力エントロピー) を上回った．

4.3 考察

まず，実験 1 で示された結果について考察する．読んだ順番に入力した場合がランダムに並べ替えた場合と同程度の効率を示したことから，受動的に蓄積されたユーザの行動履歴を用いた属性推定は非効率であるということが示された．また，提案した 3 つの指標を用いることで推定を効率化できたことから，3 つの指標によって各記事の推定への貢献度を予測可能であるということが明らかになった．さらに，指標 2 (推定出力エントロピー) と指標 3 (正解ラベル確率上昇度) が指標 1 (被アクセスエントロピー) を上回ったことから，推定モデル由来の指標の方が統計情報をもとにした指標よりも優れているということが示された．

次に，実験 2 の結果について考察する．指標 1 (被アクセスエントロピー) を用いた場合がランダムに並べ替えた場合を下回ったこと，指標 3 (正解ラベル確率上昇度) が指標 2 (推定出力エントロピー) を上回ったことという 2 点において実験 1 と異なる結果となった．このことから，選択された記事をユーザが読む確率が指標ごとに異なり，そのことが推定の効率に影響

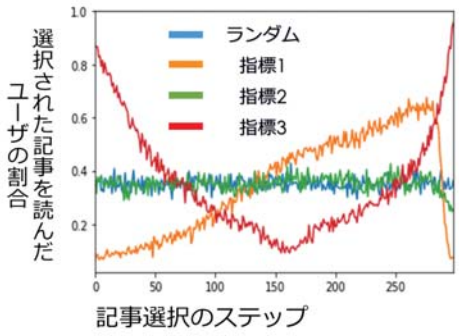


図 7: 選択された記事を読んだユーザの割合の推移

表 3: 各指標の評価 (◎:非常に有効，○:有効，△:効果なし，×:逆効果)

	推定への貢献度	読まれる確率	推定の効率化
ランダム	△	△	△
指標 1	○	×	×
指標 2	◎	△	○
指標 3	◎	○	◎

を与えたと考えられる．

そこで，選択された記事を読んだユーザの割合が記事選択のステップごとにどのように推移していくかを指標ごとに調べたところ，図 7 のようになった．

推定効率という観点でより重要だと考えられる序盤の記事選択に着目すると，指標 3 (正解ラベル確率上昇度) を用いることでユーザの読む確率が高い記事を優先的に選択できていることがわかる．一方で，指標 1 (被アクセスエントロピー) を用いるとユーザの読む確率が低い記事を優先的に選択してしまう傾向があることが明らかになった．以上のことから，各指標の評価をまとめると表 3 のようになる．推定への貢献度の予測，およびユーザが読む確率の予測という両面から考えると，指標 3 が最も推定を効率化できるということが明らかになった．

5. 結論

本稿では，日本経済新聞社が提供する Web サービス「日経電子版」に登録しているユーザを対象とし，テキスト情報からのユーザ属性の推定手法，属性推定の効率化という 2 つの連続したテーマで研究を行った．

第 3 章で述べたように，日経電子版に登録されたユーザの読んだ記事のタイトルから，ユーザの性別・年齢・職業が推定可能であるということがわかった．すなわち，読む記事には属性ごとに傾向があり，記事のタイトルのセマンティックな情報からその傾向を学習可能であるということが明らかになった．

また，第 4 章で述べたように，能動的な推定において効率的に推定を行う手法を発見することができた．提案した 3 つの指標のうち，2 つが推定の効率化に有効であるということが明らかになった．さらに，記事の推定への貢献度と記事が読まれる確率という 2 つの特性を反映した指標が有効であるということが示され，提案した 3 つの指標の中では指標 3 (正解ラベル確率上昇度) が最も有効であるということが明らかになった．

今後の課題としては，属性推定モデルの構築，推定の効率化という 2 つの観点から考えられる．

属性推定モデルの構築という観点からは，まず推定精度の向上という課題が挙げられる．本稿で畳み込みニューラルネットワークのモデル構築の際に参考にした Kim[Kim 14] の文献では，学習済み word2vec モデルのパラメタも更新の対象とすることにより推定精度を高められることが示されている．このように，タスクに特化するようにモデルのパラメタを更新するアプローチは性能を向上させることが期待できるため，推定精度を実用的な水準まで向上させるために今後取り組むべき課題であると言える．また，本稿では日経電子版に登録されたユーザに対する属性推定を行ったが，その他のデータセットを用いて本稿で得られた結果の再現性を検証することも課題である．

推定の効率化という観点からも，まずは複数のデータセットを用いた再現性の検証が挙げられる．また，本稿で提案した 3 つの指標はそれぞれ統計情報，モデルによる出力，過去に行われた逐次推定から得られる比較的単純な指標であり，推定モデルの内部構造に依存しない．したがって，異なる推定モデルを用いて本稿と同様の実験を行うことにより，本稿で提案した入力の優先順位の予測方法が汎用的であるかを検証することも課題の一つであると言える．逆に，推定モデルの内部構造を考慮した予測方法によって更に推定の効率を高められる可能性もあるため，その手法を検討することも課題の一つと考えられる．さらに，記事について「ユーザが読んだ際の推定への貢献度」と「ユーザが読む確率」の両方を反映した予測が行えるように，過去の逐次推定から学習する方法をより高度化していくことも課題として挙げられる．

参考文献

[Kim 14] Kim, Y.: Convolutional neural networks for sentence classification, *arXiv preprint arXiv:1408.5882* (2014)

[Kudo 05] Kudo, T.: Mecab: Yet another part-of-speech and morphological analyzer, *http://mecab. sourceforge. net/* (2005)

[Lilleberg 15] Lilleberg, J., Zhu, Y., and Zhang, Y.: Support vector machines and word2vec for text classification with semantic features, in *Cognitive Informatics & Cognitive Computing (ICCI* CC), 2015 IEEE 14th International Conference on*, pp. 136–140IEEE (2015)

[Mikolov 13] Mikolov, T., Chen, K., Corrado, G., and Dean, J.: Efficient Estimation of Word Representations in Vector Space, *CoRR*, Vol. abs/1301.3781, (2013)

[鈴木 16] 鈴木正敏，松田耕史，関根聡，岡崎直観，乾健太郎?FWikipedia 記事に対する拡張固有表現ラベルの多重付与, 言語処理学会第 22 回年次大会 (2016)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

CVR 予測のためのノンパラメトリック Delayed Feedback モデル

吉川 友也 *1　　今井 優作 *2
Yuya Yoshikawa　　Yusaku Imai

*1千葉工業大学 人工知能・ソフトウェア技術研究センター
STAIR Lab, Chiba Institute of Technology

*2株式会社サイバーエージェント
CyberAgent, Inc.

Predicting conversion rates (CVRs) in display advertising (e.g., predicting the proportion of users who purchase an item (i.e., a conversion) after its corresponding ad is clicked) is important when measuring the effects of ads shown to users and to understanding the interests of the users. There is generally a time delay (i.e., so-called *delayed feedback*) between the ad click and conversion. In this paper, we propose a nonparametric delayed feedback model for CVR prediction that represents the distribution of the time delay without assuming a parametric distribution, such as an exponential or Weibull distribution. Because the distribution of the time delay is modeled depending on the content of an ad and the features of a user, various shapes of the distribution can be represented potentially. In an experiment on Criteo dataset, we show that the proposed model outperforms the existing method that assumes an exponential distribution for the time delay in terms of conversion rate prediction.

1. はじめに

インターネット広告業界において，広告がユーザにクリックされた後，その広告に紐づく商品が購入される割合は，コンバージョン率 (CVR) と呼ばれる．CVR の予測は，表示する広告の効果測定やユーザの興味を理解する上で重要になるため，CVR 予測のためのモデルがここ数年よく研究されている [Lee 12, Ji 17].

コンバージョンのログは，図 1 のようなデータベースとして記録される．基本的に，広告のクリックとコンバージョンの間には，時間遅れ (これを *delayed feedback* と呼ぶ) が発生する．その結果，観測期間の終了までにコンバージョンが起きなかったサンプルのコンバージョン時刻は，‘unobserved’ とデータベース上に記録される．そして，コンバージョンの時間遅れは数時間から数日に及ぶため，そのようなサンプルの割合は比較的多いことが知られている [Chapelle 14b].

コンバージョン時刻が ‘unobserved’ と記録されたサンプルを全て負例として扱えば，ロジスティック回帰やニューラルネットワーク等を用いて CVR 予測モデルを学習できる．しかし，これらのサンプルの一部が最終的にコンバージョンする場合，その CVR 予測モデルは誤ったラベルを用いて学習されることになり，結果として精度の低い CVR 予測結果となり得る．したがって，delayed feedback を考慮して，‘unobserved’ となっているサンプルの正負を推定しながら CVR 予測モデルを構築することが不可欠である．

このような背景から，Chapelle は delayed feedback による時間遅れが指数分布に従うことを仮定した CVR 予測モデルを提案した [Chapelle 14a]．しかし，[Chapelle 14a] の図 5 で示される通り，時間遅れの実際の分布は指数分布ではなかったり周期的であったりし，サンプルによって分布の形は多様である．したがって，時間遅れに対しては，指数分布やワイブル分布のような決まった形の分布を仮定するのではなく，データに適切な分布を推定できるようにすることが望ましい．

そこで本論文では，時間遅れの分布に対してパラメトリックな分布を仮定しない CVR 予測のためのノンパラメトリック delayed feedback モデル（以下，NoDeF）を提案する．NoDeF は，時間遅れの分布を表現するために，カーネル密度推定のアイディアを一部参考にしている．より具体的には，時間遅れの分布をコンバージョン時刻と時間軸上の疑似点のカーネルの重み付き和で表現する．ここで，重みはデータから学習されるものである．その上で，NoDeF は各サンプルが最終的にコンバージョンするかどうかを表す潜在変数を持ち，これがコンバージョン時刻が ‘unobserved’ となったサンプルの正負を推定する役割を果たす．NoDeF のパラメータ推定は EM アルゴリズムに基づいて行う．

実験では，Criteo データセットを用いて，NoDeF が未知のサンプルの CVR を正しく予測できることを示す．

ID	Click date	Conversion date	Ad feature 1	...	User feature 1	...
1	2018/01/04 10:12:15	2018/01/12 16:30:02	0.1	...	10.3	...
2	2018/01/05 08:42:33	unobserved	0.3	...	8.4	...
...	...	...	...	...	...	...
n	2018/03/30 22:50:11	unobserved	0.8	...	12.2	...

図 1: コンバージョンログデータベースの一例．各行が 1 つのサンプルに対応し，クリック時刻 (click date), コンバージョン時刻 (conversion date), 特徴量 (ad features, user features) から成る．もしコンバージョンがその時点までに起きていない場合は，そのサンプルのコンバージョン時刻は ‘unobserved’ と記録される．

1.1 関連研究

NoDeF は，[Chapelle 14a] で提案された delayed feedback モデルの拡張である．[Chapelle 14a] のモデルは，時間遅れの分布がサンプルの特徴量によって決定されるパラメータを持つ指数分布に従うと仮定する．その後，[Ji 17] は時間遅れの分布として混合ワイブル分布を用いたり，[Safari 17] はワイブル分布を時間遅れの分布とした場合の効率的なモデルの学習法を構築したりしている．我々が知る限り，本論文の研究は，CVR 予測モデルにおける時間遅れの分布をノンパラメトリックに表現する最初の研究である．

連絡先: 吉川 友也，千葉工業大学 人工知能・ソフトウェア技術研究センター， yoshikawa@stair.center

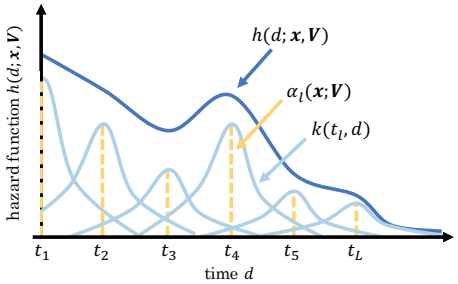


図 2: NoDeF におけるハザード関数 h，重み関数 α_l，カーネル k の関係．黄色の点線は各時刻 t_l における $\alpha_l(\boldsymbol{x};\boldsymbol{V})$ を示し，薄青色の実線は各時刻 t_l における $k(t_l,d)$ を示す．また，紺青色の実線はハザード関数 $h(d;\boldsymbol{x},\boldsymbol{V})$ の値を示す．

2. 事前準備: 生存時間分析

本節では，NoDeF を説明するために必要な生存時間分析を簡単に紹介する．生存時間分析は本来，生物の死や機械の故障といったイベントが起こるまでの時間を分析するために用いられている [Kleinbaum 12].

イベントが起こった時刻を表す確率変数 T が与えられたとき，$f(t) = Pr[T = t]$ は T の確率密度関数，$F(t) = \int_0^t f(x)dx$ は $f(t)$ の累積分布関数としてそれぞれ定義する．あるイベントが時刻 t まで起こらない確率は，生存時間関数 $s(t) = 1 - F(t)$ で与えられる．また，あるイベントが時刻 t まで起こらず，時刻 t になったとき起きるイベント発生率は，ハザード関数 $h(t)$ として定義される．$h(t), f(t), s(t)$ の関係は以下のとおりである．

$$h(t) = \frac{f(t)}{s(t)}. \tag{1}$$

さらに，生存時間関数 $s(t)$ はハザード関数 $h(t)$ を用いて導出でき，

$$s(t) = \exp\left(-\int_0^t h(x)dx\right), \tag{2}$$

となる．

3. 提案法

本節では，NoDeF の定式化，パラメータ推定法，CVR の予測法について説明する．

観測データとして，n 個の 4 つ組の集合 $\mathcal{D} = \{(\boldsymbol{x}_i, y_i, d_i, e_i)\}_{i=1}^n$ が与えられるとする．具体的には，$\boldsymbol{x}_i \in \mathbb{R}^M$ は i 番目のサンプルを表す特徴ベクトル，$y_i \in \{0,1\}$ は i 番目のサンプルがコンバージョンしたかどうかを表す二値変数，$d_i \in [0,\infty]$ は i 番目のサンプルにおけるクリックとコンバージョンの間の時間遅れを表す．ここで，コンバージョンが起きていない場合は，$d_i = \infty$ となる．$e_i \in [0,\infty)$ は，i 番目のサンプルにおけるクリックからの経過時間を表す．

3.1 Model

NoDeF は，時間遅れモデルとコンバージョンモデルから構成される．時間遅れモデルはクリックとコンバージョンの間の時間遅れを捉えるためのモデルであり，コンバージョンモデルは新しいサンプルが与えられたときに CVR を予測するためのモデルである．

NoDeF では，時間遅れモデルを 2. 節で説明した生存時間分析の枠組みに基づいて定義する．時間遅れの分布は，表示される広告の内容やその広告を見るユーザの特徴により変化すべきである．したがって，NoDeF の時間遅れモデルにおいては，時間遅れの分布に対して指数分布やワイブル分布を仮定せず，また，分布の形が広告やユーザの特徴によって決定づけられるように定義する．

まず，NoDeF におけるハザード関数を説明する．ハザード関数を定義するために，NoDeF は $L \in \mathbb{N}_+$ 個の疑似点 $\{t_l \geq 0\}_{l=1}^L$ を時間軸上に等間隔に配置する．その上で，ハザード関数，すなわち，i 番目のサンプルのコンバージョンが時間遅れ d_i まで起きず，d_i のその瞬間に起きる割合を，以下のように定義する．

$$h(d_i;\boldsymbol{x}_i,\boldsymbol{V}) = \sum_{l=1}^{L} \alpha_l(\boldsymbol{x}_i;\boldsymbol{V})k(t_l,d_i), \tag{3}$$

ここで，k はカーネル関数を表す．直感的には，カーネル関数の値は時間軸上の 2 点の類似度を表現する．NoDeF で使用できるカーネル関数は，$t_l, \tau, a \geq 0$ に対して，$k(t_l,\tau)$, $\int_0^a k(t_l,\tau)d\tau$, $\int_a^\infty k(t_l,\tau)d\tau$ が解析的に計算できる必要がある．例えば，バンド幅 $h > 0$ のガウスカーネルは NoDeF で使用可能である．この場合は，上記 3 つの値は以下の式で得られる．

$$k(t_l,\tau) = \exp\left(-\frac{(t_l-\tau)^2}{2h^2}\right), \tag{4}$$

$$\int_0^a k(t_l,\tau)d\tau = -h\sqrt{\frac{\pi}{2}}\left[\mathrm{erf}\left(\frac{t_l-a}{\sqrt{2}h}\right) - \mathrm{erf}\left(\frac{t_l}{\sqrt{2}h}\right)\right] \tag{5}$$

$$\int_a^\infty k(t_l,\tau)d\tau = h\sqrt{\frac{\pi}{2}}\left[1 + \mathrm{erf}\left(\frac{t_l-a}{\sqrt{2}h}\right)\right]. \tag{6}$$

α_l はパラメータ $\boldsymbol{V} \in \mathbb{R}^{L\times M}$ を持つ重み関数で，時間軸上の l 番目の疑似点 t_l に対するカーネル関数の値を調整するものである．NoDeF では，α_l を以下のように定義する．

$$\alpha_l(\boldsymbol{x}_i;\boldsymbol{V}) = \left(1 + \exp\left(-\boldsymbol{V}_l^\top \boldsymbol{x}_i\right)\right)^{-1}. \tag{7}$$

図 2 は，(3) におけるハザード関数 h，重み関数 α_l，カーネル関数 k の関係を示す．

生存時間関数 (2) の定義と (3) に基づくと，NoDeF における生存時間関数は以下のようになる．

$$s(d_i;\boldsymbol{x}_i,\boldsymbol{V}) = \exp\left(-\sum_{l=1}^{L}\alpha_l(\boldsymbol{x}_i;\boldsymbol{V})\int_0^{d_i} k(t_l,\tau)d\tau\right). \tag{8}$$

次に，[Chapelle 14a] と同様に，コンバージョンまでの経過時間によらず i 番目のサンプルがコンバージョンするかどうかを表す潜在変数 $c_i \in \{0,1\}$ を考える．もし，$y_i = 1$，すなわち，i 番目のサンプルがコンバージョンしたと記録されていれば，明らかに $c_i = 1$ となる．その一方で，$y_i = 0$，すなわち，i 番目のサンプルが経過時間 e_i までにコンバージョンしなかった場合，c_i は決定することができない．したがって，$y_i = 0$ となるサンプルに対しては，c_i の割り当てを推定する必要がある．

i 番目のサンプルにおいて時間遅れ d_i でコンバージョンが起こる確率を定義する．ハザード関数 (3) と生存時間関数 (8) に基づくと，上記の確率は以下のように計算できる．

$$p(d_i|\boldsymbol{x}_i, c_i = 1) = s(d_i;\boldsymbol{x}_i,\boldsymbol{V})h(d_i;\boldsymbol{x}_i,\boldsymbol{V}). \tag{9}$$

コンバージョンモデルに関しては，尤度が微分可能な二値分類器（例えば，ロジスティック回帰や多層パーセプトロン）を用いることが可能である．本論文では，簡単のため，以下のロジスティック回帰を用いる．

$$p(c_i = 1|\boldsymbol{x}_i;\boldsymbol{w}) = \left(1 + \exp(-\boldsymbol{w}^\top \boldsymbol{x}_i)\right)^{-1}, \tag{10}$$

$$p(c_i = 0|\boldsymbol{x}_i;\boldsymbol{w}) = 1 - p(c_i = 1|\boldsymbol{x}_i), \tag{11}$$

ここで，$\boldsymbol{w} \in \mathbb{R}^M$ はコンバージョン分類器の重みベクトルである．

次に，NoDeF の尤度を定義する．簡便のため，以下の 2 つの集合を定義する．

$$\mathcal{I}_1 = \{i | y_i = 1, i = 1, 2, \cdots, n\}, \quad \mathcal{I}_0 = \{i | y_i = 0, i = 1, 2, \cdots, n\}.$$

パラメータ $\Theta = \{\boldsymbol{V}, \boldsymbol{w}\}$ が与えられたとき，観測データ $\mathcal{D} = \{(\boldsymbol{x}_i, y_i, d_i, e_i)\}_{i=1}^n$ の尤度は以下のように分解できる．

$$p(\mathcal{D}; \Theta) = \prod_{i=1}^{n} \sum_{c_i \in \{0,1\}} p(y_i | \boldsymbol{x}_i, c_i, e_i) p(c_i | \boldsymbol{x}_i) p(d_i | \boldsymbol{x}_i, c_i = 1), \tag{12}$$

ここで，$c_i = 0$ の場合は必ず $y_i = 0$ となるため，以下の等式は常に成り立つことが分かる．

$$p(y_i = 0 | \boldsymbol{x}_i, c_i = 0, e_i) = 1, \tag{13}$$

$$p(y_i = 1 | \boldsymbol{x}_i, c_i = 0, e_i) = 0. \tag{14}$$

したがって，(13) と (14) を尤度 (12) に代入し，サンプル集合を $\mathcal{I}_1$ と $\mathcal{I}_0$ に分割することにより，尤度は以下のように変形できる．

$$\begin{aligned} p(\mathcal{D}; \Theta) &= \prod_{i \in \mathcal{I}_1} p(c_i = 1 | \boldsymbol{x}_i) p(d_i | y_i = 1, \boldsymbol{x}_i) \\ &\times \prod_{i \in \mathcal{I}_0} \sum_{c_i \in \{0,1\}} p(y_i = 0 | \boldsymbol{x}_i, c_i, e_i) p(c_i | \boldsymbol{x}_i). \end{aligned} \tag{15}$$

$p(y_i = 0 | \boldsymbol{x}_i, c_i = 1, e_i)$ は，i 番目のサンプルが経過時間 e_i までにコンバージョンが起きず，その後にコンバージョンが起きる確率であり，この確率は以下のように計算できる．

$$p(y_i = 0 | \boldsymbol{x}_i, c_i = 1, e_i) \tag{16}$$

$$= p(d_i > e_i | \boldsymbol{x}_i, c_i = 1, e_i) \tag{17}$$

$$= 1 - \int_0^{e_i} p(d_i = \tau | c_i = 1, \boldsymbol{x}_i) d\tau \tag{18}$$

$$= s(e_i; \boldsymbol{x}_i, \boldsymbol{V}), \tag{19}$$

ここで，(18) から (19) への式変形は，2. 節で説明した $s(t) = 1 - F(t)$ という関係式を適用することで得られる．

3.2 パラメータ推定法

本節では，EM アルゴリズムに基づく NoDeF のパラメータ学習法を説明する．

まず，EM アルゴリズムにおける標準的なやり方で目的関数を定義する．イエンセンの不等式より，対数尤度の下限 $Q(\Theta; \bar{\Theta})$ は以下のように導出できる．

$$\begin{aligned} \log p(\mathcal{D}; \Theta) &\geq Q(\Theta; \bar{\Theta}) \\ &= \sum_{i \in \mathcal{I}_1} \log \Big[p(c_i = 1 | \boldsymbol{x}_i) p(d_i | \boldsymbol{x}_i, c_i = 1) \Big] \\ &+ \sum_{i \in \mathcal{I}_0} \sum_{c_i \in \{0,1\}} \bar{q}_{ic_i} \log \Big[p(y_i | \boldsymbol{x}_i, c_i, e_i) p(c_i | \boldsymbol{x}_i) \Big], \end{aligned} \tag{20}$$

ここで，$\bar{q}_{ic_i}$ は c_i の事後分布で，以下のように定義される．

$$\bar{q}_{ic} \propto p(y_i = 0 | \boldsymbol{x}_i, c_i = c, e_i) p(c_i = c | \boldsymbol{x}_i). \tag{21}$$

もし $c = 0$ ならば，$p(y_i = 0 | \boldsymbol{x}_i, c_i = c, e_i)$ は必ず 1 となる．したがって，

$$\bar{q}_{i0} = p(c_i = 0 | \boldsymbol{x}_i, y_i = 0, d_i, e_i) \propto p(c_i = 0 | \boldsymbol{x}_i), \tag{22}$$

となり，これは，(11) を用いて計算可能である．その一方で，$c = 1$ の場合は，c_i の事後分布は以下のように計算できる．

$$\bar{q}_{i1} \propto p(c_i = 1 | \boldsymbol{x}_i) p(y_i = 0 | \boldsymbol{x}_i, c_i = 1, e_i), \tag{23}$$

ここで，$p(c_i = 1 | \boldsymbol{x}_i)$ と $p(y_i = 0 | \boldsymbol{x}_i, c_i = 1, e_i)$ は，それぞれ (10) と (16) を用いて計算できる．ここで，(22) と (23) により得られた $\bar{q}_{ic}$ は，$\bar{q}_{ic} = \bar{q}_{ic} / (\bar{q}_{i0} + \bar{q}_{i1})$ と正規化する必要があることに注意する．E ステップは，パラメータ Θ の現在の推定値の下で，c_i の事後分布を更新することである．

M ステップでは，c_i の事後分布を固定して，パラメータ Θ を勾配に基づく最適化手法を用いて更新する．本論文では，準ニュートン法における効率的な手法である L-BFGS を使用する．ここで，目的関数 (20) に $\boldsymbol{w}$ と $\boldsymbol{V}$ に対する ℓ_2 正則化項を追加する．正則化の強さは，$\lambda_{\boldsymbol{w}}, \lambda_{\boldsymbol{V}} \geq 0$ の値の大きさで調節する．この正則化は，平均 0，精度 $\lambda_{\boldsymbol{w}}, \lambda_{\boldsymbol{V}}$ のガウス事前分布をパラメータに対して置くことと等価である．

まず，$\boldsymbol{w}$ の勾配は，以下のように計算できる．

$$\begin{aligned} \frac{\partial Q(\Theta; \bar{\Theta})}{\partial \boldsymbol{w}} &= \sum_{i \in \mathcal{I}_1} \frac{\partial}{\partial \boldsymbol{w}} \log p(c_i = 1 | \boldsymbol{x}_i) \\ &+ \sum_{i \in \mathcal{I}_0} \sum_{c_i \in \{0,1\}} \bar{q}_{ic} \frac{\partial}{\partial \boldsymbol{w}} \log p(c_i | \boldsymbol{x}_i) - \lambda_{\boldsymbol{w}} \boldsymbol{w}, \end{aligned} \tag{24}$$

ここで，

$$\frac{\partial}{\partial \boldsymbol{w}} \log p(c_i = 1 | \boldsymbol{x}_i) = \boldsymbol{x} \left(1 - p(c_i = 1 | \boldsymbol{x}_i)\right), \tag{25}$$

$$\frac{\partial}{\partial \boldsymbol{w}} \log p(c_i = 0 | \boldsymbol{x}_i) = -\boldsymbol{x} p(c_i = 1 | \boldsymbol{x}_i), \tag{26}$$

である．次に，$\boldsymbol{V}_l$ の勾配は以下のように計算できる．

$$\begin{aligned} \frac{\partial Q(\Theta; \bar{\Theta})}{\partial \boldsymbol{V}_l} &= \sum_{i \in \mathcal{I}_1} \frac{\partial}{\partial \boldsymbol{V}_l} \log p(d_i | \boldsymbol{x}_i, c_i = 1) \\ &+ \sum_{i \in \mathcal{I}_0} \sum_{c_i \in \{0,1\}} \bar{q}_{ic} \frac{\partial}{\partial \boldsymbol{V}_l} \log p(y_i = 0 | \boldsymbol{x}_i, c_i, e_i) - \lambda_{\boldsymbol{V}} \boldsymbol{V}_l, \end{aligned} \tag{27}$$

ここで，

$$\frac{\partial}{\partial \boldsymbol{V}_l} \log p(d_i | \boldsymbol{x}_i, c_i = 1) = \frac{\partial}{\partial \boldsymbol{V}_l} \log s(d_i; \boldsymbol{x}_i, \boldsymbol{V}) + \frac{\partial}{\partial \boldsymbol{V}_l} \log h(d_i; \boldsymbol{x}_i, \boldsymbol{V}), \tag{28}$$

$$\frac{\partial}{\partial \boldsymbol{V}_l} \log p(y_i = 0 | \boldsymbol{x}_i, c_i = 1, e_i) = \frac{\partial}{\partial \boldsymbol{V}_l} \log s(e_i; \boldsymbol{x}_i, \boldsymbol{V}), \tag{29}$$

$$\frac{\partial}{\partial \boldsymbol{V}_l} \log s(d_i; \boldsymbol{x}_i, \boldsymbol{V}) = -\boldsymbol{x}_i \alpha_l(\boldsymbol{x}; \boldsymbol{V})(1 - \alpha_l(\boldsymbol{x}; \boldsymbol{V})) \int_0^{d_i} k(t_l, \tau) d\tau, \tag{30}$$

$$\frac{\partial}{\partial \boldsymbol{V}_l} \log h(d_i; \boldsymbol{x}_i, \boldsymbol{V}) = \frac{\boldsymbol{x}_i \alpha_l(\boldsymbol{x}; \boldsymbol{V})(1 - \alpha_l(\boldsymbol{x}; \boldsymbol{V})) k(t_l, d_i)}{h(d_i; \boldsymbol{x}_i, \boldsymbol{V})}, \tag{31}$$

である．

EM アルゴリズムでは，目的関数 (20) の値が収束するまで，E ステップと M ステップを交互に繰り返し行いながらパラメータ Θ を推定する．

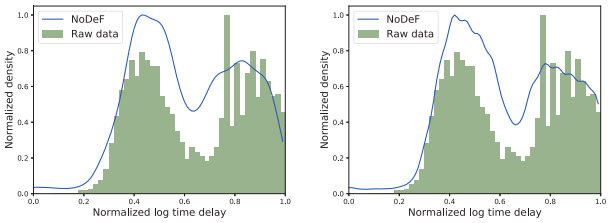
超パラメータの設定. NoDeF では，疑似点の数 L，ガウスカーネルのバンド幅 h，精度パラメータ $\lambda_{\boldsymbol{w}}, \lambda_{\boldsymbol{V}}$ が超パラメータである．これらの超パラメータは交差検定法や開発用セットを用いて決定することができる．h を決定する別の方法として，等間隔に配置された隣接する二つの疑似点の間の長さを利用する方法がある．時間遅れの分布を滑らかな関数として推定するためには，$h = (t_{i+1} - t_i)/2$ として h を決定することを推奨する．この方法は，4. 節の実験で一貫して用いる．

3.3 CVR の予測

NoDeF では，新たなサンプルが指定した時刻までにコンバージョンするかどうかの予測が可能である．これは，以下の式を用いて，サンプル $\boldsymbol{x}$ が時刻 $E \geq 0$ までにコンバージョンする

表 1: Criteo データセットにおける直近キャンペーンに対する予測性能．太字は各指標において最も良いスコアを示す．

	Log loss	Accuracy	AUC
NAIVE	0.2818 ± 0.021	0.9124 ± 0.013	0.7187 ± 0.019
DFM	0.3689 ± 0.051	0.9151 ± 0.012	0.7213 ± 0.022
NoDeF	$\mathbf{0.2575} \pm 0.020$	$\mathbf{0.9157} \pm 0.012$	$\mathbf{0.7242} \pm 0.025$



(a) $L = 10$ (b) $L = 20$

図 3: 異なる L を設定した NoDeF における推定された時間遅れの分布．その他の超パラメータは，$\lambda_{\boldsymbol{w}} = 0.1$，$\lambda_{\boldsymbol{V}} = 0.1$ と設定した．

確率を求めることで可能である．

$$\begin{aligned} p(y=1|\boldsymbol{x}, c=1, E) &= p(c=1|\boldsymbol{x})p(d<E|c=1,\boldsymbol{x}) \\ &= p(c=1|\boldsymbol{x})\int_0^E p(t|c=1,\boldsymbol{x})dt \\ &= p(c=1|\boldsymbol{x})\left(1-s(E;\boldsymbol{x},\boldsymbol{V})\right) \end{aligned} \quad (32)$$

4. 実験

この節では，[Chapelle 14a] で使用されているコンバージョンログデータセットの Criteo データセットを用いて，NoDeF の予測性能を示す．

実験では，[Chapelle 14a] と同様に，直近のキャンペーンに関するコンバージョンログのみから構成されるデータセットを用いる．まず，このデータセットから，6 つの期間のコンバージョンログを抽出する．その上で，各期間において，サンプル集合を訓練用，開発用，テスト用に分割する．訓練用セットはその期間の最初の 3 日間にクリックされた 50,000 サンプルであり，その 3 日間を超えてコンバージョンが起こったサンプルのコンバージョン時刻は ‘unobserved’ とする．開発用セットは，その期間の 4 日目から 5 日目にクリックされた 10,000 サンプルから構成され，それ以降にコンバージョンが起きたサンプルは負例として扱う．テスト用セットは，その期間の 5 日目から 6 日目にクリックされた 10,000 サンプルから構成され，それ以降にコンバージョンが起きたサンプルは負例として扱う．

各サンプルには，8 種類の整数値特徴と 9 種類のカテゴリカル特徴がある．カテゴリカル特徴量については，one-hot 表現に変換し，整数値特徴と連結して使用する．この処理により作成される特徴ベクトルは 2,594 次元であるが，主成分分析を用いて 100 次元に次元圧縮して実験で用いる．

NoDeF では，各サンプルの遅れ時間や経過時間は，対数変換した後で正規化して用いる．NoDeF の超パラメータは，$L \in \{10, 20, 30\}, \lambda_{\boldsymbol{w}} \in \{1.0, 0.1, 0.01\}, \lambda_{\boldsymbol{V}} \in \{1.0, 0.1, 0.01\}$ の範囲でグリッドサーチを行い，開発用セットで最適な組み合わせを求める．また，ガウスカーネルのバンド幅 h は，3.2 節の最後で説明した方法を用いて決定する．

比較のために，[Chapelle 14a] で用いられている DFM と NAIVE を用いる．DFM は [Chapelle 14a] の提案手法で，時間遅れに対して指数分布を仮定して delayed feedback を考慮するモデルである．NAIVE はベースライン手法で，コンバージョン時刻が ‘unobserved’ となっているサンプルを全て負例として扱って学習したロジスティック回帰モデル [*1] である．DFM と NAIVE の超パラメータは，開発用セットを用いて決定する．DFM については，遅れ時間と経過時間を訓練用セットで観測した遅れ時間の最大値で正規化して用いる．

表 1 は，上記の Criteo データセットにおける予測性能を示す．この表から，全ての指標において，NoDeF は NAIVE と DFM よりも優れた性能を示すことが分かる．

図 3 は，異なる L を設定した NoDeF で推定された時間遅れの分布である．図を見ると，NoDeF は分布に関する事前知識無しで，実際のデータに現れる 2 つのピークを捉えられていることが分かる．その上で，異なる L を設定した場合でも，推定された分布は滑らかであることが見て取れるため，h の自動決定が有効であることが示唆される．

5. おわりに

本論文では，インターネット広告におけるコンバージョン率 (CVR) 予測のために，ノンパラメトリック delayed feedback モデル (NoDeF) を提案した．既存の delayed feedback モデルとは異なり，NoDeF は広告クリックからコンバージョンまでの時間遅れの分布をノンパラメトリックに推定可能である．実験では，Criteo データセットを用いて，NoDeF が既存手法と比較して優れた CVR 予測が可能であることを示した．

参考文献

[Chapelle 14a] Chapelle, O.: Modeling Delayed Feedback in Display Advertising, *Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 1097–1105 (2014)

[Chapelle 14b] Chapelle, O., Manavoglu, E., and Rosales, R.: Simple and Scalable Response Prediction for Display Advertising, *ACM Transactions on Intelligent Systems and Technology*, Vol. 5, No. 4, p. Article 61 (2014)

[Ji 17] Ji, W., Wang, X., and Zhu, F.: Time-Aware Conversion Prediction, *Frontiers of Computer Science*, Vol. 11, No. 4, pp. 702–716 (2017)

[Kleinbaum 12] Kleinbaum, D. G. and Klein, M.: *Survival Analysis*, Statistics for Biology and Health, Springer New York, New York, NY (2012)

[Lee 12] Lee, K.-c., Orten, B., Dasdan, A., and Li, W.: Estimating Conversion Rate in Display Advertising from Past Erformance Data, in *Proceedings of the 18th ACM SIGKDD International Conference on Knowledge Discovery and Data Miningg*, p. 768, New York, New York, USA (2012), ACM Press

[Safari 17] Safari, A., Altman, R. M., and Loughin, T. M.: Display Advertising: Estimating Conversion Probability Efficiently, *arXiv preprint* (2017)

∗1 ロジスティック回帰の実装は Scikit-learn 0.19.0 を用いた．

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

スタイルの類似性を捉えた単語ベクトルの教師なし学習

Learning Style-sensitive Word Vector via Unsupervised-manner

赤間怜奈 *1 Reina Akama　渡邉研斗 *1 Kento Watanabe　横井祥 *1*2 Sho Yokoi　小林颯介 *3 Sosuke Kobayashi　乾健太郎 *1*2 Kentaro Inui

*1東北大学 大学院情報科学研究科 Graduate School of Information Sciences, Tohoku University
*2理研 AIP RIKEN AIP
*3株式会社 Preferred Networks Preferred Networks, Inc.

This paper is the first study aiming at capturing stylistic similarity in an unsupervised manner. We construct a novel style-sensitive word vector predicting the target word for giving nearby and wider contexts under the assumption that the style of all the words in an utterance is consistent. We also introduce an evaluation dataset with human judgments on the stylistic similarity between word pairs. Experimental results illustrate capturing the stylistic similarity significantly.

1. はじめに

自然言語において，**何を伝えるか（意味）**だけに限らず，**どう表現するか（スタイル）**の側面も考慮することは重要であり，ことばのスタイルをモデル化することは，文書分類や文生成などの自然言語処理に有用である [1, 2, 3].

このような背景のため，近年では，スタイルのある側面に部分的な定義（たとえば，性別や敬意表現など）を与えることで，スタイルをモデル化する研究が盛んに行われている [4, 5, 6, 7, 8]. しかし，スタイルは極めて主観的な性質を持つため，スタイルそのものを明確に定義することは難しい [9]. そのため，定義されたスタイル-ラベルの分類問題などの教師ありタスクに定式化することは困難かつ不適切である.

本研究の貢献を以下に示す：(1) スタイルを定義せずに，スタイルの類似性を捉えた単語ベクトル空間を教師なし学習する. ここで我々が期待する単語ベクトル空間とは，(「意味」は近くとも)「スタイル」が大きく異なる “俺” と “私” は遠くに配置され，(「意味」は異なっているとしても)「スタイル」が似ている “俺” と “だぜ” が近くに配置されるような空間である（図 1 左）. (2) スタイルの類似性を包括的に定量評価する新しい手法を提案し，そのための評価用データセットを作成する. 本研究はスタイルの類似性を定量的に評価するための評価データセットを作成した最初の研究である. (3) 提案手法により獲得した単語ベクトルが，スタイルの類似性を捉えていることを定量的および定性的に示す.

2. スタイルの類似性を捉えた単語ベクトル

2.1 本論文で用いる記号の定義

本論文では，発話を単語列 w_1,w_2,...w_I として表す. ここで I は発話に含まれる単語数である. たとえば w_i は発話内の i 番目の単語を表す. とくに注目するターゲット単語を w_t と表し，w_{t+1} はターゲット単語の次の単語を表す. また，$\boldsymbol{v}_w$ と $\tilde{\boldsymbol{v}}_w$ はそれぞれターゲット単語ベクトルと文脈単語ベクトルを表す. ターゲット単語と文脈単語との距離を d，文脈窓のサイズを δ とする.

連絡先: 東北大学 大学院情報科学研究科
〒980-8579 宮城県仙台市青葉区荒巻字青葉 6-6-05
E-mail: reina.a@ecei.tohoku.ac.jp

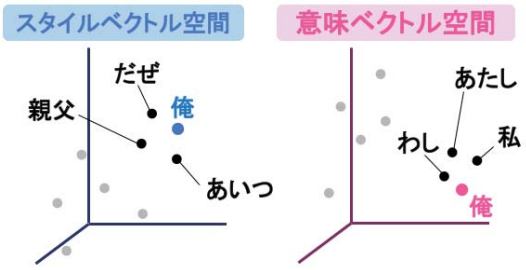


図 1　一般的な単語ベクトル空間（右）では，意味的に類似した単語が近い空間に配置される. 一方で，本研究で期待するスタイルを捉えたベクトル空間（左）とは，たとえば（意味は異なるとしても）スタイルが類似する “俺” と “だぜ” が近くに配置され，(意味は近くとも) スタイルが大きく異なる “俺” と “私” が遠くに配置されるような空間である.

2.2 ベースラインモデル

まず，Mikolov らが提案した Countinuous Bag-of-Words (CBOW) [10] の概要を説明する. 彼らが「vector representations that capture a large number of precise *syntactic* and *semantic* word relationships」と述べているように [11], CBOW は単語の統語情報および語義情報等の「意味」の類似性を捉えた単語ベクトルを学習する確率モデルである. CBOW では，近傍の文脈単語集合 $C_{w_t}^{near} = \{w_{t\pm d} | \ 1 \leq d \leq \delta\}$ (δ は文脈窓幅である) を入力とした時のターゲット単語 w_t の予測確率を最大化することにより，単語ベクトル $\boldsymbol{v}_{w_t}$ を学習する：

$$P(w_t|C_{w_t}^{near}) \propto \exp(\boldsymbol{v}_{w_t} \cdot \tilde{\boldsymbol{v}}_{C_t^{near}}), \qquad (1)$$

ここで，$\tilde{\boldsymbol{v}}_{C_t^{near}} := \frac{1}{|C_{w_t}^{near}|} \sum_{w \in C_{w_t}^{near}} \tilde{\boldsymbol{v}}_w$ は，全文脈単語ベクトルの平均ベクトルを表す. 本研究では，この CBOW をベースラインモデル *CBOW-near-ctx* と呼ぶ.

2.3 提案モデル 1：発話内のスタイル一貫性に基づくモデリング

本研究では，単語のスタイルの類似性を捉えた単語ベクトルを学習したい. しかし，*CBOW-near-ctx* のように近傍の文脈単語集合からターゲット単語を予測するだけでは，単語の「意味」の類似性を捉えた単語ベクトルを学習できても，スタイルの類似性を捉えた単語ベクトルは学習できないと考えられる. スタイルの類似性を捉えるための手がかりとして，性別属性 [12]

や人物情報 [13] などが有用と考えられるが，同じ「女性」という属性であっても，全ての女性が必ずしも同一のスタイルで発話するとは考えにくい．さらに，同一人物であっても，話し相手や状況に応じて複数のスタイルを使い分けることは珍しくない．したがって，性別情報や人物情報ではスタイルの類似性を捉えることは難しいと考えられる．

そこで本研究では，性別属性や人物情報を使わずにスタイルの類似性を捉える手がかりとして，「属性や人物情報に関わらず，ある 1 つの発話内の全単語のスタイルは一貫している」という直観的な仮定をたてた．この仮定に基づき，発話内の全ての文脈単語 $C_{w_t}^{all} = \{w_{t\pm d} | \ 1 \leq d \leq I\}$ からターゲット単語を予測するモデル *CBOW-all-ctx* を学習することで，スタイルの類似性を捉えた単語ベクトルを構築する．これは，ベースライン *CBOW-near-ctx* の文脈窓幅 δ を発話長 I に拡張することに等しい．この拡張モデルでは，意味の類似性に加えてスタイルの類似性も捉えた単語ベクトルが学習されると期待される．

2.4 提案モデル 2：スタイル情報と意味情報の分離

前節では意味の類似性とスタイルの類似性を捉えるモデル *CBOW-all-ctx* を提案した．本研究では *CBOW-all-ctx* を拡張して，純粋にスタイルの類似性のみを捉えた単語ベクトルの獲得を試みる．

2.2 節では，近傍の文脈単語からターゲット単語を予測することで，意味の類似性を捉えた単語ベクトルが学習可能であると述べた．したがって，近傍の文脈単語を無視すれば，意味の類似性を捉えない単語ベクトルが学習されると考えられる．そこで，スタイルの類似性のみを捉えるシンプルな工夫として，*CBOW-all-ctx* の学習に用いた文脈語から，近傍 $C_{w_t}^{near} = \{w_{t\pm d} | \ 1 \leq d \leq \delta\}$ を除外する．この工夫により，スタイル情報だけを捉えた単語ベクトルが学習されると期待される．このモデルを *CBOW-dist-ctx* と呼ぶ．

さらに本研究では，単語ベクトル $\boldsymbol{v_t}$ を (1) スタイルの類似性のみを捉える単語ベクトル $\boldsymbol{x_t}$ と (2) 意味の類似性のみを捉える単語ベクトル $\boldsymbol{y_t}$ に分離しながら同時に学習する拡張モデル *CBOW-sep-ctx* を提案する（図 2）：

$$\boldsymbol{v}_{w_t} = \boldsymbol{x}_{w_t} \oplus \boldsymbol{y}_{w_t} \tag{2}$$

$$\tilde{\boldsymbol{v}}_c = \tilde{\boldsymbol{x}}_c \oplus \tilde{\boldsymbol{y}}_c \tag{3}$$

ここで，$\oplus$ はベクトルの連結を表す．また，$\boldsymbol{x_t}$ をスタイルベクトル，$\boldsymbol{y_t}$ を意味ベクトルと呼ぶ．単語ベクトル $\boldsymbol{v_t}$ と同様に，文脈単語ベクトル $\tilde{\boldsymbol{v}}_c$ もスタイルベクトルと意味ベクトルに対応するベクトル $\tilde{\boldsymbol{x}}_c$，$\tilde{\boldsymbol{y}}_c$ に分割される．

本研究では，スタイルの類似性と意味の類似性を明示的に分離して学習するために，ターゲット単語から文脈単語までの距離に応じてパラメータを更新するベクトルを切り替える．具体的には，ターゲット単語の近傍の文脈単語集合 $C_{w_t}^{near}$ からは意味の類似性とスタイルの類似性の両方を捉えることができると考えられるため，スタイルベクトル $\boldsymbol{x}_{w_t}$ と意味ベクトル $\boldsymbol{y}_{w_t}$ の両方のパラメータを更新する．また，ターゲット単語から一定の距離 δ 以上離れている文脈単語集合 $C_{w_t}^{dist}$ からはスタイルの類似性のみを捉えることができると考えられるため，スタイルベクトル $\boldsymbol{x}_{w_t}$ のパラメータのみを更新する．以上の更新手順をまとめると，予測確率 $P(w_t|C_{w_t})$ は以下のように定式化できる：

$$P(w_t|C_{w_t}) \propto \begin{cases} \exp(\boldsymbol{v}_{w_t} \cdot \tilde{\boldsymbol{v}}_{C_{w_t}^{near}}) \ (1 < d \leq \delta) \\ \exp(\boldsymbol{x}_{w_t} \cdot \tilde{\boldsymbol{x}}_{C_{w_t}^{dist}}) \ (\delta < d \leq I) \end{cases} \tag{4}$$

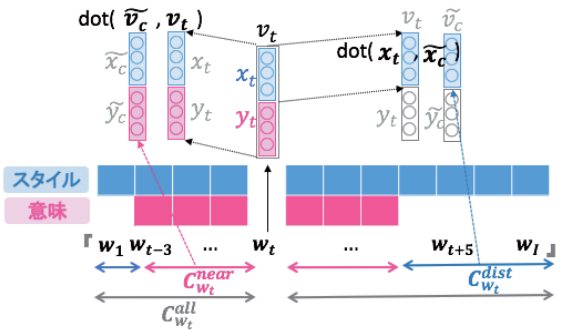


図 2　*CBOW-sep-ctx* の概念図．ターゲット単語の近傍で共起する単語（$C_{w_t}^{near}$）はスタイル（青）および意味（赤）の両方の類似性に有効かつ発話内で共起する単語（$C_{w_t}^{all}$）はスタイルの類似性に有効という考えに基づく．

3. 実験

提案した単語ベクトルがスタイルおよび意味（つまり統語，語義）の類似性を捉えているか評価する．

データセット

本研究では，学習コーパスとして，ショートストーリー (SS) を用いる．SS とは，Web に投稿された漫画やアニメの二次創作作品であり，かぎ括弧で囲まれた登場人物の発話が記載されている．我々は，かぎ括弧で囲まれた約 30M 発話を収集した．前処理として，収集した発話に対して単語単位の分かち書きや品詞情報の付与等 *1 を施した後，スタイルを捉えやすくする工夫として “です + わ” や “です + ぜ” のように文末の機能語の連結処理をおこなった [12]．作成したコーパスの 99% を訓練データ，1% をテストデータとして用いた．

パラメータ設定

学習する全ての単語ベクトルの次元数を 300 次元に統一した．例外として，提案モデル *CBOW-sep-ctx* では，分割されたスタイルベクトル $\boldsymbol{x}_{w_t}$ および意味ベクトル $\boldsymbol{y}_{w_t}$ の次元としてそれぞれ 300 次元を用意し，合計 600 次元の単語ベクトル $\boldsymbol{v}_{w_t}$ を学習した．窓幅は $\delta = 5$ を用いた．また *CBOW-sep-ctx* における学習率は，$\{ \boldsymbol{v}_{C_{w_t}^{near}}, \boldsymbol{x}_{C_{w_t}^{dist}}, \tilde{\boldsymbol{v}}_{C_{w_t}^{near}}, \tilde{\boldsymbol{x}}_{C_{w_t}^{dist}} \}$ の各部分で学習率と更新回数の期待値との積が一定となるよう，部分毎に調整をおこなった． 学習にはコーパス内での出現頻度が 5 以上の単語を用い，結果として語彙サイズは約 10 万となった．学習の高速化のため，負例サンプリングによる近似をおこなった．コーパス中の単語の各出現について計 10 回ずつ学習した後，学習を停止した．

3.1 スタイルの類似性に関する評価

提案モデルがスタイルの類似性を捉えていることを検証するために，モデルが捉えた単語の類似性が人間の感じる単語のスタイルの類似性とどの程度相関があるかを定量的に確かめる．

我々が知る限り，スタイルの類似性を定量的に評価するための尺度およびデータセットは存在しない．そこで我々は，単語類似度タスク（similarity task）のための評価データセットの構築手法 [14] を参考にして，以下の 2 ステップで単語ペアに対して人間がスタイルの類似度を付与したデータを新しく構築する．(1) クラウドソーシングによって “俺” や “だぜ” のような何ら

*1　表現の分散による不必要な語彙の増加を防ぐ目的で，動詞の原形化および一部の単語について漢字・ひらがな・カタカナ表現の統一処理をおこなった．

モデル	ρ_{style}	ρ_{sem}	syntax acc @5	syntax acc @10
CBOW-near-ctx	12.1	27.8	86.3	85.2
CBOW-all-ctx	36.6	24.0	85.3	84.1
CBOW-dist-ctx	**56.1**	15.9	59.4	58.8
CBOW-sep-ctx				
スタイルベクトル $\boldsymbol{x}$	**51.3**	**28.9**	68.3	66.2
意味ベクトル $\boldsymbol{y}$	9.6	18.1	**88.0**	**87.0**

表 1　スタイル/語義的/統語的な類似性に関する評価の結果．ρ_{style} および ρ_{sem} は実際の係数 ×100 の値である．

かのスタイルと強く関係しそうな単語を収集する [*2]．具体的には，テストセットからランダムに抽出した 1,000 文の各文を 5 人のアノテータに提示し，4 人以上がスタイルが現れていると判断した単語を選択してもらった．(2) 次に，収集したスタイルに関係する単語の集合から 1,000 の単語ペアをランダムに生成し，各ペアについて 15 人のアノテータに 5 段階（−2：スタイルが異なる〜+2：スタイルが類似している）でスタイルの類似度のスコア付けを指示した．また，単語ペアだけではどのようなスタイルであるかを判定することが難しいため，各単語を含む発話もアノテータに提示した．この発話は，テストセットから無作為に抽出することでひとつの単語ペアにつき 3 種類を用意した．最終的には，アノテータ間での合意が認められた 399 の単語ペアとそれらに対する類似度のスコアが得られた [*3]．本研究はスタイルの類似性を定量的に評価するための評価データセットを作成した最初の研究である．

本研究では，以下の手順で学習された単語ベクトルがスタイルの類似性を捉えているかを定量評価する．(1) 評価データセット内の全単語ペアについて，単語ベクトルを用いてコサイン類似度を計算する．(2) 単語ペアの集合を計算した類似度順に並べ替える．(3) モデルが並べ替えた単語ペアの順序と，人間がスコア付けした単語ペアの順序について，Spearman の相関係数 ρ_{style} を計算する．

結果を表 1 の左部に示す．全ての提案モデル *CBOW-{all,dist}-ctx* 及び *CBOW-sep-ctx* のスタイルベクトル $\boldsymbol{x}$ はベースラインモデル *CBOW-near-ctx* より高い相関を持つことがわかる．特に *CBOW-dist-ctx* とスタイルベクトル $\boldsymbol{x}$ は，それぞれ $\rho_{style} = 56.1$，51.3 と，スタイルの類似性について人間の認識と高い相関を持つ結果となった．これらの結果は，発話内の文脈単語を使用することが，スタイルの類似性を捉えた単語ベクトルの構築に寄与していることを意味する．

3.2　統語・語義の類似性に関する評価

標準的な単語ベクトルである CBOW は，意味（つまり統語および語義）の類似性を捉えることができると検証されている [10]．本研究でも（1）品詞の予測からみる統語的な類似の捕捉，（2）人間との相関からみる語義的な類似の捕捉の 2 つの観点から，提案した単語ベクトルの特性を詳細に分析する．

3.2.1　統語的な類似性

同じ品詞の単語がベクトル空間上の近い位置に配置されているかを計算することで，単語ベクトルが統語的な類似性を捉えているかを評価する．具体的には，あるターゲット単語 w と類似する上位 N 単語 w' の品詞の一致率の平均 syntax acc を以下の式で算出する：

$$\text{syntax acc} = \frac{1}{|V|N} \sum_{w \in V} \sum_{w' \in \mathcal{N}(w)} \mathbb{I}[\text{PoS}(w) = \text{PoS}(w')], \quad (5)$$

ここで $\mathbb{I}[\cdot]$ は指示関数を意味し，$\text{PoS}(w)$ は単語 w の品詞を返す関数を意味する．$\mathcal{N}(w)$ は $\cos(w, w')$ に関する類似度上位 N までに含まれる単語 $\{w'\}$ の集合である．

表 1 の右部に $N = 5, 10$ のときの品詞の平均一致率を示す．どちらの N についても，*CBOW-{near,all}-ctx* および *CBOW-sep-ctx* の意味ベクトル $\boldsymbol{y}$ が統語的な類似性を捉えている結果となった．反対に，*CBOW-dist-ctx* スタイルベクトル $\boldsymbol{x}$ は，統語的な類似性を捉えておらず，これらの結果は，本研究の目的であるスタイルの類似性だけを捉えた単語ベクトルの構築が部分的に達成できたことを意味する．ここで興味深いのは，*CBOW-all-ctx* とスタイルベクトル $\boldsymbol{x}$ は両方とも発話内の全単語を文脈として学習しているにもかかわらず，*CBOW-all-ctx* のほうが統語的な類似性を捉えているということである．これは *CBOW-sep-ctx* の予測確率（式（4））の計算において，近傍の文脈単語 $C_{w_t}^{near}$ から得られる統語的な情報を意味ベクトル $\boldsymbol{y}$ がフィルタリングしたためと推測できる．なお，提案モデル *CBOW-sep-ctx* における $\boldsymbol{x}$ および $\boldsymbol{y}$ がそれぞれ捉える統語的な性質の差異については，3.2.2 節で詳しく分析する．

3.2.2　語義的な類似性

単語ベクトルが語義的類似性を捉えているかを評価する．本研究では，評価データセットとして日本語単語類似性データセット（JWSD） [16] を用いた．JWSD は約 4,000 の単語ペアから形成され，各単語ペアには人間が付与した 0 から 10 の類似度スコアを持つ．我々は，3.1 節のスタイルの類似性評価と同様に，モデルが計算した単語ベクトルのコサイン類似度と人間が付与した類似度スコアとの間の Spearman の相関係数（ρ_{sem}）を算出した．

結果を表 1 の中央部に示す．驚くべきことに，*CBOW-dist-ctx* とスタイルベクトル $\boldsymbol{x}$ はスタイルの類似性評価では高い ρ_{style} であったにもかかわらず，語義の類似性評価ではスタイルベクトル $\boldsymbol{x}$ が高い ρ_{sem} であり，*CBOW-dist-ctx* が低い ρ_{sem} となった．本研究の目的はスタイルの類似性**のみ**を捉えた単語ベクトルの構築であるが，提案したスタイルベクトル $\boldsymbol{x}$ はスタイルの類似性以外の類似性も捉えている結果となった．この原因についての考察は次節で述べるが，我々はスタイルベクトル $\boldsymbol{x}$ が発話のトピック（relatedness）の類似性を捉えたためだと推測した．JWSD には単なる語義の類似だけでなく，あるトピックに関連する単語たちや同義語たちもペアとして含まれているため，トピックの類似性を捉える単語ベクトルでは ρ_{sem} の値は大きくなる．

3.3　スタイルベクトルおよび意味ベクトルの定性分析

提案モデル *CBOW-sep-ctx* によって獲得した 2 種類のベクトルが持つ性質を定性的に分析する．分析対象とするターゲット単語 [*4] について，各ベクトル空間上でコサイン類似度が大きい上位 5 件の単語を表 2 に示す．表 2 左部より，スタイルベク

*2　少なくとも日本語には，役割語 [15] など特にスタイルの差異によく関与する単語がある一方で，「ホワイトボード」などどの人物がどの状況で言っても同じ表現となる，いわばスタイルの差異が関与しない単語がある．そのため，スタイルとは関係ない単語を用いてスタイルの類似性の評価データを作成することは非効率であり，この段階で除外したい．

*3　10 人以上のアノテータのスコアが $\{-2, -1\}$ または $\{+2, +1\}$ に一致している場合を合意があるものとした．

*4　分析対象とする単語は，スタイル類似度評価データセットの作成過程でアノテータ 5 人全員が選択したスタイルに関係する単語を用いた．

ターゲット単語 w_t	スタイルベクトル: $\boldsymbol{x}_{w_t}$	意味 (語義/統語) ベクトル: $\boldsymbol{y}_{w_t}$
俺	おまえ，あいつ，ねーよ，奴，そいつ	僕，あたし，私，おまえ，わし
拙者	でござる，ござる，ござるよ，ないでござる，たでござる	僕，俺，吾輩，私，あたし
かしら	わね, ないわね, わ，だわ，かしらね	かな，でしょうか，かしらね，かなぁ，でしょう
サンタ	サンタクロース，トナカイ，クリスマス，ソリ，プレゼント	お客，プロデューサー，メイド，由比ヶ浜，鹿目

表 2　スタイルベクトル空間および意味ベクトル空間における分析対象の単語とコサイン類似度が大きい上位 5 単語.

トル $\boldsymbol{x}$ 空間では，“俺” に対しては “おまえ” や “ねーよ（文末）” といった男性らしく粗野な単語との類似度が高い結果となった．また “拙者” に対しては “ござる” という忍者や侍らしい古典的な言葉遣いの単語が近くに配置されていることがわかる．このように，スタイルベクトル $\boldsymbol{x}$ はスタイルの類似性を捉えていることが観察された．一方，表 2 の右部より，意味ベクトル空間 $\boldsymbol{y}$ では，“俺” や “拙者” に対しては一人称代名詞である “僕” や “私” が近くに配置されていることがわかる．なお，紙面の都合により省略するが “俺” と類似する上位 15 位の単語全てが人称代名詞であった．これらの結果から，提案した *CBOW-sep-ctx* は (1) スタイルの類似性を捉える単語ベクトルと (2) 統語・語義の類似性を捉える単語ベクトルに分離しながら単語ベクトル同時に学習していることが，定性的に確かめられた．

面白いことに，スタイルベクトル $\boldsymbol{x}$ において単語 “サンタ” は “トナカイ” や “クリスマス” 等の同じ**トピック**の単語との類似度が高いことが観測された（表 2，4 行目）．本研究では，スタイルの類似性と捉えるために「発話内の全単語のスタイルは一貫している」という仮定を立てたが，発話内ではスタイルだけでなくトピックも一貫していることが多い．例えば “サンタ” と “トナカイ” はクリスマスのトピックであり，これらはしばしば 1 つの発話内で共起しやすい．したがって，発話内で共起するの全ての単語の情報を用いたスタイルベクトル $\boldsymbol{x}$ ではトピックの関連性も捕捉しており，提案手法はトピックの類似性も捉えたと考えられる．

4. おわりに

本研究では，スタイルの類似性を捉える単語ベクトルを教師なし学習することを試みた．具体的には，「発話内の単語のスタイルは一貫している」という仮定に基づいて，ターゲット単語から文脈単語までの位置によって学習する単語ベクトルを調節することで，スタイルの類似性を捉えた単語ベクトルと，統語的/語義的な類似性を捉えた単語ベクトルを同時に学習するモデルを提案した． 実験では，提案モデルが 2 つの性質の異なる類似性をそれぞれ捉えていることを，定量的および定性的に確認した．なお，本研究では定性評価を実施するために，単語ペアに対して人間がスタイルの類似度スコアを付与した新しい評価用データセットを作成した．このスタイルの類似性を捉えられたかを定性的に評価する手法は我々が初めて提案した手法である．

しかし，定性評価の結果，提案したスタイルベクトルはスタイルの類似性に加えてトピックの類似性も捉えていることが明らかになった．今後は，「文書（複数の発話）のトピックは一貫している」という仮定を基に，スタイルとトピックが分離できるようにモデルを拡張する．

謝辞

本研究の一部は，豊田中央研究所および文部科学省科研費 15H01702 の支援を受けた．

参考文献

[1] E. Pavlick and J. Tetreault. An Empirical Analysis of Formality in Online Communication. *Transactions of the Association of Computational Linguistics*, 4:61–74, 2016.

[2] X. Niu and M. Carpuat. Discovering Stylistic Variations in Distributional Vector Space Models via Lexical Paraphrases. In *Proceedings of the Workshop on Stylistic Variation*, pages 20–27, 2017.

[3] D. Wang, N. Jojic, C. Brockett, and E. Nyberg. Steering Output Style and Topic in Neural Response Generation. In *EMNLP2017*, pages 2130–2140, 2017.

[4] E. Pavlick and A. Nenkova. Inducing Lexical Style Properties for Paraphrase and Genre Differentiation. In *NAACL-HLT2015*, pages 218–224, 2015.

[5] L. Flekova, D. PreoŢiuc-Pietro, and L. Ungar. Exploring Stylistic Variation with Age and Income on Twitter. In *ACL2016*, pages 313–319, 2016.

[6] D. Preotiuc-Pietro, W. Xu, and L. H. Ungar. Discovering User Attribute Stylistic Differences via Paraphrasing. In *AAAI2016*, pages 3030–3037, 2016.

[7] R. Sennrich, B. Haddow, and A. Birch. Controlling Politeness in Neural Machine Translation via Side Constraints. In *NAACL-HLT2016*, pages 35–40, 2016.

[8] X. Niu, M. Martindale, and M. Carpuat. A Study of Style in Machine Translation: Controlling the Formality of Machine Translation Output. In *EMNLP2017*, pages 2804–2809, 2017.

[9] W. Xu. From Shakespeare to Twitter: What are Language Styles all about? In *Proceedings of the Workshop on Stylistic Variation*, pages 1–9, 2017.

[10] T. Mikolov, K. Chen, G. Corrado, and J. Dean. Efficient Estimation of Word Representations in Vector Space. In *ICLR2013*, 2013.

[11] T. Mikolov, I. Sutskever, K. Chen, G. Corrado, and J. Dean. Distributed Representations of Words and Phrases and Their Compositionality. In *NIPS2013*, pages 3111–3119, 2013.

[12] C. Miyazaki, T. Hirano, R. Higashinaka, T. Makino, and Y. Matsuo. Automatic Conversion of Sentence-end Expressions for Utterance Characterization of Dialogue Systems. In *PACLIC2015*, pages 307–314, 2015.

[13] J. Li, M. Galley, C. Brockett, G. Spithourakis, J. Gao, and B. Dolan. A persona-based neural conversation model. In *Proc. ACL2016*, pages 994–1003, 2016.

[14] D. Gerz, I. Vulic, F. Hill, R. Reichart, and A. Korhonen. SimVerb-3500: A Large-Scale Evaluation Set of Verb Similarity. In *EMNLP2016*, pages 2173–2182, 2016.

[15] S. Kinsui. *Vaacharu nihongo: yakuwari-go no nazo (In Japanese)*. Tokyo, Japan: Iwanami, 2003.

[16] Y. Sakaizawa and M. Komachi. Construction of a Japanese Word Similarity Dataset. In *LREC2018*, 2018.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

レイヤーベクトルを用いたマルチプレックスネットワークのエンベディング

Multiplex Network Embedding with Layer Vectors

松野 竜太　　村田 剛志
Ryuta Matsuno　Tsuyoshi Murata

東京工業大学 情報理工学院 情報工学系
Department of Computer Science, School of Computing, Tokyo Institute of Technology

Network embedding is a method to convert nodes in a network into low dimensional vectors. Most of existing works are designed for single-layer networks, however, real world networks are often represented as multiplex networks. Thus, we propose a novel embedding method for multiplex networks, named MELL, which incorporates layer vectors that capture layer connectivity. The experimental results of link prediction tasks show that MELL outperforms all of the existing methods.

1. はじめに

ネットワークエンベディングは, ネットワーク上のノードを低次元のベクトルに変換する手法で, ネットワーク上のノードの近接関係をベクトル空間中の距離関係に反映させることでネットワーク構造を学習している. この手法は, ネットワーク分析に広く応用されており, 例としてネットワーク可視化, ノードの多クラス分類, リンク予測が挙げられる. 特に潜在的なエッジを予測するリンク予測は, 情報推薦や知識発見などへの応用が可能であるため, 本研究では特にリンク予測に焦点を当てる.

既存のエンベディング手法のほとんどが単層ネットワークを対象としている一方で, 現実世界には, マルチプレックスネットワークと呼ばれるネットワークが多く存在する. マルチプレックスネットワークは, 全てのレイヤーが同じノードを持つ多層ネットワークで, 同一のノード間における複数の関係性を表現することができる. 例えば, 同じユーザーに利用されている複数のソーシャルネットワークは, 1 つのレイヤーが 1 つのソーシャルネットワーク上の関係を表すマルチプレックスネットワークとして表現できる.

マルチプレックスネットワークでは, 各レイヤーが互いに影響しあっているため各レイヤーを独立に分析することは非効果的である. 例えば, あるソーシャルネットワーク上で友人関係にあるユーザー同士が, 別のソーシャルネットワーク上でも友人関係であることは十分考えられる. 従って, これらのソーシャルネットワークを合わせて分析することでより効果的な分析を行える. 一方で, 関連性の低いソーシャルネットワークが同時に存在する場合もあるため, マルチプレックスネットワークを分析する際は, 各レイヤーの関係性に留意することが重要となる.

本研究では, レイヤーベクトルを用いたマルチプレックスネットワークのエンベディング手法として MELL を提案する. レイヤーベクトルとは, 各レイヤーの構造からレイヤーの関係性を学習するベクトルである. MELL は, 全てのレイヤー構造をエンベディングに反映すると同時に, レイヤーベクトルによってレイヤーごとの関係性を利用してエンベディングを行うことができる. MELL は, エンベディングの結果に基づいてリンク予測を行うことができ, リンク予測について, 既存手法と比較した実験においては, 全てのデータセットで既存手法を上回る精度を示し, 最大で 25%高い AUC 値を示した.

連絡先: 東京工業大学 情報理工学院 情報工学系
東京都目黒区大岡山 2 丁目 12-1 W8-59
E-mail:ryutamatsuno@net.c.titech.ac.jp

2. 問題定義

本研究の対象であるマルチプレックスネットワーク及びリンク予測問題を次のように定義する.

定義 1 (マルチプレックスネットワーク)**.** マルチプレックスネットワークは, 全てのレイヤーが同じノードを持つ多層ネットワークである. マルチプレックスネットワーク $\mathcal{G}$ は $\mathcal{G} = \{G^1, ..., G^L\}$ と表され, $G^l = (\mathcal{V}^l, \mathcal{E}^l)$ が l 番目のレイヤーを示す. $\mathcal{V}^l = \{v_1^l, ..., v_N^l\}$ はノードの集合, $\mathcal{E}^l \subset \mathcal{V}^l \times \mathcal{V}^l$ はエッジの集合である. L, N はそれぞれレイヤー数, ノード数を示す. また, $M = \sum_{l=1}^{L} |\mathcal{E}^l|$ は $\mathcal{G}$ の全エッジ数を表す.

定義 2 (マルチプレックスネットワークにおけるリンク予測問題)**.** この問題は, 与えられたマルチプレックスネットワークの任意のレイヤーの接続されていないノード対間に潜在的なエッジが存在する確率 (以下, エッジ確率) を求める問題である.

本研究では, マルチプレックスネットワークのエンベディングを行い, リンク予測問題に対して評価を行う.

3. 提案手法

本研究では, 単層ネットワークに用いられるベクトルの内積を利用したエンベディング手法 [Xu 2017] に基づいて, マルチプレックスネットワークのエンベディング手法 MELL (Multiplex network Embedding via Learning Layer vector) を提案する. 具体的には, 内積を利用した手法に以下の 3 つの新しいアイデアを組み込んでいる.

- MELL は, 全レイヤーの構造を同時に利用するために, 各レイヤーをそれぞれエンベディングした上で, 各レイヤー上の同一ノードに対するベクトルのばらつきを小さくする.
- MELL は, レイヤーごとの関係性を反映するために, レイヤーベクトルを利用する.
- MELL は, 無向グラフに対応するために, 1 つのノードに対して 2 つのベクトルをエンベディングする.

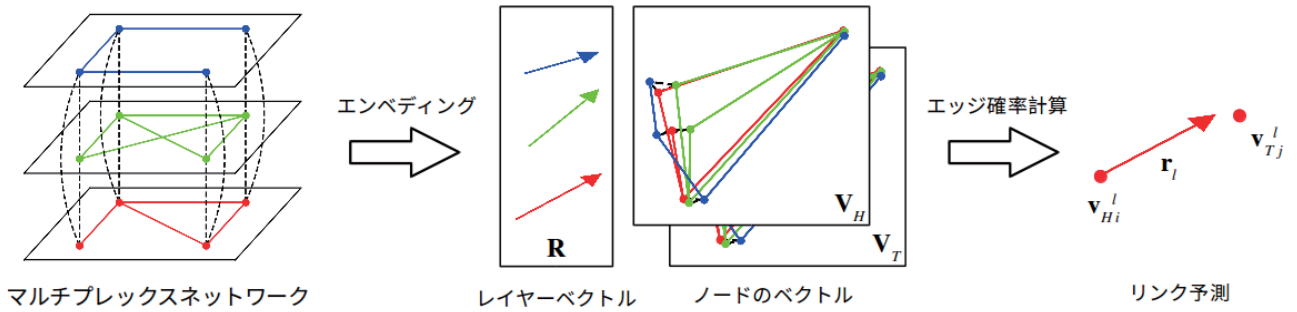


図 1: MELL を用いたリンク予測全体の流れ．MELL は，マルチプレックスネットワークからレイヤー毎に各ノードのベクトルとレイヤーベクトルを学習する．これらのベクトルを用いて式 (2) によりエッジ確率を計算しリンク予測を行う．

MELL の全体的な流れを図 1 に示す．

最初のアイデアは，マルチプレックスネットワークの各レイヤーをエンベディングして，各レイヤーの同一ノードに対するベクトルのばらつきを制限することである．MELL は，まず各レイヤーをエンベディングし，次に各レイヤーの同一ノードのエンベディングのベクトル $\mathbf{v}_i^1, ..., \mathbf{v}_i^L$ の分散 $\mathbb{V}[\{\mathbf{v}_i^1, ..., \mathbf{v}_i^L\}]$ を制限する．すなわち，MELL は $\mathbf{v}_i^1 \approx ... \approx \mathbf{v}_i^L$ となるようにエンベディングを行う．これによりレイヤー毎のエンベディングが同一に近づく．エッジ確率は各レイヤーのエンベディングに基づいて計算されるため，これは全レイヤーで同じようなリンク予測を行うことを意味している．構造が似ているレイヤー間においては，一方に存在するエッジを他方でも予測できるため，このアイデアは有効である一方，構造が異なるレイヤー間においては，関連の無いレイヤーを反映してしまうため，うまくエンベディングを行うことができない．

レイヤー間の関係を反映したエンベディングを行うために，MELL はレイヤーベクトルを利用する．レイヤーベクトルは各レイヤーに 1 つ割り当てられるベクトルで，他のレイヤーとの類似性を学習する．このレイヤーベクトルは，エッジ確率の計算に使用され，l 番目のレイヤーにおいて，v_i^l, v_j^l 間のエッジ確率 $p(v_i^l, v_j^l)$ は次のように定義される．

$$p(v_i^l, v_j^l) = \sigma\left((\mathbf{v}_i^l + \mathbf{r}_l)^\mathsf{T} \cdot \mathbf{v}_j^l\right) \tag{1}$$

$\sigma(x)$ は $\sigma(x) = 1/(1+\exp(-x))$ で定義されるシグモイド関数である．$\mathbf{v}_i^l, \mathbf{v}_j^l$ はそれぞれ v_i^l, v_j^l に対応するベクトルで，$\mathbf{r}_l$ は l 番目のレイヤーのレイヤーベクトルを表す．同一ノードのばらつきの制限と式 (1) から，レイヤー構造の類似性がレイヤーベクトルの類似性に反映されることがわかる．このレイヤーベクトルの働きによって，レイヤー毎に異なるエッジ確率を計算できるため，レイヤーに応じたリンク予測が可能になる．

レイヤーベクトルを利用した場合，式 (1) のようにエッジ確率の計算が非対称になる．すなわち，$p(v_i^l, v_j^l) \neq p(v_j^l, v_i^l)$ である．式 (1) は，非対称なエッジ確率が求められる有向グラフでは問題ないが，対称なエッジ確率を必要とする無向グラフでエッジ確率を正しく計算できない．そのため，MELL は [Zhou 2017] を参考に，無向グラフにおいて同一ノードに対して 2 つのベクトルをエンベディングしている．MELL は，1 つの無向エッジを 2 つの双方向の有向エッジとして見なし，1 つのノードに対して，有向エッジが出る際のベクトルと有向エッジが入る際のベクトルの 2 つのベクトルを割り当てている．従って v_i^l から v_j^l へのエッジ確率は次のように再定義される．

$$p(v_i^l, v_j^l) = \sigma\left((\mathbf{v}_{Hi}^{\ l} + \mathbf{r}_l)^\mathsf{T} \cdot \mathbf{v}_{Tj}^{\ l}\right) \tag{2}$$

$\mathbf{v}_{Hi}^{\ l}$ は，エッジが出る際の v_i^l のベクトル，$\mathbf{v}_{Tj}^{\ l}$ はエッジが入る際の v_j^l のベクトルを表す．なお，有向グラフにおいては，$\mathbf{v}_{Hi}^{\ l}$ 及び $\mathbf{v}_{Ti}^{\ l}$ は同一である．

MELL は，以上のアイデアを式 (2) と次に示す損失関数に反映し，損失を最小化することによって，ノード及びレイヤーのベクトルを学習する．損失関数 $Loss$ は，次のように定義される．

$$\begin{aligned} Loss(\mathcal{E}_{pos}, \mathcal{E}_{neg}; \lambda, \beta, \gamma) = &- \sum_{(v_i^l, v_j^l) \in \mathcal{E}_{pos}} \log p(v_i^l, v_j^l) \\ &- \sum_{(v_i^l, v_j^l) \in \mathcal{E}_{neg}} \log\left(1 - p(v_i^l, v_j^l)\right) \\ &+ \beta\left(\mathbb{V}[\mathbf{V}_H] + \mathbb{V}[\mathbf{V}_T]\right) \\ &+ \frac{\lambda}{N}(\|\mathbf{V}_H\|_F^2 + \|\mathbf{V}_T\|_F^2) + \gamma\|\mathbf{R}\|_F^2 \end{aligned} \tag{3}$$

$\mathbf{V}_H, \mathbf{V}_T \in \mathbb{R}^{L \times N \times d}$ はそれぞれエッジが出る際，入る際の各レイヤー各ノードのベクトルである．d はエンベディングの次元を表し，$\mathbf{R} \in \mathbb{R}^{L \times d}$ は各レイヤーのレイヤーベクトルを示す．$\mathcal{E}_{pos} = \bigcup_{l=1}^{L} \mathcal{E}^l$ は存在するエッジの集合であり，無向グラフでは，$\mathcal{E}'^l = \{(v_j^l, v_i^l) | (v_i^l, v_j^l) \in \mathcal{E}^l\}$ として，$\mathcal{E}_{pos} = \bigcup_{l=1}^{L} (\mathcal{E}^l \cup \mathcal{E}'^l)$ とする．$\mathcal{E}_{neg}$ は，学習の際に利用するネガティブサンプルで，全レイヤーの接続されていないノード対からランダムにサンプルする．サンプル数は，ハイパーパラメータである k を用いて $k|\mathcal{E}_{pos}|$ とする．第 3 項は，同一ノードのベクトルのばらつきを制限する項で，$\mathbb{V}[\mathbf{V}_H] = \frac{1}{L}\sum_{l=1}^{L} \|\mathbf{V}_H[l] - \mathbb{E}[\mathbf{V}_H]\|_F^2, \mathbb{E}[\mathbf{V}_H] = \frac{1}{L}\sum_{l=1}^{L} \mathbf{V}_H[l]$ と計算される．$\mathbf{V}_H[l] \in \mathbb{R}^{N \times d}$ は，$\mathbf{V}_H$ の l 番目の行列を表す．$\mathbb{V}[\mathbf{V}_T]$ も同様に計算される．第 4, 5 項は，正則化項であり，λ は各ノードのベクトルに対する正則化係数，γ はレイヤーベクトルに対する正則化係数である．MELL は式 (3) の損失関数を最急降下法等を用いて最小化することで，ノードのベクトル $\mathbf{V}_H, \mathbf{V}_T$ 及びレイヤーベクトル $\mathbf{R}$ を学習する．ハイパーパラメータは，エンベディングの次元 d，ネガティブサンプルの割合 k，エンベディングに対する正則化係数 λ，同一ノードのエンベディングに対する正則化係数 β，レイヤーベクトルに対する正則化係数 γ の 5 つである．これらのパラメータはグリッドサーチによって決定される．

表 1: 本実験で使用したデータセットの詳細. L はレイヤー数, N はノードの数, M は全エッジ数を示す.

データセット	L	N	M	種類	有向/無向
CS-Aarhus	5	61	620	交流関係	無向グラフ
Pierre Auger Collaboration	16	514	7153	共著関係	無向グラフ
EU Air Transportation	37	450	3588	交通網	無向グラフ
C.Elegans Connectome	3	279	5863	神経網	有向グラフ
Xenopus	5	461	620	遺伝子網	有向グラフ

MELL は, エンベディングの結果から v_i^l, v_j^l 間のエッジ確率を式 (2) により計算し, リンク予測を行う. なお, 無向マルチプレックスネットワークにおいては, $p(v_i^l, v_j^l)$ と $p(v_j^l, v_i^l)$ の平均を予測値として使用する.

4. 実験

マルチプレックスネットワークにおけるリンク予測について, 提案手法の MELL を既存手法と比較する実験を行った.

4.1 データセット

本実験では, 表 1 に示した 5 つの異なる種類のデータセットを使用した. これらのデータセットは, CoMuNe 研究室のウェブサイトから取得した [*1]. データセットの詳細は次の通りである.

- CS-Aarhus [Magnani 2013] : ユーザー間における 5 種類の交流関係を表す無向マルチプレックスネットワーク
- Pierre Auger Collaboration [De Domenico 2015a] : 16 分野における共著関係を表現した無向マルチプレックスネットワーク
- EU Air Transportation [Cardillo 2013] : ヨーロッパ圏における 37 の航空会社による路線を表現した無向マルチプレックスネットワーク
- C.Elegans Connectome[Chen 2006][De Domenico 2015b] : 神経網における 3 種類の反応性を表現した有向マルチプレックスネットワーク
- Xenopus [Stark 2006] [De Domenico 2015b] : 遺伝子およびタンパク質間における 5 種類の反応を表現した有向マルチプレックスネットワーク

4.2 実験手法

それぞれのデータセットにおいて, 各レイヤーの α_t% のエッジを学習に使用し, 残りのエッジをテスト用エッジとして使用する. テストにおいては, テスト用エッジと同数の接続されていないノード対をランダムにサンプルし, これらを合わせて使用する. 提案手法及び既存手法は, テスト用エッジおよびランダムにサンプルされた接続されていないノード対のそれぞれに対してリンク予測を行い, エッジが存在する確率を 0 から 1 の間で出力する. 評価には, リンク予測問題で一般的に用いられる AUC (AUROC) 値を利用する. 各実験において学習に使用するエッジを一様に 5 回変え, AUC 値の平均を最終的な値として報告する. $\alpha_t = 20\%$ において, この実験設定は 5 分割交差検証法と同等である.

4.3 比較手法

マルチプレックスネットワークにおけるリンク予測問題に対する既存手法として, APP, MTNE-R 及び MTNE-R Consensus (以下 MTNE-R Cons.), MULTITENSOR の 4 つが挙げられる. 本実験では, MELL をこれらの既存手法と比較した. 既存手法の詳細は次の通りである.

- APP [Zhou 2017] : APP は単層ネットワークにおけるエンベディング手法であり, ランダムウォークを用いてノード間の近接関係を学習する. APP はエンベディング結果からリンク予測を行うことができ, マルチプレックスネットワークに対しては, 各レイヤーごとに独立にエンベディングを行い, リンクを予測する.
- MTNE-R, MTNE-R Cons. [Xu 2017] : MTNE は無向マルチプレックスネットワークのエンベディング手法で, 各レイヤーをそれぞれエンベディングした上で, 全レイヤー構造の共通部分を利用してそれらのエンベディングを改善する. MTNE-R は, 各レイヤーのエンベディングを用いてリンク予測を行う手法, MTNE-R Cons. は全レイヤーの共通部分を用いてリンク予測を行う手法である.
- MULTITENSOR [De Bacco 2017] : MULTITENSOR はテンソル分解を利用した手法である. この手法は, ポアソンテンソル分解によってマルチプレックスネットワークネットワークの隣接テンソルを分解し, 再び隣接テンソルを生成する. MLTITENSOR はこの再生成したテンソルの値に基づいてリンク予測を行う.

4.4 実験結果

各データセットにおいて, α_t を 20%, 40%, 60%, 80% と変化させ, それぞれにおいて提案手法および既存手法の AUC 値を測定した. 実験結果を表 2 に示す.

一連の実験結果から全てのデータセット, 全ての α_t において, 提案手法の MELL が既存手法を上回る AUC 値を示していることがわかる. 特に Xenopus において $\alpha_t = 80\%$ の場合, 既存手法の最高値よりも 25%高い AUC 値を示しており, 本研究の提案がマルチプレックスネットワークのエンベディング及びリンク予測に極めて有効であることが, 本実験によって示された.

APP は, 全ての場合で最低の AUC 値を示しており, マルチプレックスネットワークに対する単層ネットワークのエンベディング手法の使用が非効果的であることがを示している.

MTNE-R 及び MTNE-R Cons. は, CS-Aarhus と Pierre Auger Collaboration で比較的良いリンク予測を行っている. 一方で, EU Air Transportation では低い AUC 値を示している. 前者の 2 つのデータセットは, ネットワーク種類の特性により各レイヤーが似た構造を持っている. 従って MTNE-R 及び MTNE-R Cons. はレイヤー構造が似ている場合にのみ有効にリンクを予測できることがわかる.

MULTITENSOR は, ほとんどの場合において既存手法の中で最も高い精度でリンク予測を行っている.

*1 https://comunelab.fbk.eu/data.php

表 2: 本実験の結果：表中の数値は AUC の値を表し, 高いほど高精度なリンク予測を示す. α_t は, 学習に利用したエッジの割合を示す. MTNE-R および MTNE-R Cons. は無向グラフでのみ評価を行った. 太字は, 各データセットの各 α_t において最も高い AUC の値を表す.

		学習率 α_t			
データセット	手法	20%	40%	60%	80%
CS-Aarhus	APP	0.5461	0.6630	0.7376	0.7757
	MTNE-R	0.6977	0.7788	0.7921	0.8492
	MTNE-R Cons.	0.6943	0.7645	0.8189	0.8370
	MULTITENSOR	0.6645	0.7827	0.8862	0.9071
	MELL	**0.8173**	**0.8877**	**0.9224**	**0.9417**
Pierre Auger Collaboration	APP	0.6060	0.7913	0.8894	0.9434
	MTNE-R	0.9214	0.9525	0.9765	0.9873
	MTNE-R Cons.	0.9217	0.9542	0.9775	0.9874
	MULTITENSOR	0.9451	0.9705	0.9817	0.9893
	MELL	**0.9811**	**0.9918**	**0.9956**	**0.9979**
EU Air Transportation	APP	0.4364	0.4904	0.5536	0.5828
	MTNE-R	0.5535	0.6891	0.7446	0.7817
	MTNE-R Cons.	0.5550	0.7010	0.7440	0.7683
	MULTITENSOR	0.8516	0.9041	0.9344	0.9463
	MELL	**0.9806**	**0.9897**	**0.9941**	**0.9944**
C.Elegans Connectome	APP	0.5875	0.6800	0.7287	0.7518
	MULTITENSOR	0.7167	0.8019	0.8434	0.8836
	MELL	**0.8360**	**0.9144**	**0.9430**	**0.9701**
Xenopus	APP	0.5135	0.5260	0.5536	0.5442
	MULTITENSOR	0.5469	0.5921	0.6441	0.6664
	MELL	**0.7575**	**0.8159**	**0.8818**	**0.9130**

5. おわりに

本研究では, マルチプレックスネットワークのエンベディング手法 MELL を提案した. MELL はレイヤーベクトルを利用することで, 各レイヤーの関係性を考慮したエンベディングを行うことができる. リンク予測に対する既存手法との比較実験において, MELL は 5 種類の全てのデータセットで既存手法を上回る AUC 値を示し, ネットワークの種類にかかわらず高い精度でリンク予測を行えることを示した.

今後の課題としては, ネットワーク可視化やノードの多クラス分類への応用, 及び時系列ネットワークへの応用が挙げられる.

参考文献

[Cardillo 2013] Cardillo, A., Gómez-Gardeñes, J., Zanin, M., Romance, M., Papo, D., Pozo, F. d., and Boccaletti, S. Emergence of network features from multiplexity. Scientific Reports 3 (2013), 1344.

[Chen 2006] Chen, B. L., Hall, D. H., and Chklovskii, D. B. Wiring optimization can relate neuronal structure and function. Proceedings of the National Academy of Sciences of the United States of America 103, 12 (2006), 4723–4728.

[De Bacco 2017] De Bacco, C., Power, E. A., Larremore, D. B., and Moore, C. Community detection, link prediction, and layer interdependence in multilayer networks. Physical Review E 95 (2017), 042317.

[De Domenico 2015a] De Domenico, M., Lancichinetti, A., Arenas, A., and Rosvall, M. Identifying modular flows on multilayer networks reveals highly overlapping organization in interconnected systems. Physical Review X 5 (2015), 011027.

[De Domenico 2015b] De Domenico, M., Porter, M. A., and Arenas, A. Muxviz: a tool for multilayer analysis and visualization of networks. Journal of Complex Networks 3 (2015), 159–176.

[Magnani 2013] Magnani, M., Micenkova, B., and Rossi, L. Combinatorial Analysis of Multiple Networks. ArXiv e-prints (2013).

[Stark 2006] Stark, C., Breitkreutz, B.-J., Reguly, T., Boucher, L., Breitkreutz, A., and Tyers, M. Biogrid: a general repository for interaction datasets. Nucleic Acids Research 34, suppl_1 (2006), D535–D539.

[Xu 2017] Xu, L., Wei, X., Cao, J., and Yu, P. S. Multitask network embedding. In 2017 IEEE International Conference on Data Science and Advanced Analytics (2017), pp. 571–580.

[Zhou 2017] Zhou, C., Liu, Y., Liu, X., Liu, Z., and Gao, J. Scalable graph embedding for asymmetric proximity. 31st AAAI Conference on Artificial Intelligence (2017).

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

脳波特徴の階層性を利用した効率的なシャープレイ値推定による脳波識別の根拠の定量化

Quantification of contribution of features to EEG classification using the efficient estimation of Shapley Value based on a hierarchy of EEG features

立川 和樹 *1 Kazuki Tachikawa　河合 祐司 *1 Yuji Kawai　朴 志勲 *1 Jihoon Park　浅田 稔 *1 Minoru Asada

*1大阪大学大学院工学研究科
Graduate School of Engineering, Osaka University

Understanding how black-box classifiers predict is important in many applications, especially in medical diagnosis systems. We propose a method to quantify contribution of features to EEG classification using efficient estimation of the Shapley Sampling Value (SSV). EEG data have hierarchical features: an electrode signal, signals in various frequency-bands, and amplitude and phase. If contribution of a feature at a higher level (e.g., a signal of an electrode) is very small, contribution of features at the lower levels of the feature (e.g., signals of frequency-bands of the electrode) should be also small. The method prunes such features at lower levels to reduce computational complexity. We verified the usability of the method in two datasets for EEG classification. The result showed the method could reduce computational complexity of the SSV by one third, while maintaining high accuracy of the conventional SSV.

1. はじめに

深層学習の応用範囲は画像や音声，自然言語だけではなく，脳波へも広がっている [Schirrmeister 17]．このような脳波識別器を医療診断に応用する際には，その診断根拠を示すことが重要となる．しかし，深層学習を含め，ほとんどの機械学習モデルによる識別はブラックボックス化されており，識別根拠を人が理解することは難しい．そのため，学習器の識別根拠を理解するための様々な手法が提案されている [Sundararajan 17, Lundberg 17, Zhang 18]．これらの手法の中でも，シャープレイ値に基づくものは，各特徴の貢献を正確に計算するために理想的な公理を満たす唯一の方法であるため，識別根拠を理解するために理論上優れているといわれている [Lundberg 17]．しかし，シャープレイ値の計算量は，特徴数に対して階乗的に増加するため，これをより少ない計算量かつ少ない誤差で近似する手法が望まれる．そのため，Shapley Sampling Value (SSV) [Štrumbelj 14] が，識別モデルを限定しない近似手法として提案されている．

本研究では，SSV を用いることで，より正確，かつ，人に理解しやすい形式で，脳波の識別モデルの識別根拠を明らかにできることを示す．また，SSV の計算量を削減するために，脳波は複数の周波数帯成分の重ね合わせで構成され，それぞれの周波数帯成分に複数の特徴が含まれるという特徴の階層性を利用して，一度の計算に必要な特徴の数を減らすことで計算量を削減する手法を提案し，その有効性を実験的に示す．

2. 関連研究

2.1 シャープレイ値

シャープレイ値は協力ゲーム理論において協力によって得られた利得を公正に分配するための唯一の手法として Shapley により提案された [Shapley 53]．識別モデルを f とし，入力を x，入力する特徴の数を M，それぞれの特徴が識別へ貢献した度合いを ϕ とする．また，S は i 番目の特徴 x_i を除く x の部分集合である．モデル f と入力 x についての識別における i 番目の特徴の貢献は，次式で与えられる．

$$\phi_i(f,x) = \sum_{S \subseteq x \setminus i} \frac{|S|!(M-|S|-1)!}{M!}[f_{S\cup i}(S\cup i) - f_S(S)] \quad (1)$$

上式は，識別モデルへの入力 x に，ある特徴 x_i がある場合とない場合でのモデルの出力の差分を，必ずしもすべての可能な特徴の組み合わせで計算し，その差分に応じて，特徴に貢献を割り当てることを意味する．

この組み合わせを厳密に計算するためには，その組み合わせごとにモデルを学習させる必要がある．さらに，計算量は特徴の数 n に対して $\mathcal{O}(n!)$ であるため，計算量が膨大になるという問題がある．SSV は，各特徴が互いに独立に分布していることを仮定し，さらに，モンテカルロサンプリングにより，シャープレイ値を推定したものである．それによって，組み合わせごとの学習が不要になり，計算量が少なくなることが示されている [Štrumbelj 14]．

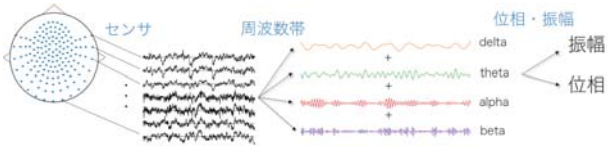


図 1: 脳波特徴の階層性

2.2 脳波識別において識別根拠を明らかにする方法

図 1 に示すように，脳波識別において識別根拠を明らかにする方法は，特徴の詳細さに応じてセンサレベル，周波数帯レベル，そして，振幅・位相レベルの三つの階層に分けられる．センサレベルでは，どのセンサの信号がどの程度識別に貢献したかを示し，周波数帯レベルでは，センサごとにどの周波数帯がどの程度識別に貢献したかを示す．さらに，振幅・位相レベルでは周波数帯ごとに位相・振幅がそれぞれどの程度識別に貢献したかを示す．

Sturm et al. は，Layer-wise Relevance Propagation (LRP) を用いた手法を提案した [Sturm 16]．LRP は識別モデルが

連絡先: 立川 和樹，kazuki.tachikawa@ams.eng.osaka-u.ac.jp

ニューラルネットの場合に，入出力の勾配を利用して識別根拠を明らかにする方法である [Ancona 17] ．この手法はシャープレイ値の公理系を満たさないが，それらを満たすように修正された Integrated Gradients (IG) 法が提案されている [Sundararajan 17] ．しかし，振幅や位相は入力空間にはない特徴であるため，この手法では，このレベルでの貢献を直接求められない．

Schirrmeister et al. は，入力する波の振幅にノイズを加え，そのノイズの大きさと出力の変化の相関を計算することにより，識別器の挙動を明らかにする方法である Input-perturbation network-prediction correlation map (IPNPCM 法) を提案した [Schirrmeister 17]．この方法は，振幅レベルでモデルの挙動を可視化できる．しかし，この方法は，波の振幅の大きさの変化とそれに伴う識別器の出力の変化の関係が線形である度合いを計算するものであり，これらの非線形な関係や他の変数との交互作用を考慮していないため，厳密な識別根拠を示すことは難しい．

3. 提案手法

各電極で計測された波をバンドパスフィルタにより任意の周波数帯ごとに分け，それぞれのバンドパスされた波を FFT により，さらに振幅成分と位相成分に分けたものを特徴とし，SSV によりそれぞれの特徴の貢献を求め，識別根拠を明らかにする手法を提案する．また，その計算量を削減する方法も提案する．図 1 のように，脳波識別の根拠を説明する方法には三つのレベルがあり，センサレベルのような低いレベルでの説明では，波を周波数帯ごとに分けないため，特徴の数は比較的少ない．また，低いレベルでの説明で識別に貢献していないと判断された特徴については，それをさらに詳細にした高いレベルでの説明においても貢献は低いと考えられる．そこで，まずセンサレベルで SSV を計算し，貢献の小さいセンサを除いて周波数帯レベルで SSV を計算し，さらに，貢献の小さい周波数帯を取り除き，最後に振幅・位相レベルで SSV を計算するという階層的な手法を提案する．このように，一度に貢献を計算する特徴の数 n を減らすことで，計算量を大きく削減できることが期待される．

4. 実験

4.1 データセット

二つの公開データセットを用いて提案手法の有効性を示す．

一つ目のデータセットは，PhysioNet で公開されている睡眠ポリグラフデータセットである [Goldberger 00]．このデータセットは，健常な成人男性 10 名，成人女性 10 名の計 20 名の 1〜2 晩分の睡眠データを 100Hz のサンプリング周波数で計測したものであり，30 秒を 1 エポックとしている．このデータセットには，Fpz-Cz と Pz-Oz に配置された電極から得られた脳波データや眼電データ (EOG) など，および，それらのデータに対する睡眠段階を Wake (W) , REM (R) , N1, N2, N3 に分類したラベルデータが付与されている．これらの睡眠段階は，脳波や EOG などに基づいて決められている．例えば，ラベルが N3 である基準は，2Hz 以下の低周波活動の振幅が 75μV 以上である状態が 1 エポック中で 20%以上続くことである．そのため，N3 についての識別においては，低周波活動の振幅に貢献が大きくなることが予想される．

二つ目のデータセットは UCI Machine Learning Repository で公開されている EEG Database である [Asuncion 07]．このデータセットは 256Hz-64 チャンネル脳波計で，被験者に視覚刺激を提示した際の 1 秒分の脳波を計測したものである．被験者は 122 人であり，その内 77 人はアルコール中毒であり，45 人は健常である．

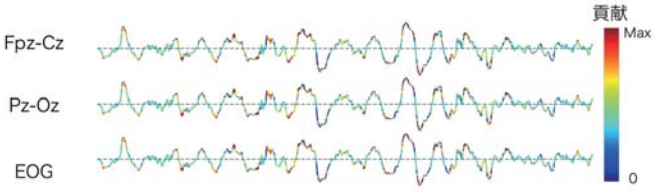


図 2: IG による識別根拠の可視化結果

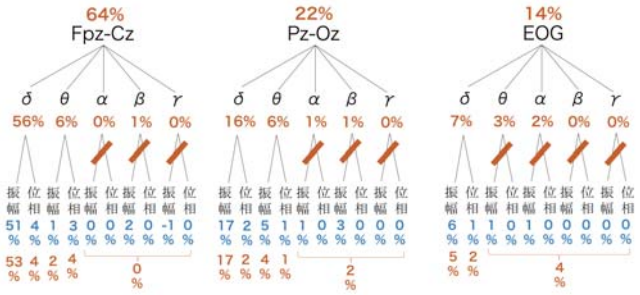


図 3: 提案手法による識別根拠の説明．青は SSV による貢献の推定，オレンジは提案法による貢献の推定の結果を表す

4.2 実験設定

PhysioNet のデータセットについては，3 層の畳み込み層と 1 層の全結合層を持つ識別モデルで睡眠段階を 5 クラス分類した．10 分割交差検証でのテストデータの識別率は約 81%であった．この識別器を用いて，ランダムに選ばれた N3 クラスの一つのデータについて IG [Sundararajan 17] と提案手法により識別根拠を求めた．また，提案手法による計算量の削減量と近似誤差を評価するために，ランダムに選ばれた 30 データに対して，SSV を各特徴に対して 1000 回サンプリングしたものを貢献の真値として，その真値と提案手法による推定値との差の絶対値を各データに対して 10 回ずつ計算した．今回，モンテカルロサンプリングの回数を {5, 10, 20, 50, 100, 200, 500} のいずれかに設定し，これらの回数に対する手法の性能を評価した．なお，貢献の値が最大値の 1/5 以下の場合に，それ以下のレベルの貢献は計算しないようにした．

UCI のデータセットについても同じく，3 層の畳み込み層と 1 層の全結合層を持つ識別モデルを用いて，アルコール中毒の有無について 2 クラス分類した．10 分割交差検証でのテストデータの識別率は約 75%であった．なお，電極位置が標準 10-20 法にはない 3 チャンネル (X, Y, nd) については位置が不明のため，使用していない．IPNPCM 法 [Schirrmeister 17] と提案手法を，ランダムに選ばれた一つのデータに対して適用した．

なお，どちらの実験においても，周波数帯の区分を，δ 波 <2Hz <θ 波 <7Hz <8Hz <α 波 <13Hz <β 波 <30Hz <γ 波とした．なお，どちらの識別器も畳み込み層はそれぞれのセンサで記録された波を時間方向に畳み込み，空間方向へは畳み込まないため，識別器の構成上，空間的な情報である位相特徴の貢献は低くなると考えられる．

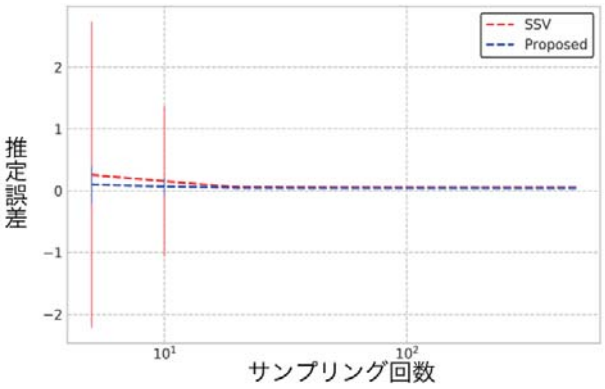


図 4: 提案手法と SSV による推定誤差の平均．エラーバーは標準偏差を示す．

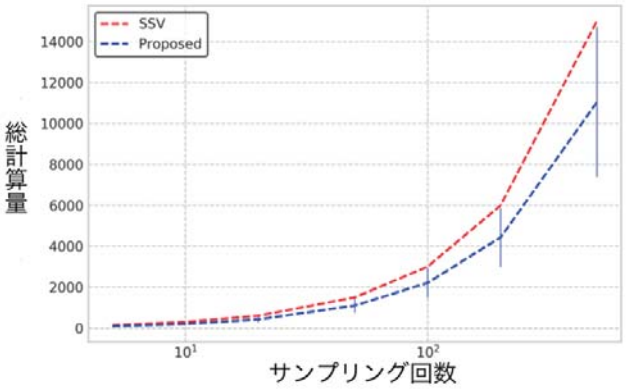


図 5: 提案手法と SSV による計算量の平均．エラーバーは標準偏差を示す．

4.3 実験結結果

睡眠ポリグラフデータセットでの識別について，図 2 に従来手法である IG により識別根拠を可視化した結果を，図 3 に提案手法による結果を示す．IG による可視化では信号の何が識別に貢献しているのかが，直感的にわからず，さらなる解析が必要であるといえる．提案手法では δ 帯の振幅特徴に着目していたことが定量的に示されている．また，この結果は 4.1 節で述べたクラス N3 の定義（低周波の振幅）と整合しており，この識別根拠が正しいことを示す．次に，この課題における SSV と提案手法の比較結果を図 4 と図 5 に示す．これらの図より，提案手法は少ないサンプリング回数で，より正確に貢献の値を推定できていることがわかる．

EEG Database での識別について，図 6 に IPNPCM 法 [Schirrmeister 17] による可視化結果を，図 7 に提案手法による可視化結果を示す．なお，提案手法において，負の貢献を持つ特徴は，そのクラスの識別関数の値を下げることで識別に貢献する．IPNPCM 法は，ほとんどの特徴に 1 か -1 かの極端な値を与えていることに対して，提案手法は特定の特徴に大きな貢献を与えている．これにより，一部の脳領域における θ 帯域の振幅が識別に特に大きく貢献していることがわかる．

5. 結論

本稿では，脳波を周波数帯ごとに分解し，それぞれの波を FFT により振幅成分と位相成分に分解したものを特徴とし，SSV によりそれぞれの特徴の識別への貢献を定量的に求める方法を提案した．それによって，脳波識別における識別根拠を従来手法よりも直感的に，かつ，定量的に示すことができた．また，脳波特徴の階層性を利用した枝刈りにより SSV の計算量を削減する方法を提案し，実際の脳波データを用いた実験により，SSV による推定と比べて，より少ない計算量でほとんど誤差なく推定可能であることを示した．

謝辞

本研究の一部は国立研究開発法人科学技術振興機構 (JST) の研究成果展開事業「センター・オブ・イノベーション (COI) プログラム」の支援によって行われた．

参考文献

[Ancona 17] Ancona, M., Ceolini, E., Öztireli, C., and Gross, M.: A unified view of gradient-based attribution methods for Deep Neural Networks, *arXiv preprint arXiv:1711.06104* (2017)

[Asuncion 07] Asuncion, A. and Newman, D.: UCI machine learning repository (2007)

[Goldberger 00] Goldberger, A. L., Amaral, L. A., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., Mietus, J. E., Moody, G. B., Peng, C.-K., and Stanley, H. E.: Physiobank, physiotoolkit, and physionet, *Circulation*, Vol. 101, No. 23, pp. e215–e220 (2000)

[Lundberg 17] Lundberg, S. M. and Lee, S.-I.: A unified approach to interpreting model predictions, in *Advances in Neural Information Processing Systems*, pp. 4768–4777 (2017)

[Schirrmeister 17] Schirrmeister, R. T., Springenberg, J. T., Fiederer, L. D. J., Glasstetter, M., Eggensperger, K., Tangermann, M., Hutter, F., Burgard, W., and Ball, T.: Deep learning with convolutional neural networks for EEG decoding and visualization, *Human Brain Mapping*, Vol. 38, No. 11, pp. 5391–5420 (2017)

[Shapley 53] Shapley, L. S.: A value for n-person games, *Contributions to the Theory of Games*, Vol. 2, No. 28, pp. 307–317 (1953)

[Štrumbelj 14] Štrumbelj, E. and Kononenko, I.: Explaining prediction models and individual predictions with feature contributions, *Knowledge and Information Systems*, Vol. 41, No. 3, pp. 647–665 (2014)

[Sturm 16] Sturm, I., Lapuschkin, S., Samek, W., and Müller, K.-R.: Interpretable deep neural networks for single-trial EEG classification, *Journal of Neuroscience Methods*, Vol. 274, pp. 141–145 (2016)

[Sundararajan 17] Sundararajan, M., Taly, A., and Yan, Q.: Axiomatic attribution for deep networks, *arXiv preprint arXiv:1703.01365* (2017)

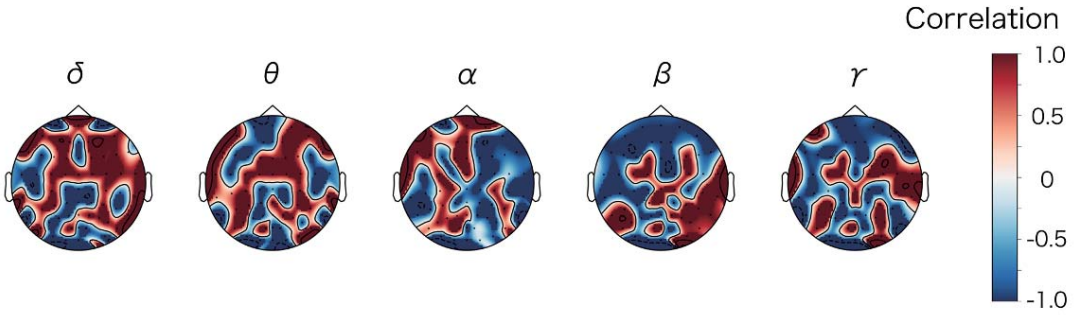


図 6: IPNPCM 法 [Schirrmeister 17] による識別根拠の可視化結果

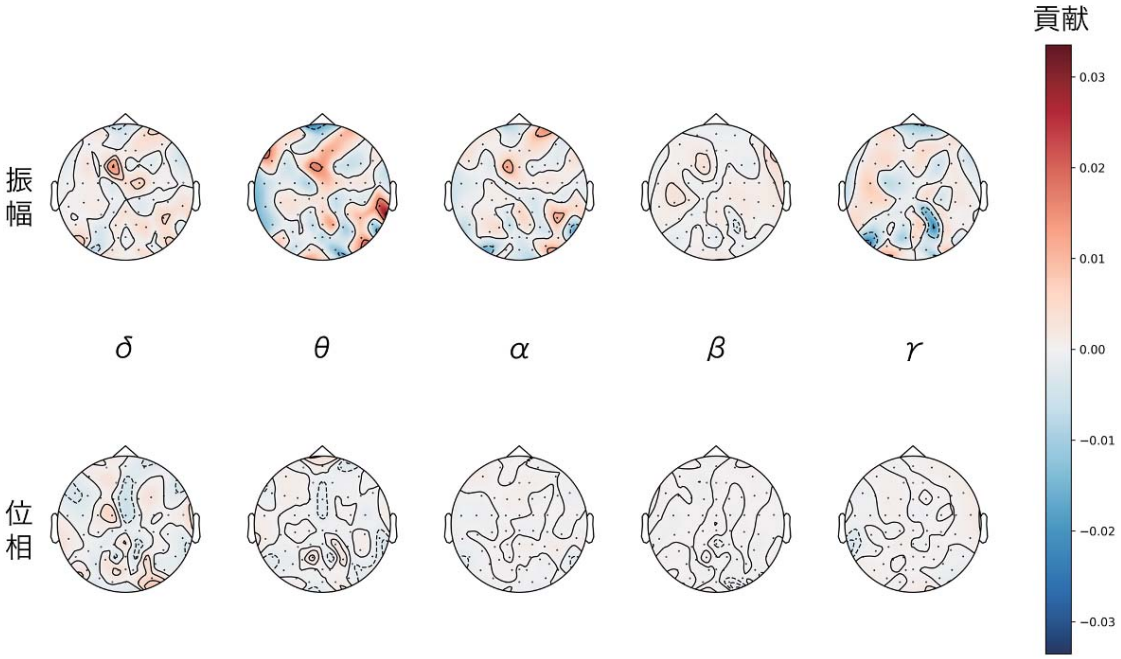


図 7: 提案手法による識別根拠の可視化結果

[Zhang 18] Zhang, Q. and Zhu, S.-C.: Visual Interpretability for Deep Learning: a Survey, *arXiv preprint arXiv:1802.00614* (2018)

[1N3] [General Session] 2. Machine Learning

座長:松井 藤五郎（中部大学）

Tue. Jun 5, 2018 5:20 PM - 7:00 PM Room N (2F Sakurajima)

[1N3-01] Excluding the Data with Exploration from Supervised Learning Improves Neural Fictitious Self-Play

○Keigo Kawamura[1], Jun Suzuki[2,3], Yoshimasa Tsuruoka[4] （1. Graduate School of Engineering, The University of Tokyo, 2. NTT Communication Science Laboratories, NTT Corporation, 3. RIKEN Center for Advanced Intelligence Project, 4. Graduate School of Information Science and Technology, The University of Tokyo）

5:20 PM - 5:40 PM

[1N3-02] Estimation of a non-linear reward function using score-based inverse reinforcement learning

○Natsumi Watanabe[1], Gakuto Masuyama[2], Kazunori Umeda[1] （1. Chuo University, 2. Meijo University）

5:40 PM - 6:00 PM

[1N3-03] Toward satisficing in general reinforcement learning

○Kuniaki Satori[1], Yutaka Yoshida[1], Kenta Yamagishi[1], Yuya Ushida[2], Takumi Kamiya[2], Tatsuji Takahashi[1] （1. Tokyo Denki University, 2. Graduate School of Tokyo Denki Univerity）

6:00 PM - 6:20 PM

[1N3-04] Hybird Learning Using Profit Sharing and Genetic Algorithm -Task Division Performance in MDP Environments-

○Kohei Suzuki[1], Shohei Kato[1,2] （1. Nagoya Institute of Technology, 2. Frontier Research Institute for Information Science, Nagoya Institute of Technology）

6:20 PM - 6:40 PM

[1N3-05] Inverse Reinforcement Learning with BDI Agents for Pedestrian Behavior Simulation

○Nahum Alvarez[1], Itsuki Noda[1] （1. The National Institute of Advanced Industrial Science and Technology (AIST)）

6:40 PM - 7:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

Neural Fictitious Self-Play における探索由来のデータを含めない教師あり学習による性能改善

Excluding the Data with Exploration from Supervised Learning Improves Neural Fictitious Self-Play

河村 圭悟 *1　鈴木 潤 *2*3　鶴岡 慶雅 *4
Keigo Kawamura　Jun Suzuki　Yoshimasa Tsuruoka

*1東京大学大学院工学系研究科
Graduate School of Engineering, The University of Tokyo

*2NTT コミュニケーション科学基礎研究所
NTT Communication Science Laboratories, NTT Corporation

*3理化学研究所 革新知能統合研究センター
RIKEN Center for Advanced Intelligence Project

*4東京大学大学院情報理工学系研究科
Graduate School of Information Science and Technology, The University of Tokyo

Neural fictitious self-play (NFSP) is a method for solving imperfect information games. While methods developed in recent years such as counterfactual regret minimization or DeepStack require the state transition rules of the games, NFSP works without them. In this paper, we propose to exclude the exploration data from the supervised learning component in NFSP and keep the probability of exploration, in order to explore without breaking the average strategy. We show that this change significantly improves the performance of NFSP in a simplified poker game, Leduc Hold'em, and compare the results for different exploration probabilities.

1. はじめに

人工知能分野の研究対象として，ゲーム AI が盛んに用いられている．その理由の一つは，実世界の問題に初めから人工知能の技術を適用しても実世界の問題が複雑すぎて技術の到達点（マイルストーン）を評価するのが困難となるため，行動の制約や報酬などのルールが厳密に定められたゲームにおいて技術を確立し，徐々に複雑なゲーム設定へと対象を移行することで，技術を効果的に高めていくためである．従って，現実の問題設定により近い不完全情報ゲームを対象とし，高い性能を発揮するプレイヤを作ることができれば，実問題への人工知能技術の応用の可能性を大きく進展できると考えられる．

不完全情報ゲームの文脈では，Texas Hold'em というポーカーゲームがよく題材として用いられる．Bowling らは，Texas Hold'em のベット額を制限した heads-up limit Texas Hold'em (HULHE) の解を，counterfactual regret minimization+ (CFR+) [Tammelin 14] という手法を用いて求めることに成功した (essentially weakly solved) [Bowling 15]．また，Moravčík らは，相手の手を仮定した時の最終的な期待報酬をニューラルネットワークで予測して CFR+を用いる DeepStack [Moravčík 17] というアルゴリズムを提案し，HULHE より複雑なゲームである heads-up no-limit Texas Hold'em (HUNL) においてプロのポーカープレイヤに勝利した．ほぼ同時期に，Brown らは，抽象化したゲームを探索して相手の手に応じて部分ゲームを生成し CFR+を用いて解くことで戦略を得る，nested subgame solving と呼ばれるアルゴリズムを提案し，このアルゴリズムを用いた AI である Libratus は HUNL においてプロのポーカープレイヤに勝利した [Brown 17]．

これらのアルゴリズムは，いずれもゲームの木を探索することで戦略を求める手法である．したがって，これらの手法を適用するには，agent があらかじめゲームの内容や状態遷移規則を全て知っておく必要がある．しかしながら，実世界の問題を解く場合には，環境の状態遷移規則が初めからわかっているという状況は考えにくく，未知の環境と相互作用しながら agent が状態遷移規則を把握していくような設定で問題を解くことができる手法が望まれる [河村 17]．

Heinrich らは，不完全情報ゲームで古くから用いられてきた Fictitious Play (FP) [Brown 51] と呼ばれる手法に強化学習の手法を応用して，ゲームの状態遷移規則を知ることなくゲームの解を求める Neural Fictitious Self-Play (NFSP) と呼ばれる手法を提案した [Heinrich 16]．この手法は，従来標準型ゲーム (Normal Form Game) で表現されたゲームにしか用いることができなかった FP を，展開型ゲーム (Extensive Form Game) で表現されたゲームにも適用できるようにした Fictitious Self-Play (FSP) と呼ばれる手法 [Heinrich 15] に，ニューラルネットワークを用いた教師あり学習と，ニューラルネットワークを Q 学習に応用した Deep Q-Network (DQN) [Mnih 15] を用いたものである．NFSP は，HULHE において事前の抽象化や簡略化といった前提知識を用いることなく既存のプレイヤに匹敵する性能が得られることが知られている．

本研究では，NFSP の教師あり学習が最適応答戦略の平均戦略を計算することを意図していることに着目し，教師あり学習の学習データに探索で得たデータを含めないようにすることで，NFSP の性能を向上させることができることを実験的に示す．

2. 関連研究

2.1 標準型ゲームと展開型ゲーム

標準型ゲームと展開型ゲームは，どちらも不完全情報ゲームを記述するモデルである．

展開型ゲームは木構造に基づく表現方式で，木のノードにあたる状態 s，各状態 s に対するターンプレイヤ $p \in P \cup \{c\}$，木のエッジにあたる行動 a がある．ここで，P はゲームプレイヤの集合を表しており，プレイヤのターンではそのプレイヤが行動の意思決定を行う．また，c は偶然手番を表しており，

連絡先: 河村圭悟，東京大学大学院工学系研究科電気系工学専攻，kkawamura@logos.t.u-tokyo.ac.jp

偶然手番では行動は各状態に対して事前に定まっている確率分布 $f(s)$ に従って生起する．木のリーフにあたる終端状態 z にゲームが到達すると，各プレイヤは報酬 $r_p(z)$ を得る．不完全情報ゲームでは，同じ状態であってもプレイヤによって観測できる情報が異なる．プレイヤ p から見て区別できないノードの集合を情報集合 I_p と呼ぶ．

展開型ゲームにおけるプレイヤ p の振る舞いは，p がターンプレイヤであるような任意の情報集合 I_p に対して行動集合 A 上の確率分布を与える関数 $\sigma_p(I_p)$ によって定まる．この関数を**戦略** と呼ぶ．各プレイヤの戦略の組み合わせ $\sigma = \sigma_1, \cdots, \sigma_N$ は戦略プロファイルと呼ばれる．プレイヤ p の期待報酬は戦略プロファイルに依存し， $r_p(\sigma)$ で表される．プレイヤ p 以外の戦略 σ_{-p} を固定したとき，期待報酬を最大化するような戦略 $\underset{\sigma_p}{\operatorname{argmax}}\, r_p(\sigma_p, \sigma_{-p})$ を σ_{-p} に対する **最適応答戦略** と呼び， $b_p(\sigma_{-p})$ で表す．どのプレイヤも，自身の戦略が自身以外の戦略に対する最適応答戦略になっているとき，その戦略プロファイルは **ナッシュ均衡戦略** であるという．

一方，標準型ゲームではこのような木構造を用いずにゲームを表現する．標準型ゲームでは，プレイヤ $p \in P$ はいくつかの**純粋戦略** a_p^N を持っており，各プレイヤが同時にどれか 1 つの純粋戦略を選択することでゲームが行われ，選択された純粋戦略の組み合わせに応じて各プレイヤは報酬 $r_p^N\left(\left\{ a_{p'}^N \mid p' \in P^N \right\}\right)$ を得る．各純粋戦略は，展開型ゲームにおいて戦略を決定的な (いずれかの行動のみが確率 1 で選択されるような) 確率分布にしたものに相当する．標準型ゲームでは，純粋戦略上の確率分布を**混合戦略**と呼び， σ_p^N で表す．標準型ゲームにおいても，展開型ゲームと同様に最適応答戦略，ナッシュ均衡戦略などを定義することができる．

2.2 Neural Fictitious Self-Play

FP は，標準型ゲームのナッシュ均衡戦略を求めるアルゴリズムである．FP では，最適応答戦略を用いて，混合戦略を

$$\sigma_{p,t+1}^N \leftarrow \frac{t}{t+1}\,\sigma_{p,t}^N + \frac{1}{t+1}\,b_p^N\left(\sigma_{-p,t}^N\right) \qquad (1)$$

と更新する．すなわち，各時刻の最適応答戦略を平均するように混合戦略を更新する．このアルゴリズムは，2 人零和ゲームなどいくつかの条件でナッシュ均衡戦略に収束することが示されている．

FSP は，FP を展開型ゲームでも適用できるようにし，さらに関数近似を用いて大きなゲームにも適用できるようにしたアルゴリズムである．標準型ゲームにおける混合戦略 σ_p^N と展開型ゲームにおける戦略 σ_p は，表現方法は異なるものの，不完全情報ゲームにおけるプレイヤの振る舞いを表しているという点では同じである．そこで，混合戦略 σ_p^N と戦略 σ_p が同じ振る舞いを示しているとき，σ_p^N と σ_p を実現等価であるという．ここで，戦略 σ_1 と σ_2 が同じ振る舞いを示すとは，任意の状態 s に対して，他のプレイヤ $-p$ が s に到達するように行動を選択した場合に状態 s に到達する確率 $x(s)$ が，プレイヤ p が σ_1 に従った場合と σ_2 に従った場合で等しいことを指す．この概念を用いて，FP のプロセスを展開型ゲームでの実現等価なプロセスに置き換えたのが Extensive-form Fictitious Play (XFP) [Heinrich 15] である．FSP ではさらに，XFP のプロセスが最適応答戦略を求めることと平均戦略を求めることの 2 つに分けられることに着目し，最適応答戦略を求める部分を強化学習で，平均戦略を求める部分を教師あり学習で近似している．これによって，XFP におけるすべての情報集合における確率分布を保持・更新しなければならないという問題点を解消し，かつ最新の機械学習のアルゴリズムを適用することができるようになっている．

FSP は特定の機械学習の手法に依存しない汎用的なアルゴリズムであるが，ここにニューラルネットワークによる強化学習・教師あり学習を適用したのが NFSP である．また，NFSP では教師あり学習のサンプリング方法を改善するために，通常の circular replay buffer ではなく reservoir buffer を用いている．これによって，有限のメモリでもデータ全体から等確率でサンプリングして保持することができ，平均戦略の計算を効率よく行えるようになっている．

3. 提案手法

本研究では，NFSP の教師あり学習が最適応答戦略の平均戦略を計算することを意図していることに着目し，教師あり学習の学習データに探索で得たデータを含めないようにすることを提案する．

NFSP の強化学習では，相手プレイヤの戦略に対する最適応答戦略を求めるために，探索と活用を行っている．具体的には，NFSP では ε-greedy を用いている．すなわち，確率 ε でランダムな手を選択し，確率 $1-\varepsilon$ で Q 値が最大であるような手を確定的に選択する．

ε-greedy を用いた Q 学習では，学習中は探索を含めた方策に基いて行動する．しかし，Q 学習は方策オフ型の学習方式で，Q 値が示す値は行動方策ではなく greedy に行動を選択した場合の期待累積報酬なので，最適応答戦略としては探索を含まない greedy な戦略を用いるべきである．探索を含めた方策を最適応答戦略として用い，平均戦略の計算に含めてしまうと，これがノイズとなって戦略がナッシュ均衡から外れてしまうことが考えられる．

オリジナルの NFSP では，ε-greedy の ε を学習の進行に合わせて小さくしているため，学習が進むにつれて探索を含めた戦略が greedy な戦略に近づいていき，先述の問題は起こらない．しかしながら，NFSP で行われる自己対戦は対戦相手の戦略が学習の進行に応じて変化するため，通常の Q 学習と異なり探索を無くすことはできないと考えられる．例えばある時刻 t について，状態 s で行動 a_1 を取る価値が a_2 よりも低いとすると，強化学習が正しく機能していれば平均戦略の a_1 を選択する確率は 0 に近づいていく．ここで，対戦相手の戦略が変化し，a_2 の価値は変化しないまま a_1 の価値が a_2 よりも高くなった場合，そのことを学習するためには s において a_1 を選択しなければならない．しかし，ε が十分小さくなってしまった場合，もはや a_1 が選択されることはなく，最適応答戦略を正しく求めることができなくなってしまう．

これらの問題を同時に解決するためには，探索の確率 ε をある程度大きな値に保ちつつ，活用によって得られたデータのみを教師あり学習に与えればよい．もし探索を含めた方策が最適応答戦略になっているのであれば，探索によって得られたデータを教師あり学習に含めないことで，学習が遅くなってしまう．しかし，ε-greedy を用いた Q 学習では，探索を含めた方策は一般に最適方策にはなっていないので，このようなことは起こらないと考えられる．

以上を踏まえた提案手法の擬似コードを Algorithm 1 に示す．提案手法に関わる部分は太字で示している．

4. 実験

提案手法の有効性を検証するために，小規模な不完全情報ゲームである 2 人 Leduc Hold'em に対し，提案手法を含むいくつか

Algorithm 1 改良 NFSP

```
Γ is a game and N is the number of players
function NFSP(Γ)
    Initialize Π, Q, θ^Π, θ^Q, θ^Q', M^SL, M^RL
    for i = 1, 2, ··· , N do                    ▷ 各プレイヤについて
        Initialize M_i
    end for
    for iteration = 1, 2, ··· do
        ε ← ε(iteration)                                  ▷ ε の値
        for i = 1, 2, ··· , N do
            σ_i ← ε-greedy(Q) (確率 η) or Π (確率 1 − η)
        end for
        Initialize Γ
        repeat
            n ← turn player of Γ
            M_n.s ← M_n.s'
            observe state s* and M_n.s' ← s*
            Store M_n in M^RL    ▷ 無条件でデータを保存
            if M_n.IsGreedy then   ▷ greedy に行動している強化学習由来のデータのみ保存
                Store M_n in M^SL
            end if
            Periodically update θ^Q with M ∼ M^RL , θ^Q'
            Periodically update θ^Π with M ∼ M^SL
            Periodically update θ^Q' ← θ^Q    ▷ RL のターゲットを更新
            Sample action a by strategy σ_i
            Execute a on Γ
            M_n.a ← a
            M_n.IsGreedy ← IsGreedy   ▷ 強化学習でかつ greedy に行動している場合のみチェック
            Reward M_n.r ← 0 ▷ 終端状態以外では報酬 0
        until Γ is over
        for i = 1, 2, ··· , N do
            set M_i.r ▷ 終端では状態に従って報酬を与える
        end for
    end for
    return Π (s, a|θ^Π)
end function
```

の設定で戦略を求め，得られた戦略の可搾取量 (exploitability) を計算し比較した．

Leduc Hold'em は以下のようなゲームである [Southey 05]．まず，3 種類のカードを各 2 枚ずつ，計 6 枚用意する．各プレイヤに 1 枚ずつ配り，場に 1 枚伏せて置き，残りの 3 枚は使用しない．各プレイヤは自分のカードだけを見ることができる．また，各プレイヤは場代として 1 単位のチップを供託する．ターンプレイヤは，賭けるチップを増やすベットか，相手と同じ賭け額にするコールか，ゲームから降りるフォルドを選択できる．ただし，一度もベットされていない場合はコール・フォルドは選択できず，代わりに何もしないチェックを選択できる．いずれを選択してもターンが相手に移り，お互いがチェックを選択するか，どちらかがコール・フォルドを選択するまでこれを繰り返す．この一連の流れをベットラウンドという．フォルドが選択された場合，フォルドを選択しなかったプレイヤが賭けられていたすべてのチップを得てゲームが終了する．それ以外の場合，伏せてあった場のカードを公開してもう一度ベットラウンドを行う．それでもフォルドが選択されなかった場合，お互いのカードを公開し，役が強い方のプレイヤが賭けられていたすべてのチップを得てゲームが終了する．ここで，役はワンペアまたはハイカードである．つまり，場のカードと同じ種類のカードを持っているプレイヤがいればそのプレイヤが勝利し，そうでない場合は数字の大きいプレイヤが勝利する．ベット時に増やすチップは，1 回目のベットラウンドでは 2，2 回目のベットラウンドでは 4 である．また，1 ベットラウンドにつきベットは 1 人 1 回しか選択できない．

可搾取量は，戦略プロファイルがナッシュ均衡戦略にどれだけ近いかを定量的に評価できる指標で，2 人零和不完全情報ゲームでは以下のように計算できる [Johanson 11]．

$$\epsilon(\sigma) = \sum_{p \in \{1,2\}} r_p(b_p(\sigma_{-p}), \sigma_{-p}) \tag{2}$$

すなわち，可搾取量はその戦略から最大で 1 ゲームあたりどれだけ搾取できるかを表している．この値は常に非負で，この値が 0 であることと戦略 σ がナッシュ均衡戦略であることは同値である．また，この値が 0 に近いほど，その戦略プロファイルはナッシュ均衡戦略に近いと言える．可搾取量を計算するためにはゲーム木を全探索する必要があるため，大規模なゲームに対しては可搾取量を計算することはできない．そのため，本論文では Leduc Hold'em という比較的単純化されたゲームを対象とした．

本研究では，教師あり学習の学習データに強化学習の探索で得たデータを含めないようにすることで，性能を悪化させることなく継続的に探索が行えるようになる，という仮説を立てている．そのため，比較する実験設定として以下の 4 つを用意した．

A. 通常の NFSP．ε は学習とともに急激に減衰する．具体的には，$\varepsilon = \frac{0.06}{\sqrt{n}}$，$n$ は [Heinrich 16] における iteration (128 game steps)．

B. A. において，教師あり学習の学習データに強化学習の探索で得たデータを含めないようにしたもの（提案手法）．

C. A. において，ε を減衰させず，固定したもの．

D. B. および C.，すなわち，教師あり学習の学習データに強化学習の探索で得たデータを含めないようにし，さらに ε を固定したもの．

ε の固定値には 0.1 を用いた．それ以外のハイパーパラメータは [Heinrich 16] に従っている．

それぞれの設定について，10^7 ゲーム行った後の可搾取量を 5 回計測した平均値を表 1 に示す．ε が減衰する設定では通常の NFSP と提案手法に差はないが，ε を固定値にした場合，通常の NFSP では性能が大きく悪化するが，提案手法では性能が有意に改善することがわかる．これは，通常の NFSP では探索の結果も平均に含まれるため，一定確率で探索を行うような設定では平均戦略にノイズが入ってしまうが，提案手法ではそのようなことが起こらず，学習が進んでも探索を続けられるからであると考えられる．

また，性能に対する ε の影響を調べるため，$0.01, 0.02, 0.05, 0.1, 0.2, 0.5$ の 6 種類の ε に対して同様の実験を行った．その結果を図 1 に示す．

既存の設定では，ε を固定すると性能が大きく悪化し，その度合いが ε の増加に従うことがわかる．これは，既存の設定

表 1: 各設定における，10^7 ゲーム行った後の可搾取量の値．各設定につき 5 回ずつ実験を行い，その平均を記載している．通常の NFSP (A.) と比較して，有意水準 $\alpha = 0.01$ で有意に差があるものには † を付けている．

設定	可搾取量
A.	$(3.8 \pm 0.5) \times 10^{-2}$
B.	$(4 \pm 1) \times 10^{-2}$
C.	$(26.8 \pm 0.8) \times 10^{-2\dagger}$
D.	$\mathbf{(2.3 \pm 0.5) \times 10^{-2\dagger}}$

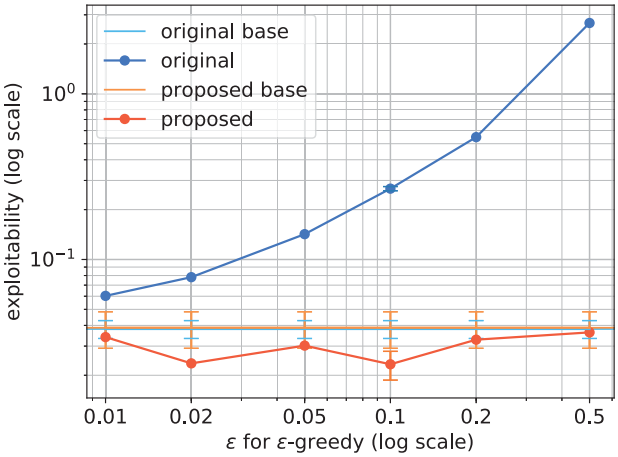


図 1: 各設定における，10^7 ゲーム行った後の可搾取量の値．名前に base が付く横線は，オリジナルの NFSP と同様，ε が急速に減衰する設定における結果を表している．$\varepsilon = 0.1$ の設定と ε が減衰する設定については 5 回ずつ実験を行った平均とその標準偏差を，それ以外のデータについては 1 回だけ実験を行った結果を表示している．

では探索の結果も平均戦略に含まれてしまうため，探索を行いすぎると性能が悪化する，という直感に即している．また，提案手法では，ε を固定すると性能が多少改善し，ε が 0.02 から 0.1 の間にある場合に特に性能に改善が見られるという大まかな傾向が見て取れる．これは，平均戦略の学習に探索を含めないため，探索を続けることで平均戦略の性能を落とすことなく最適応答戦略を正しく計算できるのではないかという直感に即している．ε が大きすぎる場合に性能が多少悪化するのは，活用で得られるデータが減少することで教師あり学習に学習させるデータの量が減ってしまい，教師あり学習の追従速度が低下するためであると考えられる．

5. おわりに

本研究では，NFSP の教師あり学習が最適応答戦略の平均戦略を計算することを意図していることに着目し，教師あり学習の学習データに強化学習の探索で得たデータを含めないようにすることで，性能を悪化させることなく継続的に探索が行えるのではないか，という仮説を立て，この手法によって NFSP の性能を向上させることができることを実験的に示した．

NFSP は，一般の不完全情報ゲームに対し強化学習を用いて事前知識のない状況から解くことができるという汎用的な手法である．今後も NFSP の性能を向上させる研究を続けるとともに，実際に NFSP を種々の大規模な不完全情報ゲームに対して適用することも行っていきたい．

参考文献

[Bowling 15] Bowling, M., Burch, N., Johanson, M., and Tammelin, O.: Heads-up limit hold'em poker is solved, *Science*, Vol. 347, No. 6218, pp. 145–149 (2015)

[Brown 51] Brown, G. W.: Iterative solution of games by fictitious play, *Activity analysis of production and allocation*, Vol. 13, No. 1, pp. 374–376 (1951)

[Brown 17] Brown, N. and Sandholm, T.: Superhuman AI for heads-up no-limit poker: Libratus beats top professionals, *Science* (2017)

[Heinrich 15] Heinrich, J., Lanctot, M., and Silver, D.: Fictitious Self-Play in Extensive-Form Games, in *Proceedings of ICML*, pp. 805–813, JMLR Workshop and Conference Proceedings (2015)

[Heinrich 16] Heinrich, J. and Silver, D.: Deep Reinforcement Learning from Self-Play in Imperfect-Information Games, *arXiv:1603.01121* (2016)

[Johanson 11] Johanson, M., Waugh, K., Bowling, M., and Zinkevich, M.: Accelerating Best Response Calculation in Large Extensive Games, in *Proceedings of the 22nd IJCAI - Volume 1*, pp. 258–265 (2011)

[Mnih 15] Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., Graves, A., Riedmiller, M., Fidjeland, A. K., Ostrovski, G., Petersen, S., Beattie, C., Sadik, A., Antonoglou, I., King, H., Kumaran, D., Wierstra, D., Legg, S., and Hassabis, D.: Human-level control through deep reinforcement learning, *Nature*, Vol. 518, pp. 529–533 (2015)

[Moravčík 17] Moravčík, M., Schmid, M., Burch, N., Lisý, V., Morrill, D., Bard, N., Davis, T., Waugh, K., Johanson, M., and Bowling, M.: DeepStack: Expert-level artificial intelligence in heads-up no-limit poker, *Science* (2017)

[Southey 05] Southey, F., Bowling, M., Larson, B., Piccione, C., Burch, N., Billings, D., and Rayner, C.: Bayes' Bluff: Opponent Modelling in Poker, in *Proceedings of the Twenty-First Conference on UAI*, UAI'05, pp. 550–558, Arlington, Virginia, United States (2005), AUAI Press

[Tammelin 14] Tammelin, O.: Solving Large Imperfect Information Games Using CFR+, *arXiv:1407.5042* (2014)

[河村 17] 河村 圭悟, 鈴木 潤, 鶴岡 慶雅：未知環境における多人数不完全情報ゲームの戦略計算, ゲームプログラミングワークショップ 2017 論文集, pp. 80–87 (2017)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

軌道のスコアに基づく逆強化学習を用いた非線形な報酬関数の推定

Estimation of a non-linear reward function using score-based inverse reinforcement learning

渡邉　夏美 *1　　増山　岳人 *2　　梅田　和昇 *1
Natsumi Watanabe　Gakuto Masuyama　Kazunori Umeda

*1中央大学　　*2名城大学
Chuo University　Meijo University

This paper presents a novel inverse reinforcement learning method, which estimates a reward function from arbitrary trajectories and their scores. Whereas standard inverse reinforcement learning methods query (near-) optimal demonstrations to an expert and estimate a linear reward function, our method 1) queries scores of arbitrary trajectories, and 2) estimates a non-linear reward function. Our method inherits a benefit of score-based inverse reinforcement learning enabling the expert to free him/herself from a burden to generate demonstration trajectories. The method also can estimate a non-linear reward function by introducing kernel function to score-based inverse reinforcement learning. We tested our method by a control task of a simulated robotic manipulator. The results demonstrate that our method estimates a non-linear reward function, from which reinforcement learner generate trajectories with a high score.

1. 緒言

強化学習とは，未知環境における試行錯誤的な行動学習の枠組みであり，ロボットによる自律的な制御則の学習などに利用される [1]．強化学習における学習者であるエージェントは，選択した行動に対する評価値である報酬を観測することで，行動の選択基準となる方策を学習する．設計者は報酬によってタスクを表現するため，エージェントが獲得する方策の性能は報酬によって変化する．しかし，多様で複雑な環境における報酬の設定は人手では困難であり，報酬の設定が適切でない場合エージェントによるタスクの達成は不可能である．

逆強化学習 [2, 3, 4, 5] では，目的のタスクを表現する真の報酬関数をエキスパートの演示から推定する．エキスパートは目的のタスクにおける熟練者であり，真の報酬関数に対する最適方策に従って振る舞うと仮定される．推定した報酬関数を用いて強化学習を行うことで，人手により報酬を設定することなく方策を学習することができる．しかし，適切な報酬関数の推定には，演示が目的のタスクにおいて最適であることがしばしば要求され，エキスパートにとって大きな負担となり得る．

また，一般的な逆強化学習では，特徴量の線形結合で表現される報酬関数を推定する．線形な報酬関数は特徴量の設定に強く依存するため，設計者はタスクの表現に有効な特徴量を設定する必要がある．また，特徴量に関する報酬の線形性により，複雑なタスクに対して表現能力が不足する場合がある．そこで，報酬関数の表現能力の向上を目的とし，推定する報酬関数を非線形化した逆強化学習が提案されている [6]．

本稿では，エキスパートによる最適な演示を不要とし，高い表現能力を有する報酬関数を推定可能な逆強化学習を提案する．提案手法では，軌道のスコアに基づく逆強化学習 [7] を拡張し，非線形化した報酬関数を推定する．軌道のスコアに基づく逆強化学習では，エキスパートに対し任意の軌道をクエリとして提示し，エキスパートが与える軌道のスコアから真の報酬関数を推定する．そのため，一般的な逆強化学習と異なりエキスパートによる演示が不要である．提案手法では，軌道のスコアに基づく逆強化学習と同様に，任意の軌道のスコアから回帰により報酬関数を推定する．また，カーネル関数を用いて報酬関数を非線形化することで，タスクに対する表現能力を向上する．

連絡先: 渡邉夏美，中央大学大学院理工学研究科精密工学専攻，〒 112-8551 東京都文京区春日 1-13-27，n.watanabe@sensor.mech.chuo-u.ac.jp

2. 軌道のスコアに基づく逆強化学習

Burchfiel らによる軌道のスコアに基づく逆強化学習（Distance Minimization Inverse Reinforcement Learning; DM-IRL）[7] では，任意の軌道とそれらに対してエキスパートが付与するスコアから，目的のタスクにおける真の報酬関数を推定する．スコアは，軌道が目的のタスクにおいてどの程度望ましいかを表す評価値であり，エキスパートによって与えられる．ここで，エキスパートによるスコアは真の報酬関数に従って決定されると仮定する．DM-IRL では，エキスパートに課される負担は軌道に対するスコア付与のみであり，最適な演示は不要である．

エージェントがとり得る状態の集合を S，選択し得る行動の集合を A とする．方策 $\pi : S \times A \mapsto [0, 1]$ をエージェントが状態 $s \in S$ において行動 $a \in A$ を選択する確率，$\boldsymbol{\phi} : S \times A \mapsto \mathbb{R}^k$ を状態 s において行動 a を選択したときの特徴量とする．また，DM-IRL における真の報酬関数 $R : S \times A \mapsto \mathbb{R}$ は，式 (1) に示すモデルで表され，特徴量に関して線形である．

$$R(s, a) = \boldsymbol{w}^{\mathrm{T}} \boldsymbol{\phi}(s, a) \tag{1}$$

したがって，ここでの報酬関数の推定は重み $\boldsymbol{w} \in \mathbb{R}^k$ の推定と等価である．

軌道は状態行動対の列であり，i 本目の軌道 $\tau_i = \{(s^i_0, a^i_0), \ldots, (s^i_{|\tau_i|-1}, a^i_{|\tau_i|-1})\}$ のスコア v_i は，軌道を通した報酬の累積和として式 (2) で定義される．

$$v_i = \sum_{t=0}^{|\tau_i|-1} \gamma^t R(s^i_t, a^i_t) \tag{2}$$

ただし，$\gamma \in [0, 1)$ は割引率である．式（1）を代入すると，v_i

は式（3）に書き換えられる．

$$v_i = \sum_{t=0}^{|\tau_i|-1} \gamma^t \boldsymbol{w}^{\mathrm{T}} \boldsymbol{\phi}(s_t^i, a_t^i) = \boldsymbol{w}^{\mathrm{T}} \sum_{t=0}^{|\tau_i|-1} \gamma^t \boldsymbol{\phi}(s_t^i, a_t^i) \quad (3)$$

r 本の軌道とそれらに対しエキスパートが付与したスコア $(\tau_1, v_1^*), \ldots, (\tau_r, v_r^*)$ が与えられたとき，式 (4) の線形回帰により重み $\boldsymbol{w}$ が推定される．

$$\hat{\boldsymbol{w}} = \underset{\boldsymbol{w}}{\operatorname{argmin}} \|M\boldsymbol{w} - \boldsymbol{v}^*\| \quad (4)$$

ただし，$\boldsymbol{v}^* \in \mathbb{R}^r$ は軌道のスコア $v_1^*, \ldots, v_r^*$ を要素とするベクトル，$M \in \mathbb{R}^{r \times k}$ は式（5）の行列である．

$$M = \begin{pmatrix} \sum_{t=0}^{|\tau_1|-1} \gamma^t \boldsymbol{\phi}(s_t^1, a_t^1)^{\mathrm{T}} \\ \vdots \\ \sum_{t=0}^{|\tau_r|-1} \gamma^t \boldsymbol{\phi}(s_t^r, a_t^r)^{\mathrm{T}} \end{pmatrix} \quad (5)$$

本稿で提案する逆強化学習では，DM-IRL と同様に，任意の軌道とそれらに対しエキスパートが付与するスコアから，回帰により報酬関数を推定する．ただし，DM-IRL では特徴量に関し線形な報酬関数を推定するのに対し，提案手法では非線形化した報酬関数を推定する．式 (1) の報酬関数をカーネル関数を用いて非線形化することで，タスクに対する表現能力の向上を図る．

3. 非線形な報酬関数の推定

状態 s において行動 a を選択したときの観測値を要素とするベクトルを $\boldsymbol{x} : S \times A \mapsto \mathbb{R}^l$ とする．本稿では，カーネル関数 $k(\boldsymbol{x}, \boldsymbol{x}^{(i)})$ を用いて，報酬関数を式 (6) で定義する．

$$R(\boldsymbol{x}) = \sum_{i=1}^{n} a_i k(\boldsymbol{x}, \boldsymbol{x}^{(i)}) = \boldsymbol{a}^{\mathrm{T}} \boldsymbol{k}(\boldsymbol{x}) \quad (6)$$

ここで，$\boldsymbol{x}^{(i)}$ は学習に用いる軌道 $\tau_1, \ldots, \tau_r$ に現れる n 個の観測値ベクトルである．また，$\boldsymbol{k}(\boldsymbol{x}) \in \mathbb{R}^n$ は $k(\boldsymbol{x}, \boldsymbol{x}^{(1)}), \ldots, k(\boldsymbol{x}, \boldsymbol{x}^{(n)})$ を要素とするベクトルである．カーネル関数を用いることで，特徴量を明示的に扱うことなく，特徴量に関し非線形な報酬関数を定義する．

ここでは，状態行動対の列 $\{(s_0^i, a_0^i), \ldots, (s_{|\tau_i|-1}^i, a_{|\tau_i|-1}^i)\}$ に対応する観測値の時系列を軌道 $\tau_i = \{\boldsymbol{x}_0^i, \ldots, \boldsymbol{x}_{|\tau_i|-1}^i\}$ とする．式 (2) と同様に，軌道のスコアを軌道を通した報酬の累積和として定義すると，軌道 τ_i のスコア v_i は式 (7) で表される．

$$v_i = \sum_{t=0}^{|\tau_i|-1} \gamma^t R(\boldsymbol{x}_t^i) = \sum_{t=0}^{|\tau_i|-1} \gamma^t \boldsymbol{a}^{\mathrm{T}} \boldsymbol{k}(\boldsymbol{x}_t^i) = \boldsymbol{a}^{\mathrm{T}} \sum_{t=0}^{|\tau_i|-1} \gamma^t \boldsymbol{k}(\boldsymbol{x}_t^i) \quad (7)$$

r 本の軌道とそれらに対しエキスパートが付与したスコア $(\tau_1, v_1^*), \ldots, (\tau_r, v_r^*)$ が与えられたとき，式 (8) の回帰により，式 (6) のパラメータ $\boldsymbol{a} \in \mathbb{R}^n$ を推定する．

$$\hat{\boldsymbol{a}} = \underset{\boldsymbol{a}}{\operatorname{argmin}} \|K\boldsymbol{a} - \boldsymbol{v}^*\| \quad (8)$$

ただし，$K \in \mathbb{R}^{r \times n}$ は式 (9) の行列である．

$$K = \begin{pmatrix} \sum_{t=0}^{|\tau_1|-1} \gamma^t \boldsymbol{k}(\boldsymbol{x}_t^1)^{\mathrm{T}} \\ \vdots \\ \sum_{t=0}^{|\tau_r|-1} \gamma^t \boldsymbol{k}(\boldsymbol{x}_t^r)^{\mathrm{T}} \end{pmatrix} \quad (9)$$

式（6）において，軌道 $\tau_1, \ldots, \tau_r$ で現れる観測値ベクトル $\boldsymbol{x}^{(1)}, \ldots, \boldsymbol{x}^{(n)}$ を全て用いた場合，n は非常に大きな値となる．学習に用いる軌道の長さが全て等しく $|\tau_i| - 1 = T$ であるとき，K の算出による計算量のオーダは $O(rnT)$ であり，連続値のタスクを扱う場合は現実的でない．そこで，軌道内に現れた観測値ベクトルをクラスタリングし，各クラスタの平均 $\bar{\boldsymbol{x}}_1, \ldots, \bar{\boldsymbol{x}}_m$ を代表値として用いる．

4. シミュレーション

提案手法の有用性を検証するため，物理シミュレータ MuJoCo[8] を利用した強化学習用インタフェース OpenAI Gym[9] による環境 Reacher を用いてシミュレーションを行った．Fig.1 のように，Reacher は 2 リンクマニピュレータの手先をターゲット位置に移動させる制御問題である．

提案手法，DM-IRL による推定報酬関数を用いて強化学習を行い，獲得した軌道をエキスパートによるスコアで評価した．

4.1 設定

マニピュレータのリンク i の関節角とその角速度，関節に加えるトルクをそれぞれ θ_i，$\dot{\theta}_i$，T_i とする．ただし，$i = 1, 2$ である．また，ターゲット位置の x 座標，y 座標をそれぞれ x_{target}，y_{target} とする．ターゲット位置は固定とし $x_{target} = 1.0$，$y_{target} = 1.0$，マニピュレータの初期状態は $\theta_i \sim \mathcal{U}(-\pi, \pi)$，$\dot{\theta}_i = 0$ とした．

状態 s はマニピュレータの関節角 θ_i，角速度 $\dot{\theta}_i$ とターゲット位置 x_{target}，y_{target}，行動 a は関節に加えるトルク T_i により定義される．シミュレーションで用いた観測値ベクトル $\boldsymbol{x}$（提案手法）と特徴量ベクトル $\boldsymbol{\phi}$（DM-IRL）は，式 (10) の通りである．

$$\boldsymbol{x} = \begin{pmatrix} \theta_1 \\ \theta_2 \\ \dot{\theta}_1 \\ \dot{\theta}_2 \\ x_{target} \\ y_{target} \\ T_1 \\ T_2 \end{pmatrix}, \quad \boldsymbol{\phi}(s, a) = \begin{pmatrix} \sin\theta_1 \\ \sin\theta_2 \\ \cos\theta_1 \\ \cos\theta_2 \\ \dot{\theta}_1 \\ \dot{\theta}_2 \\ x_{target} \\ y_{target} \\ d_x \\ d_y \\ T_1 \\ T_2 \end{pmatrix} \quad (10)$$

ただし，d_x，d_y はマニピュレータの手先とターゲット位置との x 方向，y 方向の距離であり，$\boldsymbol{x}$ とマニピュレータのリンク長から算出される．特徴量 $\boldsymbol{\phi}$ は gym における標準の特徴量に準拠して設定した．



Fig. 1 Simulator of a 2-link manipulator

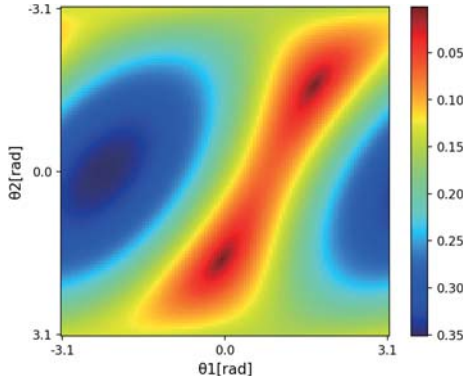


Fig. 2 A heatmap of distance to the target from the end-effector w.r.t. link angles

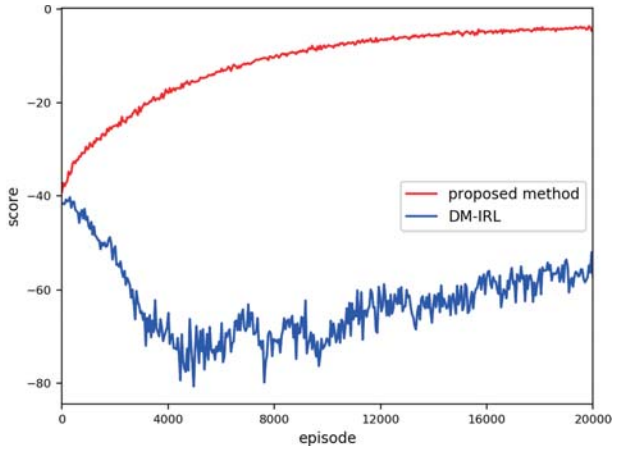


Fig. 3 Average score of each 50 episodes

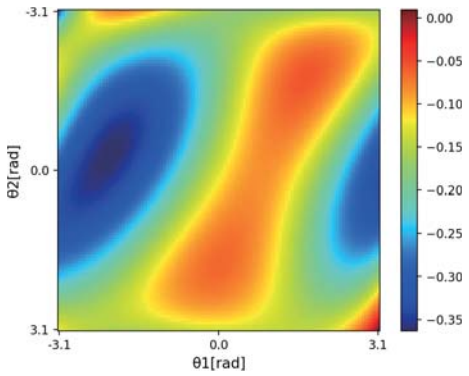
関節角に関する手先とターゲット位置との距離のヒートマップを Fig.2 に示す．Fig.1 におけるマニピュレータの関節角は，Fig.2 における右上の頂点に対応する関節角とほぼ等しい．

学習に用いる軌道 $\tau_1, \ldots, \tau_r$ は，ステップ数を 50 とし，各ステップにおいて各関節へのトルク入力 T_i を一様分布 $\mathcal{U}(-2.0, 2.0)$ からサンプルすることで生成した．軌道に対するエキスパートによるスコア $v_1^*, \ldots, v_r^*$ は式 (11) で定義した．

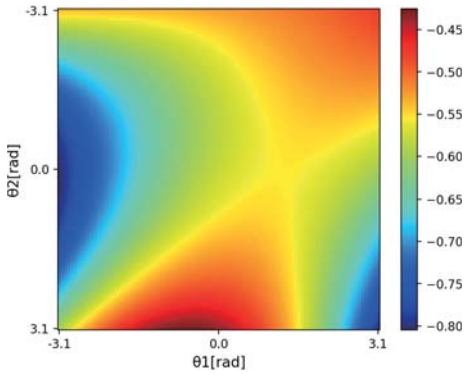
$$v_i^* = \sum_{t=0}^{|\tau_i|-1} \gamma^t \left(-\sqrt{{d_x^{(t)}}^2 + {d_y^{(t)}}^2} - ({T_1^{(t)}}^2 + {T_2^{(t)}}^2) \right) \quad (11)$$

ただし，$T^{(t)}$，$d^{(t)}$ はそれぞれステップ t におけるトルク，手先とターゲット位置との距離である．

式 (4)，(8) の回帰には最小二乗法を用い，提案手法におけるクラスタリングには K-Means を用いた．

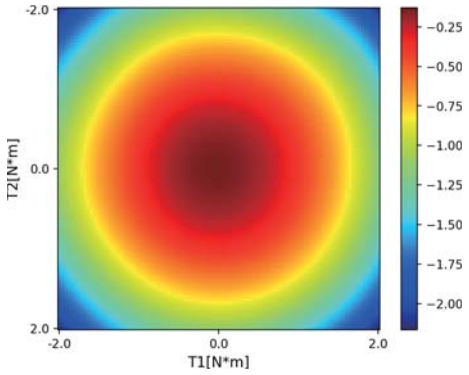


(a) Proposed method

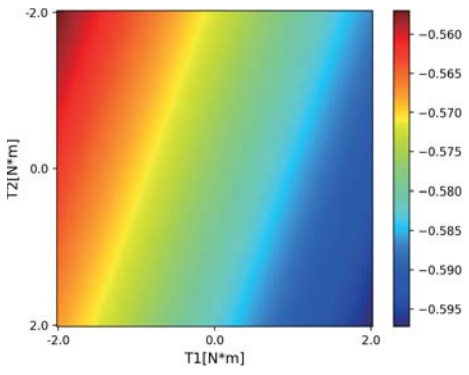


(b) DM-IRL

Fig. 4 Estimated reward function (link angles)



(a) Proposed method



(b) DM-IRL

Fig. 5 Estimated reward function (load torque)

学習に用いる軌道の本数を 2000 本とし，提案手法，DM-IRL により報酬関数を推定した．ただし，提案手法におけるクラスタリングはクラスタ数を 500 とした．続いて，推定した報酬関数を用いて強化学習を行い，式 (11) を用いて 50 エピソード毎の平均スコアを算出した．ここで，強化学習には Proximal Policy Optimization[10] を用い，エピソードのステップ数は 50 とした．

4.2 結果

推定した報酬関数を用いて行った強化学習における 50 エピソード毎の平均スコアの推移を Fig.3 に示す．提案手法では，エピソードの経過に伴いスコアが大きくなる様子が見てとれる．一方，DM-IRL による推定報酬関数を用いた場合，多数のエピソードを経てもスコアの向上は見られなかった．

また，$\dot{\theta}_i = 0$，$T_i = 0$ のときの関節角に関する推定報酬関数のヒートマップを Fig.4 に，$\theta_i = 0$，$\dot{\theta}_i = 0$ のときのトルクに関する推定報酬関数のヒートマップを Fig.5 に示す．それぞれ，(a) は提案手法，(b) は DM-IRL による推定報酬関数である．提案手法による推定報酬関数は，手先がターゲット位置付近に至る関節角において大きい値を示した．また，トルクに関しては T_1，T_2 が共にほぼ 0 となるときに最も大きい値を示した．これに対し DM-IRL では，トルクに関してはほぼ線形な報酬を示した．関節角に関しては，概形に Fig.2 との一定の類似性が見られるものの，提案手法と比べその類似性は小さい．

4.3 考察

報酬関数の推定にはランダムな方策から出力される軌道を用いたため，それらのスコアは必ずしも高くない．しかし，シミュレーションの結果から，提案手法により推定される報酬関数からは高いスコアで評価される軌道が生成可能であることが確認できたと考える．したがって，任意の軌道に対するスコアから，エキスパートが従う真の報酬関数と機能的に同等な報酬関数が推定可能であることが確認できた．

DM-IRL による推定報酬関数は特徴量の設定に依存するため，線形な報酬関数であっても有効な特徴量を用いればタスクを表現することができる．しかし，有効な特徴量の設計はタスクの複雑さに応じて困難になるため，カーネル関数により特徴量空間へ写像する提案手法は，複雑なタスクの達成において有用であるといえる．

5. 結言

任意の軌道のスコアから非線形な報酬関数を推定する逆強化学習を提案した．軌道に現れる観測値を入力とするカーネル関数を用いて報酬関数を非線形化することで，タスクに対する表現能力の向上を図った．マニピュレータの制御問題のシミュレーションにより，推定された報酬関数から学習された方策が高いスコアで評価される軌道を出力できることを確認した．

今後の展望として，クラスタリングに要する計算量の削減や学習に用いる軌道の生成方法の検討が挙げられる．

参考文献

[1] J. Kober, J. A. Bagnell and J. Peters, “Reinforcement Learning in Robotics: A Survey,” The International Journal of Robotics Research, Vol. 32, No. 11, pp. 1238–1274, 2013.

[2] A. Y. Ng and S. Russell, “Algorithms for Inverse Reinforcement Learning,” In Proceedings of the 17th International Confernce on Machine Learning, pp. 663–670, 2000.

[3] P. Abbeel and A. Y. Ng, “Apprenticeship Learning via Inverse Reinforcement Learning,” In Proceedings of the 21st International Confernce on Machine Learning, pp. 1–8, 2004.

[4] B. D. Ziebart, A. Maas, J. A. Bagnell and A. K. Dey, “Maximum Entropy Inverse Reinforcement Learning,” In Proceedings of the 23rd National Conference on Artificial Intelligence(AAAI’08), pp. 1433–1438, AAAI Press, 2008.

[5] A. Boularias, J. Kober and J. Peters, “Relative Entropy Inverse Reinforcement Learning,” In Proceedings of the 14th International Conference on Artificial Intelligence and Statistics, pp. 20–27, 2011.

[6] S. Levine, Z. Popović and V. Koltun, “Nonlinear Inverse Reinforcement Learning with Gaussian Processes,” In Proceedings of the 24th Advances in Neural Information Processing Systems, pp. 19–27, 2011.

[7] B. Burchfiel, C. Tomasi and R. Parr, “Distance Minimization for Reward Learning from Scored Trajectories,” In Proceedings of the 30th National Conference on Artificial Intelligence(AAAI’16), pp. 1–7, AAAI Press, 2016.

[8] E. Todorov, T. Erez and Y. Tassa, “MuJoCo: A physics engine for model-based control,” In Proceedings of Intelligent Robots and Systems, 2012 IEEE/RSJ International Conference on, pp. 5026–5033, IEEE, 2012.

[9] G. Brockman, V. Cheung, L. Pettersson, J. Schneider, J. Schulman, J. Tang and W. Zaremba, “OpenAI Gym,” arXiv preprint arXiv:1606.01540, 2016.

[10] J. Schulman, F. Wolski, P. Dhariwal, A. Radford and O. Klimov, “Proximal policy optimization algorithms,” arXiv preprint arXiv:1707.06347, 2017.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

満足化原理の強化学習全般への適用に向けて

Toward satisficing in general reinforcement learning

佐鳥 玖仁朗 *1 Kuniaki Satori　吉田 豊 *1 Yutaka Yoshida　山岸 健太 *1 Kenta Yamagishi　牛田 有哉 *2 Yuya Ushida　神谷 匠 *2 Takumi Kamiya　高橋 達二 *1 Tatsuji Takahashi

*1東京電機大学理工学部 School of Science and Engineering, Tokyo Denki University

*2東京電機大学大学院 Graduate School of Tokyo Denki Univerity

As the scope of reinforcement learning broadens, optimization becomes less realistic, and bounded rationality that considers the limitations in agents gets more important. Satisficing, the principal model of bounded rationality, models how people and animals explore and exploit. However, there is no efficient algorithm that represents satisficing can be applied to reinforcement learning in general. We apply our satisficing model, reference satisficing (RS) value function, and the global reference conversion (GRC) technique to the broader reinforcement learning tasks than in previous studies. In the three tasks we deal with in this study, RS and GRC work well, while there are some open problems for general reinforcement learning tasks.

1. はじめに

強化学習では, エージェントの試行錯誤を通じて未知の環境において収益を最大化する行動系列を学習する. 試行錯誤における環境の探索と知識の活用にはトレードオフが存在し, エージェントは両者のバランスを調整しながら学習を行うが, 実環境のような連続状態空間を扱う場合に適切な探索と知識活用を行うことは非常に困難である. 一方で人間は, 満足化原理 [Simon 56] と呼ばれるように, 現状が非満足であれば探索を行い満足であれば知識利用を行うように意思決定を行うことで, 探索空間の広大な未知の環境であっても目的とする基準を満たすような行動を可能としている. この満足原理を反映した意思決定手法として, 満足化価値関数 (reference satisficing: RS) が考案された. RS は多腕バンディット問題をはじめとした様々なタスクにおいて少数の探索で満足する行動系列を獲得でき, 基準値が適切であれば最適な行動系列を獲得できることがわかっている [高橋 16]. また, 状態が複数ある一般的な強化学習タスクでは各状態ごとに基準値が必要となるが, 未知の環境における各状態の基準値を推定することは非常に困難である. 一方で, タスク全体を通して得られる収益は既知であることも多く, タスク全体の期待収益に対する基準値を設定することで大局的な満足化度合いを定義しそれに対する各状態の基準値を動的に獲得する手法として大局基準変換法 (global reference convertion: GRC) が考案された [牛田 17a]. GRC を用いた RS(RS+GRC) は, 格子空間上に複数配置されたスイッチを決められた順番で押すことで報酬を獲得できるスイッチワールドタスクや運動制御課題で複雑なダイナミクスを有する大車輪タスクで, 一定以上の報酬を素早く獲得することに成功している [牛田 17b].

満足化原理は, 人間の意思決定・試行錯誤方策として重要視されながら, これまで強化学習全般に適用可能なアルゴリズムは存在していない. そこで本研究では, これまでに RS の性能と振る舞いを検証した諸タスクより一般的な強化学習の 3 タスクにおいて RS を用いる. 具体的には, 1 エピソード内で時間の経過によって報酬減衰して行くタスク, 確率的に報酬が変わるタスク, 負の報酬が与えられるタスクであり, それらのタスク対して GRC を適用することで, 様々な報酬関数に対する GRC の性質と GRC を用いた RS の適応可能性について議論する.

連絡先: 高橋達二, 東京電機大学理工学部, 埼玉県比企郡鳩山町石坂, Tel: 049-296-5416, tatsujit@mail.dendai.ac.jp

2. 満足化方策

人間の意思決定にはある基準値を定め, その値を超える行動を見つけるまで探索を行い, 発見した際は満足しその行動を選び続ける傾向が存在している. このような意思決定傾向は満足化と呼ばれ, 最良の行動を探索する最適化とは区別される. 満足化には, 複雑で最適化が困難な環境においても探索を打ち切る獲得報酬を基準として設けることで, 一定以上の報酬を獲得する行動系列を発見できる利点がある.

2.1 満足化価値関数 (RS)

RS は満足化に加え信頼性を考慮したアルゴリズムであり, 任意の状態行動対の行動価値関数を $Q(s_i, a_j)$, 任意の状態行動対とその後の信頼度を考慮した値を $\tau(s_i, a_j)$, 各状態に対する基準値を $R(s_i)$ として定義することで以下の式で算出される.

$$RS(s_i, a_j) = \tau(s_i, a_j)\Big(Q(s_i, a_j) - R(s_i)\Big) \quad (1)$$

$$\tau(s_i, a_j) = \tau_{\mathrm{curr}}(s_i, a_j) + \tau_{\mathrm{post}}(s_i, a_j) \quad (2)$$

各状態行動対の $\tau(s_i, a_j)$ はその対の訪問ごとに以下のように更新される.

$$\tau_{\mathrm{curr}}(s_t, a_t) \leftarrow \tau_{\mathrm{curr}}(s_t, a_t) + 1 \quad (3)$$

$$\tau_{\mathrm{post}}(s_t, a_t) \leftarrow \tau_{\mathrm{post}}(s_t, a_t) + \alpha_\tau\Big(\gamma_\tau(s_{t+1}, a_{t+1}) - \tau_{\mathrm{post}}(s_t, a_t)\Big) \quad (4)$$

このとき, γ_τ は未来信頼度割引率を表し, α_τ は信頼度学習率を表す. a_{t+1} は状態 s_{t+1} において選択する行動である. RS による評価値を最大化するような行動を選択する方策を満足化方策と呼ぶ.

3. 大局基準変換法 (GRC)

現実的なタスクにおいて, 各状態ごとの適切な基準値を推定することは困難である. 一方で, タスク全体を通して得られる収益は既知であることも多く, タスク全体の収益に対する適切な基準値の推定は可能である場合が多い. そこで, タスク全体を通しての基準値と現時点でのエージェントの達成度合いからタスク全体の満足度合いを求め, その値から各状態の基準値を求める手法である GRC が考案された. 以下に, GRC を用いた各状態の $R(s_i)$ の算出方法を示す.

まず, タスク全体の満足度合いを表すための達成度合いの更新式を定義する. 全体を通しての目標水準を大局満足化基準値 (global reference : R_G), それに対する大局観測期待値 (global expectation : E_G) と定義し, E_G はある期間 T_{tmp} ごとに消去, 再蓄積される一時的平均獲得報酬を用いて以下の式で更新される.

$$E_G \leftarrow \frac{E_{\mathrm{tmp}} + \gamma_G(N_G E_G)}{1 + \gamma_G N_G} \quad (5)$$

$$N_G \leftarrow 1 + \gamma_{N_G} \quad (6)$$

この E_G と報酬関数の設計に基づいてタスク設計者が与えた R_G との差 $R_G - E_G$ をタスク全体の満足化度合いとする.

各状態の満足化度合いは, 状態 s_i における最大の行動価値 Q を $\max Q(s_i)$ とした時, $\max Q(s_i) - R(s_i)$ で表される. E_G と行動価値 Q はスケールが異なるため, スケーリングパラメータ $\zeta(s_i)$ を導入し各状態に対してタスク全体の満足化度合いを適用する. 各状態の基準値 $R(s_i)$ は, 以下の式で算出する.

$$\delta_G = \min(E_G - R_G, 0) \quad (7)$$

$$\max Q(s_i) - R(s_i) = \zeta(s_i)\delta_G \quad (8)$$

$$R(s_i) = \max Q(s_i) - \zeta(s_i)\delta_G \quad (9)$$

RS+GRC は, スイッチワールドタスクや大車輪タスクで一定以上の報酬を素早く獲得することに成功している.

4. 報酬減衰グリッドワールド

報酬減衰グリッドワールドでは, 時間経過によって獲得可能な報酬が減衰する報酬関数に対して RS+GRC が適切な行動を獲得可能であるか検討する. 学習が最短経路の学習に対して行われたのではなく減衰の少ない報酬を得られる行動系列に対して行われたことを確認するため, 格子空間上に決められた位置のスタートと 4 つのゴールを配置した. エージェントは, 格子空間上の位置によって状態を識別し, 各状態で上下左右の隣接したマス目に進むために行動することができる.

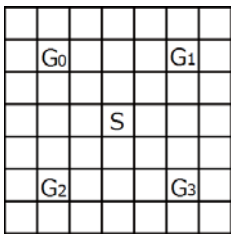


図 1: グリッドワールドタスクの設定

4.1 シミュレーションの設定

本タスクでは図 1 と同様の設定でシミュレーションを行った. 各ゴールの報酬は初期値が異なっており, エージェントがゴールへ到着すると初期値を到達ステップ数 t で割った $G_0 = 6/t, G_1 = 3/t, G_2 = 1/t, G_3 = 5/t$ が報酬として与えられる. また以降はマスの座標表現として, 格子空間を左上のマスを基準に横を x 座標, 縦軸を y 座標とてして座標 (x, y) と表現し, 実際にエージェントが通過したマスの系列を経路と呼ぶ. 格子空間は 7×7 の合計 49 マスで, エージェントは座標 $(3, 3)$ をスタートとして配置した. スタートから始まりゴールにたどり着くまでを 1 エピソードとして 1000 エピソードまで行い, 評価の指標として後悔を用いた. 強化学習タスクでは行動ではなく方策としての評価が必要であるため, 「最適経路を選び続けた場合の累計期待報酬と実際に選んだ経路の累計期待報酬の差」が後悔の定義となる.

アルゴリズムは代表的な強化学習アルゴリズムの Q 学習用いて, 学習率は $\alpha = 0.1$, 割引率は $\gamma = 0.9$ とした. エージェントの方策は, 検証方策である RS+GRC と, 比較方策として ϵ-greedy を用いた. 大局基準値 R_G は, 最短経路の 4 ステップで G_0 へ到達した際の収益である 1.5 を目指すため, その単位時間期待値として 0.375 に設定した. 大局割引率は $\gamma_G = 0.9$ とし, スケーリングパラメータ $\zeta(s_i)$ は経験的に良い成績を残した設定として全状態において一律に 1 とした. ϵ はエピソードごとに 1 から 1/600 ずつ減衰させ, 600 エピソード時点で $\epsilon = 0.0$ になるように設定した.

4.2 結果と考察

シミュレーションの結果として後悔の時間発展を図 2 に示す. ϵ-greedy は $\epsilon = 0$ になるエピソード数 600 以降で最適な経路を発見できずに後悔が増加し続ける結果となっている. ここで $\epsilon = 0$ になるまでのエピソード数を減らしても最適な経路を発見できる割合が減るのでさらに後悔が増え続ける傾きが大きくなる. 逆に $\epsilon = 0$ になるまでのエピソード数を増やしても最適な経路を発見できる割合が増えるので後悔の傾きが小さくなるが, 最適な経路を発見するまでの後悔が増えると考えられる. それに対し, 満足化アルゴリズム RS+GRC は ϵ-greedy より速く最適な経路を見つけ, 後悔も増えていない. この結果から RS+GRC は時間経過によって報酬減衰していくこのタスクに適応できたと言える. また ϵ-greedy より後悔が少なかったことよりこのタスクでは RS+GRC の有用性を示せた.

次にグリッドワールドタスクに GRC が適応できた理由は, ステップ数の増加によって獲得できる報酬が減って行くが, 1 エピソードで得られる最大報酬は決まっているので最大報酬から R_G が計算でき, E_G は R_G に収束し適応できた.

また, 時間の経過により報酬減衰するタスクでは, しないタスクと比べてゴールから得られる報酬がいつも最大とは限らないので, 最大報酬を与えるゴールでも辿り着くためのステップが多くかかったため得られる報酬が小さくなり, エージェントが他のゴールを選びやすくなってしまうような誤った学習をして局所解に陥りやすい. それに対して RS+GRC は, 最大報酬を学習していなければ図 3 のようにエピソード 500 あたりまでは E_G が R_G に達せず非満足状態となる (図 3 は 1 シミュレーションの E_G の時間発展を示したもの). そのため信頼度の影響により多く試行したものほど信頼度が低くなり, 試行回数が少ない行動の信頼度が高くなる. 非満足状態ではなるべく報酬が高いゴールへ行動しているが信頼度が低くなると探索を繰り返し E_G が R_G に収束するような最大報酬を見つけられると満足化した. そのため局所解に陥らず最適解を探索できたと考えられる.

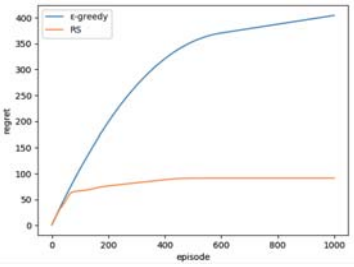


図 2: グリッドワールドの後悔の時間発展

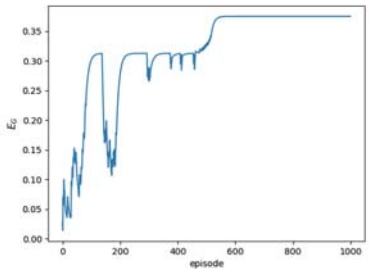


図 3: グリッドワールドの E_G の時間発展

5. ツリーバンディット

ツリーバンディットでは, 報酬が確率的に与えられる報酬関数に対して RS+GRC が適切な行動を獲得可能であるか検討する. 各状態では 4 本腕バンディットを行い, 選択した行動によって異なる状態へ遷移する. 層は全 2 層とし, $1+4$ の計 5 つの状態に対して最適な行動系列の獲得を目的とする.

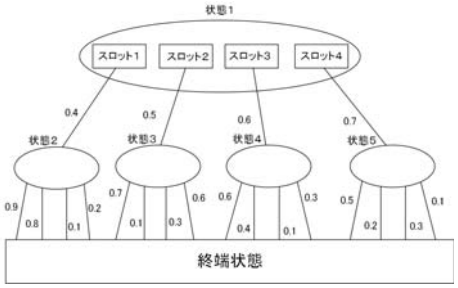


図 4: ツリーバンディットタスクの設定

5.1 シミュレーションの設定

報酬は報酬確率に従って, 0 または 1 とし, 報酬確率は図 4 と同様の値に設定した. 各層での行動選択を 1 ステップ, 終端状態である 2 層目の選択までを 1 エピソードとして 10000 エピソードまで行い, 評価の指標として後悔を用いた. アルゴリズムは代表的な強化学習アルゴリズムの Q 学習を用いて, 学習率は $\alpha = 1/n_j$, 割引率は $\gamma = 0.9$ とした. このとき n_j はその状態での行動の試行回数を意味する. エージェントの方策は, 検証方策である RS+GRC と, 比較方策として ϵ-greedy を用いた. 大局基準値 R_G は, 最適経路の期待累積収益 1.3 の単位時間期待値である 0.65 ではなく, 0.64 とした. 大局割引率は $\gamma_G = 1.0$ とし, スケーリングパラメータ $\zeta(s_i)$ は経験的に良い成績を残した設定として全状態において一律に 0.2 とした. ϵ はエピソードごとに 1.0 から 1/3000 ずつ減衰させ, 3000 エピソード時点で $\epsilon = 0.0$ になるように設定した.

5.2 結果と考察

シミュレーションの結果として後悔の時間発展を図 5 に示す. ϵ-greedy の結果は最終的にエピソード数が 3000 となった時点で最適な経路を発見できずに後悔が増加し続ける結果となっている. 一方, 満足化アルゴリズム RS+GRC は ϵ-greedy よりも後悔が少なく, 増加もしていない.

この結果より RS+GRC は確率的に報酬が変化する場合にも適用でき, ϵ-greedy よりも後悔が少なくこの確率的タスクにおいても有用性があるのではないかと考えられる.

ツリーバンディットに GRC が適応できた理由は, E_G と R_G の値を適切に設定できたからである. 報酬が確率的に与えられるタスクにおいては同じ腕を選んでも報酬が一定にもらえるわけではないので E_G は一定の値に収束することはなく R_G に近づきはするが R_G より大きくなったり小さくなったりと値が振れる. そのため最大報酬を取る腕を選んでいたとしても満足と探索を繰り返してしまう. ここで E_G の振り幅を小さくし, R_G の値の設定を E_G が振れる幅になるべく含まれていない値を設定する事により GRC が適応できる.

シミュレーションの設定では $\gamma_G = 1.0$ と $R_G = 0.64$ と設定していた. 理由は, γ_G とは大局割引率であり, 1 に近いほど E_G は昔の報酬も大きく考慮する値となり E_G の更新する変化量は小さくなる. また, 0 に近いほど E_G は直近の報酬を大きく考慮した値となり, 1 か 0 に近い値をとるので E_G の更新する変化量は大きくなる. 今回は E_G の更新する変化量を小さくしたいため 1 とした. その設定により E_G の値は全ての報酬の平均値となり探索した際の報酬も含まれるが, エピソード数が大きくなるたびに影響は小さくなり E_G は最大単位時間期待値に近づいていく.

次に R_G だが, 通常であれば期待収益の単位時間期待値である 0.65 に設定する. しかし, 報酬が確率的であり E_G が収束しないため. 最適値 0.65 に近くかつ次に良い値 0.6 で満足しない位置に設定することが望ましく, 0.64 とした.

この設定により GRC は報酬が確率的なタスクに適応できた. また, 報酬が確率的であっても E_G を最大単位時間報酬期待値へ収束させることができれば $R_G = 0.65$ に設定することでも今回のような結果が得られると考えられる.

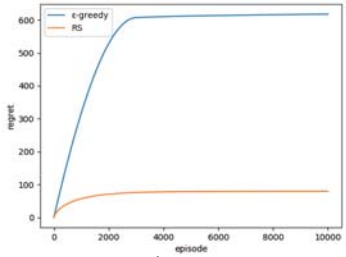


図 5: ツリーバンディットの後悔の時間発展

6. 崖歩き

崖歩きでは, 獲得報酬が負である報酬関数に対して RS+GRC が適切な行動を獲得可能であるか検討する. これまでの研究では負の報酬が与えられるタスクにおいて RS+GRC の動作の検証を行なって来なかった. GRC では E_G の更新にエピソードを通した累積獲得報酬を用いるため, 各状態ごとの基準 R に影響を与える. 崖歩きは強化学習におけるリスクを回避した最適な行動を獲得するタスクで, 格子空間上に崖を設置し崖マスに移動した際に大きな負の報酬を与える.

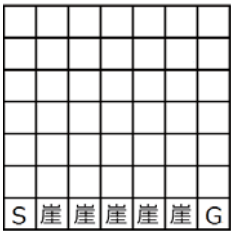


図 6: 崖歩きタスク

6.1 シミュレーションの設定

エージェントがゴールもしくは崖のあるマス目への行動を選択すると報酬が与えられ, エージェントはエピソード開始時の初期位置に戻る. 崖方向の報酬は大きな負の値として -100, ゴール方向への報酬は正の報酬として 1 を与えた.

格子空間は 7×7 の合計 49 マスで, エージェントの初期位置は座標 $(0, 6)$ に, ゴールの位置を座標 $(6, 6)$ に設定した. 崖の数は 5 マスとし, 図 6 のように配置した. 50 ステップを 1 エピソードとし, 50 エピソード行い, そのシミュレーションを 1000 回行なった結果を平均した. アルゴリズムは代表的な強化学習アルゴリズムの Q 学習を用いて, 学習率は $\alpha = 0.1$, 割引率は $\gamma = 0.9$ とした. エージェントの方策は, 検証方策である RS+GRC と, 比較方策として ϵ-greedy を用いた. 大局基準値 R_G は, 最適経路の期待累積収益 12.0 の単位時間期待値として 0.12 とした. 大局割引率は $\gamma_G = 0.9$ とし, スケーリングパラメータ $\zeta(s_i)$ は経験的に良い成績を残した設定として全状態において一律に 0.1 とした. ϵ はエピソードごとに 1.0 から 1/20 ずつ減衰させ, RS が最大報酬を獲得できる経路に収束する 20 エピソード時点で $\epsilon = 0.0$ になるように設定した.

6.2 結果と考察

シミュレーションの結果として後悔の時間発展を図 7 に示す. まず, 20 エピソードで ϵ が 0 になる ε -greedy 法の結果を

見る．この後悔は最初急激に増加し，その後一定の割合で増加し続けていることから，この時点で探索を打ち切ってしまうと，探索が足りないため最適な行動系列が発見できないことがわかる．一方で RS+GRC は ϵ-greedy 法よりも後悔を増加させずに早い段階で最適な行動系列を発見することができ，その有用性を示した．

RS+GRC が ϵ-greedy 法より高い成績を示した理由について，崖方向への行動は大きな負の報酬を与えられると，その行動の RS 値は一度の選択で急激に小さくなり再度選ばれることはなくなる．そのため崖方向への行動が選ばれなったことと，RS の信頼性を考慮した探索を行ったことが，結果後悔を $\epsilon-$greedy 法に比べ増やさなかったことに繋がったと考えられる．

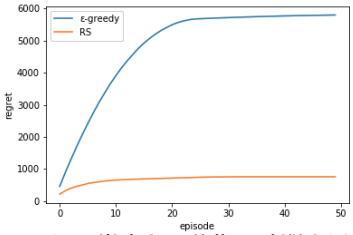


図 7: 崖歩きの後悔の時間発展

6.3 設定の変更

次に崖歩きタスクの設定を変更し，環境に状態が複数存在し，負の即時報酬が常に与えられるタスクでの挙動を確認する．そのために行動に対し常に移動コストとして負の報酬 -1 を与え続け，ゴールにたどりついたときに 0 の報酬を与えるように設定を変更したタスクでのシミュレーションを行う．また，このタスクではゴールにたどり着いた時にエピソードが終了するように設定を変更した．

格子空間や崖の配置は前タスク同様に図 6 のように設定をした．ゴールにたどり着くまでを 1 エピソードとし，300 エピソード行いそのシミュレーションを 1000 回行った結果を平均した．比較アルゴリズムは ϵ 減衰法の代わりに $\epsilon = 0$ の greedy 法を用いる．RS+GRC によるシミュレーションは，スケーリング変数 $\zeta(s_i)$ を $\zeta(s_i) = 1.0, 0.5, 0.1, 0.01$ の 4 つを用いて行なった．またこの際，$\zeta(s_i)$ は全状態に置いて一律に設定した．GRC に おける大局基準値 R_G には，1 エピソードにおいて最短の経路を通った場合における収益である -7 を目指すため，その単位時間期待値として $R_G = -0.875$ に設定した．大局割引率は $\gamma_G = 0.9$ とした．また，すべてのアルゴリズムにおいて学習率は $\alpha = 0.1$，割引率には $\gamma = 0.9$ を用いる．

6.4 結果と考察

シミュレーションの結果として後悔の時間発展を図 8 に示す．最初に greedy 法の結果をみると，後悔を序盤と中盤で伸ばすが，200 エピソード手前で最適な経路を発見することができている．これは，行動するたび常に一定の負の報酬が与えられるタスクにおいて，探索を十分な回数行った場合，最短経路の Q 値が最も小さくなりその経路を選ぶようになるためだと考えられる．次に $\zeta(s_i)$ を 1.0, 0.5, 0.1 に設定した RS の結果を見ると，最終的に最適な経路を発見できているが，他のアルゴリズムに比べ，後悔が大きくなっている．最後に $\zeta(s_i) = 0.01$ に設定した結果を見ると，最適経路を見つけることができているが，greedy 法と一致する結果となっている．この結果より，この設定のタスクでは RS+GRC は他のアルゴリズムに比べ，その有用性を示すことはできなかった．

次に，なぜ後悔が greedy 法と同じかそれ以上に蓄積されることに繋がったかを考える．RS+GRC においてスケーリング変数 $\zeta(s_i)$ はその値が適切なものより小さい場合，$Q(s_i)$ に差が出てきた際の $Q(s_i, a_j) - R(s_i)$ の最大値とそれ以外の大小関係は $\tau(s_i, a_j)$ による変動が起きにくくなるため，greedy 行動をしやすくなる傾向となる．反対に大きすぎる場合，$RS(s_i, a_j)$ の変動が起こりやすくなるので探索を行う傾向となる．今回のスケーリング変数の設定の一つである $\zeta(s_i) = 0.01$ は非常に小さい値であったため，greedy 法と結果が一致することになったと考えられる．また，RS の後悔が greedy 法を下回らなかった理由について，RS は E_G が R_G に近似し，満足化した際，以降 Q 値から greedy に行動決定を行うようになる．しかし，常に負の報酬を与え続けるタスクにおいて，最適な値に収束していない Q 値は行動を行うたびにその値を減少させていく．そのため Q 値が十分更新されていない場合，Q 値の大小関係が入れ替わり続けることから，最適な経路を選び続けるためには Q 値の減少によってその大小関係が変動しなくなるまで更新を行う必要がある．結果として RS は探索を行う分，greedy 法より後悔を蓄積することとなったと考えられる．

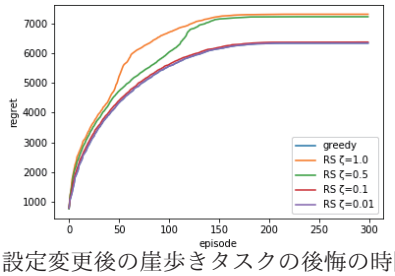


図 8: 設定変更後の崖歩きタスクの後悔の時間発展

7. 結論

本研究では GRC を用いた RS を先行研究で試されてこなかった，1 エピソード内で時間の経過によって報酬減衰して行くタスク，確率的に報酬が変わるタスク，負の報酬が与えられるタスクの 3 つの報酬関数をもつタスクに適用することでどのようなタスクに適応できるかの検証を行った．結果として，タスク内で正の報酬のみが与えられる場合では大局期待値 E_G が大局満足化基準値 R_G に収束またはツリーバンディットのように適切に超えるパラメータ設定をすることで最適な行動系列を取り続けることができ，適応できることがわかった．大きな負の報酬がタスク内にある場合では GRC を用いた RS は大きな負の報酬を避ける経路を少ない試行回数で学習し，その有用性を示したが，移動コストとして負の報酬を与える崖歩きの結果から，全状態の Q 値が行動のたびに減少するタスクの場合は RS は各状態の Q 値が十分に更新されるまで満足する行動を取り続けることはできないため，Q 値が減少を続けないような報酬関数の設計を考える必要があるといえる．

参考文献

[Simon 56] Simon, H. A.: Rational choice and the structure of the environment, *Psychological Review*, Vol. 63, No. 2, pp. 129–138 (1956)

[牛田 16] 牛田 有哉, 甲野 佑, 浦上 大輔, 高橋 達二: 探索割合を 自律調節する強化学習手法満足化基準の動的獲得, JSAI 2016 (2016 年度人工知能学会全国大会 (第 30 回)) (2016)

[牛田 17a] 牛田 有哉, 甲野 佑, 高橋 達二:生存を目的とする満足化強化学習, JSAI 2017 (2017 年度人工知能学会全国大会 (第 31 回)) (2017)

[牛田 17b] 牛田 有哉, 甲野 佑, 高橋 達二:強化学習と満足化による素早い行動系列の獲得, 情報処理学会第 79 回全国大会講演論文集, 5M-04. (2017)

[高橋 16] 高橋 達二, 甲野 佑, 浦上 大輔：認知的満足化—限定合理性の強化学習における効用, 人工知能学会論文誌, Vol. 31, No. 6, pp. AI30-M-1–11 (2016)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

Profit Sharing と遺伝的アルゴリズムを用いたハイブリッド学習 -MDPs 環境でのタスク分割性能-

Hybird Learning Using Profit Sharing and Genetic Algorithm -Task Division Performance in MDP Environments-

鈴木 晃平[*1] 加藤 昇平[*1*2]
Kohei Suzuki Shohei Kato

[*1]名古屋工業大学工学研究科情報工学専攻
Department of Computer Science and Engineering Graduate School of Engineering, Nagoya Institute of Technology

[*2]名古屋工業大学 情報科学フロンティア研究院
Frontier Research Institute for Information Science, Nagoya Institute of Technology

Reinforcement learning is generally performed in the Markov decision processes (MDP). However, there is a possibility that the agent cannot correctly observe the environment due to the perception ability of the sensor. This is called partially observable Markov decision processes (POMDP). In a POMDP environment, an agent may observe the same information at more than one state. We proposed a hybrid learning method using Profit Sharing and genetic algorithm (HPG) for this problem. However, Most of real problems can be represented in an MDP environments. In this paper, we improve HPG to adapt to MDPs environments and report the effectiveness of our method by some experiments with mazes.

1. はじめに

強化学習は，学習者であるエージェントが環境との相互作用から目標状態に達する方策の学習を行う手法である．エージェントは目標状態に達したときに報酬が得られ，それを最大化することを目的に学習する．一般に強化学習は，状態を正しく観測できるマルコフ決定過程（MDPs）の環境を想定している．しかし実際には，センサの知覚能力により状態の混同が起こっている可能性があり，エージェントがうまく学習を行えないことがある．状態の混同が発生している環境を部分観測マルコフ決定過程（POMDPs）といい，それが原因で発生する問題を不完全知覚問題という．

不完全知覚問題の解決法は，サブタスクに分割する手法 [Wiering 97, Nomura 15]，Profit Sharing （PS）を用いた手法 [Arai 01, 植村 05]，状態遷移の履歴を用いる手法 [McCallum 95] の３種類に大別できる．これらの手法ではそれぞれ欠点を持っている．サブタスクに分割する手法では，サブゴールの学習とサブタスクの再学習を行う必要があり，学習効率が悪い．PS を用いた手法では，不完全知覚状態が多く存在する環境ではランダム行動と変わらなくなるなど複雑な環境下に弱い．状態遷移の履歴を用いる手法では，環境が大きくなると計算量が発散してしまう．筆者ら [鈴木 17] は，これらの欠点を改善すべく PS と遺伝的アルゴリズム（GA）によりサブゴールを決定し，不完全知覚問題を解決する Hybrid learning using Profit sharing and Genetic algorithm （HPG）を提案した．しかし，実問題では MDPs 環境であることが多いものの，HPG の MDPs 環境下における有効性を検証していなかった．本稿では，MDPs 環境にも対応できるよう HPG を改良し，実験によりタスク分割性能を検証する．

2. 不完全知覚問題

本稿では，図 1 のようなグリッドの環境を想定する．エージェントの観測範囲は近傍の８セルとし，壁の有無のみ知覚でき，行動は上下左右の４種類とする．図 1 の環境では，スタートの状態 S からゴールである状態 G に到達するために，状態 A，B を通過しなければならない．しかし，状態 A と状態 B では近傍８セルが同一のものとなっているため，状態の混同が発生し，エージェントは２つを異なる状態だと判別できない．このように異なる状態を同一の状態と観測してしまう環境が POMDPs 環境である．さらにエージェントは，状態 A では右に，状態 B では上に移動しなければならないが，２つを同一状態とみなしているため，ゴールに近い状態 B ですべき上という行動を学習してしまい，状態 A でループに陥ってしまう．このように POMDPs 環境下で正しく学習を行えない問題が不完全知覚問題である．

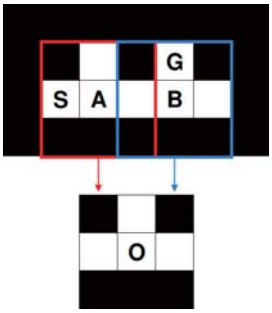


図 1: A POMDP environment

3. Profit Sharing と遺伝的アルゴリズムを用いたハイブリッド学習

提案手法では，GA を用いて不完全知覚問題を解決するエージェントを生成する．各エージェントは配列構造で表現されるサブゴールを設定し POMDPs 環境の分割を行い，サブエージェントが MDPs 環境で強化学習を行うことで不完全知覚問題に対応する．その強化学習の結果に応じ，遺伝的操作を行い環境に適したエージェントが生成される．以下に提案手法の計

連絡先: 加藤昇平，名古屋工業大学，愛知県名古屋市昭和区御器所町，052-735-5625，shohey@katolab.nitech.ac.jp

算手順を示す.

1. 初期集団を生成する.
   X 個のサブゴールと $(X+1)$ 個のサブエージェントをもつエージェント Y 個体を生成する.
2. 各エージェントが強化学習を行う.
   各エージェントは，サブゴール到達を切り替え条件に先頭のサブエージェントから順に学習する.
3. 交叉，突然変異を行い，新たなエージェントを生成する.
4. 以降,(2) ,(3) を世代数繰り返し終了.

3.1 初期集団生成

初期集団生成時において，エージェントは環境にどのような状態が存在するか未知である．サブゴールをランダムに生成すると，到達不能なサブゴールや存在し得ないサブゴールが多数出現する．これにより試行回数が増大し，さらに適応度は各サブゴールではなく順序付きサブゴール集合を評価するため，有効なサブゴールをもつエージェントの適応度まで下げてしまう可能性があり，学習が遅くなると考えられる．そのため，初期集団生成時にある程度有効なサブゴールを設定すべきである．そこで，提案手法では強化学習の一種である PS を用いてサブゴールを生成する．サブゴール生成の計算手順を以下に示す.

1. 報酬分配量を考慮した PS で学習を行う.
2. 各状態のルールの優先度からサブゴール候補を決定する.
3. サブゴール候補からランダムに各個体のサブゴールを決定する.

3.1.1 報酬分配量を考慮した Profit Sharing

Profit Sharing （PS）は，各状態ごとの行動の優先度を学習する手法で，報酬獲得した際にエピソード内すべてのルールの優先度を一括に強化するオフライン学習である．状態 s_t における行動 a_t の優先度 $P(s_t, a_t)$ は次式で強化される.

$$P(s_t, a_t) \leftarrow P(s_t, a_t) + f(x) \tag{1}$$

ここで $f(x)$ は強化関数といい，x は報酬獲得までの距離を表す．PS は，この優先度に基づくルーレット選択により行動選択を行う．提案手法では，PS のオフライン学習とルーレット選択に着目し，有効ルールである可能性が高い状態を判別し，その状態をサブゴール候補とする.

PS の強化関数は，等比減少関数が使われていることが多い．しかし，有効なサブゴールを生成するため，提案手法では同一状態で行われたルールの報酬分配量を等しくする．そのため，1 エピソードにおいて各ルールを強化するのは 1 回のみとし，各ルールの強化関数は報酬獲得までの距離 x に依存せず，次式とする.

$$f(x) = \frac{1}{W} \tag{2}$$

ここで W は，エピソード長である．ゴールに必要不可欠なルールは，不完全知覚状態の有無に関わらず毎回強化されるため，全てのルールの中で最も大きい優先度を持つ．そこで提案手法では，大きい優先度を持つルールの状態をサブゴール候補とし，初期集団生成時にこの中から各個体がサブゴールをランダムに選択する.

3.2 強化学習

初期集団生成時だけでなく各エージェントが行う強化学習にも前述した報酬分配法の PS を用い，学習の高速化を図る．PS は，報酬に至るルールをすべて強化するため報酬獲得に貪欲であり学習の立ち上がりが速い．また植村ら [植村 05] は，複数のルールを必要とする不完全知覚問題において，ランダム選択に劣らない性能をもつためには報酬獲得に必要なルールをすべて同じ確率で選択できれば十分であると示した．提案手法では，同一状態において等しく報酬を与えているため，この十分条件を満たし不完全知覚問題にも対応できる．そのため，サブゴール分割がうまくできず不完全知覚が起こっている場合でも，目標状態に達することができる．これにより早い段階で有効なサブゴールかどうか判断でき，学習時間の短縮となる.

提案手法では，PS でサブゴール候補を生成し，PS によって学習を行うエージェントを GA で選択，淘汰して問題を解決する．つまり PS と GA のハイブリッド学習となる．提案手法は，PS の局所解の陥りやすさと GA の学習の遅さというお互いの欠点を 2 つの手法を組み合せることで解消している.

3.3 交叉

提案手法では，サブゴール候補からサブゴールをランダムに決定するため，サブゴールの組み合わせが無秩序になっている可能性が高い．それにより学習序盤では，遠回りしないように適切なサブゴール到達順序にする必要がある．また学習終盤では，局所解に陥っていた場合に脱出できるようにする必要がある．そこで，交叉は 2 種類行う.

サブゴールの交叉

サブゴールの交叉は一様交叉を行う．これにより，学習序盤に意味を成さないサブゴールの順序を入れ替える．また優先度は引き継がずに初期化する．これにより，新たな解が見つかりやすくなり局所解からの脱出もできると考えられる.

サブエージェントの交叉

サブエージェントの交叉は一点交叉を行い，サブゴールと優先度を引き継ぐ．サブゴールの交叉のみでは優先度を引き継がないため，学習が遅くなってしまう．また学習が進むにつれ，サブゴールが適切な組み合わせになっていくが，サブゴールの交叉を行うことで，またサブゴールの順序を乱すことになり学習率が低下する．そこでサブエージェントの交叉を行うことで学習速度を速くする．また親 2 個体の切断箇所は共通ではなく，各個体ランダムに決定する．これによりサブゴール数が動的に変化する.

3.4 適応度計算

適応度は，各エージェントの学習後に greedy 法を用いて行動させ，ゴールしたか否かで評価方法を変更する．ゴール達成した場合は greedy 法によるステップ数，ゴールしなかった場合は学習中のゴール回数をみて更新する．これは不完全知覚問題を，ルーレット選択により偶然解決したエージェントの適応度を上げないようにするためである．適応度を次式で与える.

$$F1 = \begin{cases} R + \dfrac{Max\_step - step}{sub \times a} & \text{(completed)} \\ \dfrac{goal}{b} & \text{(uncompleted)} \end{cases} \tag{3}$$

ここで，R はゴール報酬値，Max_step は最大ステップ数，$step$ はゴール到達までのステップ数，sub はサブゴール数，$goal$ は強化学習中のゴール回数，a，b は重みを表す．重み b につい

ては、$\frac{goal}{b}$ の値がゴール報酬値 R を超えないように設定する．適応度は，最適解に近づけるためステップ数を基準に決めるが，この式で学習を進めると同様なサブゴールのみ残り，多様性がなくなってしまう．局所解に陥らないためにも，遺伝子に多様性を持たせ新たな解を見つける可能性を高めなければならない．そこで式（３）を求めた後，同一の順序付きサブゴール集合をもっているエージェントの適応度を重み c で除算する．同様の順序付きサブゴール集合を所持するエージェントを消すことでも多様性は維持できるが，学習序盤に有効なサブゴールが遺伝しにくくなり学習が遅くなってしまうため，適応度を低くする形をとる．

3.5 突然変異

初期集団を生成する際に，適切なサブゴールがサブゴール候補の中に存在しない可能性もある．その場合に局所解に陥らないためには，突然変異が重要となる．提案手法の突然変異では，配列構造で表現されるサブゴールをランダムに生成する．しかし，ただランダムに生成するだけでは，前述した通り無駄なサブゴールができてしまう．そこで突然変異で生成するサブゴールの一部にドントケアを用いて抽象化する．ドントケアを用いた要素は，観測情報の要素が何であっても真とする．これにより，生成されるサブゴールが有効である可能性を高められる．

4. 関連研究

野村ら [Nomura 15] は，HQ-learning を改良しサブゴールを GA により創発するサブゴール創発強化学習 (SERL) を提案した．しかし，この手法はランダムにサブゴールを生成するため学習が遅い．そこで筆者ら [鈴木 17] は，PS を用いて不完全知覚状態の可能性が高い状態をサブゴール候補とした HPG を提案した．しかし，これは MDPs 環境において有効でないサブゴールを生成してしまい学習効率が悪い．また arai ら [Arai 01] は，同状態において等しく報酬分配を行う First Visit Profit Sharing (FVPS) を提案し，植村ら [植村 05] が FVPS の報酬分配量をエピソードの部分系列を用いて増やした Episode-based Profit Sharing (EPS) を提案した．これらは，確率的に不完全知覚問題を解くため，状態の混同が多く発生している環境ではランダム行動に近くなってしまう．また価値を累積しているため，局所解に陥りやすく環境変化にも対応できない．

5. POMDPs 環境下での性能実験

図 2 に示す Wiering[Wiering 97] の迷路を用いて POMDPs 環境下での性能実験を行う．観測範囲は近傍 8 セルのみで，行動は上下左右の 4 種類とする．数字が書いてあるセルが道で，黒いセルが壁であり，壁に移動する行動を選んだ場合は移動を行わず，ステップ数のみ加える．道のセル上の数字は，観測情報を説明上わかりやすく表したもので，図 3 の配列構造を 9 桁の 2 進数とみなし，それを 10 進数に変換した値である．この環境で最短経路を得るためには，青いセルと赤いセルで発生する不完全知覚問題を解決しなければならない．他の経路についても必ず不完全知覚問題が複数発生する環境である．ここでは，提案手法，HPG，SERL，EPS，FVPS の 5 種類の手法で比較実験を行う．各手法の試行回数は，強化学習試行数 75 万回に統一した．この迷路の最短ステップは 28 で，1 エピソードの最大ステップ数は 150，初期サブゴール数 5 とし，また実験は 100 回行いその平均をとる．

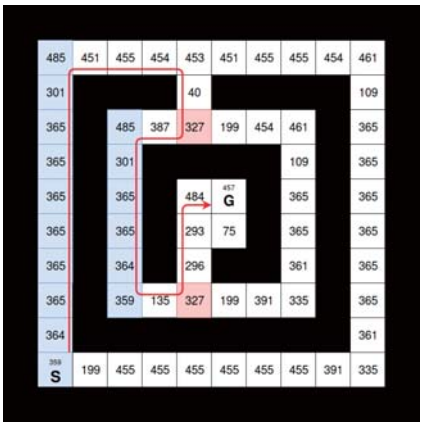


図 2: The maze of Wiering[Wiering 97]

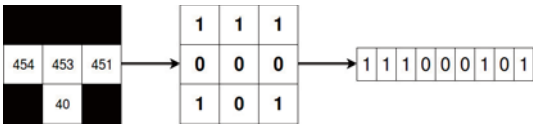


図 3: A example of subgoal

図 4 に実験結果を示す．グラフの縦軸は最短ステップ数，横軸は強化学習回数である．EPS と FVPS は局所解に陥いることがあり，最短ステップに収束していない．これらは，経験に固執して解の更新がされにくいため，学習序盤に最適解が見つからない限り局所解に陥ってしまう．SERL では，ほぼ最適解に収束している．最適解にはならなかった原因として，初期に無駄なサブゴールが多く創発され，75 万回では適切なサブゴールが発見できなかったことが考えられる．一方提案手法と HPG では，最短ステップ数に収束している．提案手法は，HPG より学習の立ち上がりが遅いが，先に最短ステップに収束した．これはサブゴール候補が多くなった分，適切なサブゴールを見つけることに時間がかかったが，解の多様性が高くなり，最適解を獲得しやすくなったと考えられる．

6. MDPs 環境下への適応性実験

図 5 に示す Sutton[Sutton 99] の迷路を用いて MDPs 環境下への適応性実験を行う．この迷路は，ゴールまでの経路が複数存在するが，最短経路を獲得するためには”25”と”62”のセルを通過しなければならない．ここでは，提案手法，HPG，SERL，FVPS，Q-learning の 5 種類の手法で比較実験を行う．各手法の試行回数は，強化学習試行数 1 万回に統一した．この迷路の最短ステップは 17 で，1 エピソードの最大ステップ数は 150，初期サブゴール数 3 とし，また実験は 100 回行いその平均をとる．

図 6 に実験結果を示す．Q-learning は学習速度は速いが，局所解に陥っており，FVPS では，1 エピソードあたりの報酬が少ないため学習が遅い．提案手法，HPG，SERL を比較すると，提案手法が最も学習速度が速い．これにより初期集団生成時に有効ルールをサブゴール候補にした有効性がみられた．また Q-learning と比較すると，学習速度は遅いが，最適解を獲得している．このことから，簡単なタスクにおいては提案手法はオーバーヘッドとなってしまうが，局所解から逃れることが

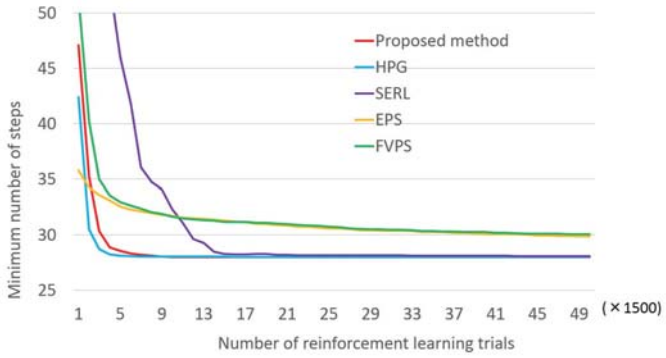


図 4: The result in the POMDP environment

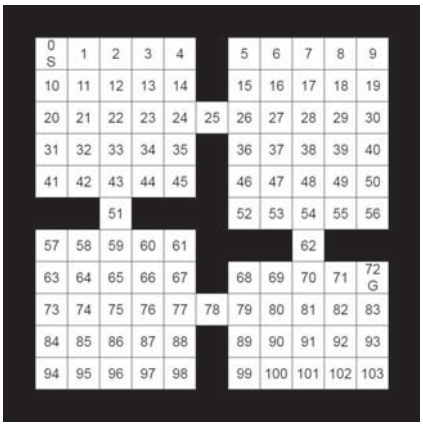


図 5: The maze of Sutton[Sutton 99]

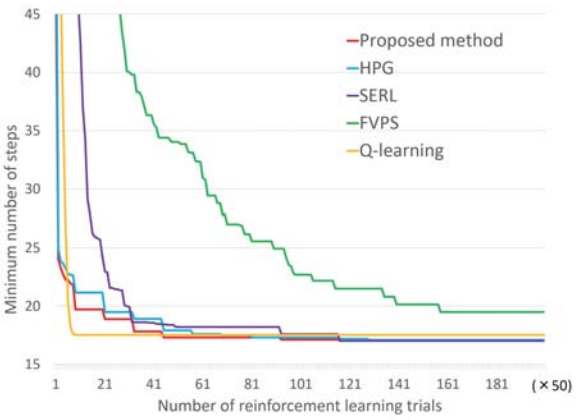


図 6: The result in the MDP environment

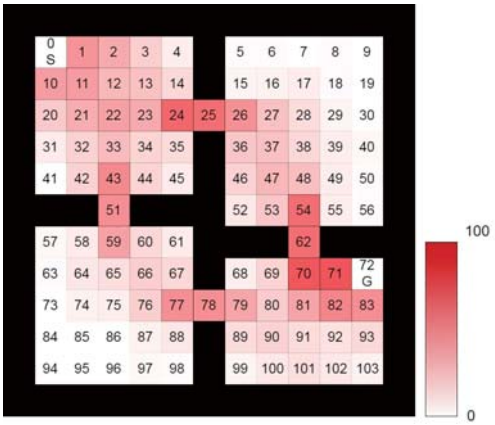


図 7: The distribution of subgoal candidates

できると考えられる．

図 7 に初期集団生成時のサブゴール候補の分布を示す．100 回の実験でサブゴール候補となった回数に赤色の濃さが対応している．最短経路上の状態がほぼ網羅されているが，”25”と”62”のセルはそれぞれ 100 回中 58 回と 62 回サブゴール候補になっており，毎回サブゴール候補になっているわけではない．しかしながら図 6 では最短経路を獲得しており，GA によるタスク分割の有効性がみられる．

7. おわりに

本稿では，不完全知覚状態の有無に関わらずタスクを解決する手法を提案した．実験により，提案手法は POMDPs 環境におけるタスクでは，他の手法より早く最適解を獲得し，また MDPs 環境下におけるタスクでは，サブタスクに分割する手法として最適解を獲得し有効性を示した．今後の課題として，複雑な MDPs 環境下での性能実験に加え，連続状態空間への拡張と車輪型ロボットを用いた実環境への適応が挙げられる．

参考文献

[Arai 01] Arai, S. and Sycara, K.: Credit assignment method for learning effective stochastic policies in uncertain domains, in *Proceedings of the 3rd Annual Conference on Genetic and Evolutionary Computation*, pp. 815–822Morgan Kaufmann Publishers Inc. (2001)

[McCallum 95] McCallum, R. A.: Instance-based utile distinctions for reinforcement learning with hidden state, in *ICML*, pp. 387–395 (1995)

[Nomura 15] Nomura, T. and Kato, S.: Dynamic subgoal generation using evolutionary computation for reinforcement learning under POMDP, *International Symposium on Artificial Life and Robotics*, Vol. 20, pp. 322–327 (2015)

[Sutton 99] Sutton, R. S., Precup, D., and Singh, S.: Between MDPs and semi-MDPs: A framework for temporal abstraction in reinforcement learning, *Artificial intelligence*, Vol. 112, No. 1-2, pp. 181–211 (1999)

[Wiering 97] Wiering, M. and Schmidhuber, J.: HQ-learning, *Adaptive Behavior*, Vol. 6, No. 2, pp. 219–246 (1997)

[植村 05] 植村 渉, 上野 敦志, 辰巳 昭治：POMDPs 環境のためのエピソード強化型強化学習法, 電子情報通信学会論文誌 A, Vol. 88, No. 6, pp. 761–774 (2005)

[鈴木 17] 鈴木晃平, 加藤昇平：不完全知覚問題に対する Profit Sharing と遺伝的アルゴリズムを用いたハイブリッド学習, 電気学会論文誌 C, Vol. 137, No. 12, pp. 1591–1599 (2017)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

Inverse Reinforcement Learning with BDI Agents for Pedestrian Behavior Simulation

Nahum Alvarez* Itsuki Noda*

* The National Institute of Advanced Industrial Science and Technology (AIST)

Crowd behavior has been subject of study in fields like disaster evacuation, smart town planning and business strategic placing. It is possible to create a model for those scenarios using machine learning techniques and a relatively small training data set to identify behavioral. We implemented a BDI-based agent model that uses such techniques into a large-scale crowd simulator, and apply inverse reinforcement learning to adjust agents' behaviors by examples. The goal of the system is to provide to the agents a realistic behavior model and a method to orient themselves without knowing the scenario's layout, based in learnt patterns around environment features.

1. Introduction

In this paper, we present a BDI agent model that includes the use of inverse reinforcement learning (IRL from here on) for the agents' decision making process, training them with knowledge learnt from previous data. The context of our research lies in the domain of pedestrian simulation on cities, with the objective of extracting knowledge of the pedestrian flow around concrete points of the map that contain certain features, like shops or restaurants. With this information we would be able to decide which spot is best for certain type of feature and how would change pedestrian affluence if we add new features or modify the existent ones. This is done by analyzing the crowd movement flow according of map features and agent characteristics. Previously IRL techniques has been used to calculate trajectories and plan movements, but as far as we know its use in agents based simulators or feature map optimization has been sparse.

2. Related Work

One of the applications of pedestrian simulation is smart city and business location planning, where we analyze people movements and behavior in their daily city life and obtain insight of what places attract more people and how different types of locations affect their actions. Then, once we have a model of the patterns that people follow, we can simulate them in other environments to assess the effectiveness of certain spots, or predict how a future potential business or facility could perform at different locations.

Using agents for the simulation is a popular approach due to be able of generating complex behavior with simple design and also escalates well, being appropriate for large scenarios. A common strategy is to model the agents with a dual behavior system controlling two types of movement (or behavior): micro and macro movement. The first one deals with collision avoiding in the near space and adjusting the agent's velocity in the crowd's flow, and the second is the one in charge of driving the agent towards its goal, creating and updating its route and taking care of the decision making process [Torrens et al., 2012]. Our simulator handles micro movements in an autonomous way, with its own subsystem where agents adapt to the crowd flow, and also allows to control macro movements using behavior scripts. To achieve our goal, we are focused in macro movements as it is the module that creates the agent's behavior.

In order to learn behavior patterns, we can take advantage of machine learning techniques. Concretely, apprenticeship learning methods have been widely used in intelligent agents' systems to train them to perform tasks in changing environments. Simulating people's behavior and not only trajectory planning is a difficult task, as their movements are governed by hidden rules and oriented to goals that may be hidden as well. We can observe strategies to emulate different behaviors for agents in [Faccin et al., 2017] but it is a static model with pre-designed driving styles, having the problem of not being able to simulate unplanned behaviors. There are previous works where agents are given a behavior cognitive model for pedestrians like in [Luo et al., 2008], [Martinez-Gil et al., 2017] or [Crociani et al., 2016], but they are specific to its domain, escalating badly, or they take as a given the reward or utility functions that drive the agents behavior, which often is unknown in complex scenarios. Using IRL is appropriate to overcome this issue, because IRL methods work on domains where the reward function is hidden. Hence, it is ideal for modeling animal or human behavior [Ng et al., 2000]. Works that use IRL to manage agent's behavior were sparse, but some researchers are starting to use it [Šošić et al., 2017]. IRL not only allows to train agents into achieving concrete goals, but also can learn different behavior patterns, as it is shown in [Abbeel & Ng, 2004] where driving styles are learned by an agent.

3. Pedestrian Simulator

We developed an agent based pedestrian simulator called CrowdWalk to perform crowd behavior for generic scenarios [Yamashita et al., 2009]. It can simulate movements of more than 1 million agents in a large area like complex building or town blocks in a city. Maps and agents' behaviors are configurable so that we can conduct simulations with various situations of maps

Contact: Nahum Alvarez, National Institute of Advanced Industrial Science and Technology (AIST), 2-3-26 Aomi, Koto-ku, Tokyo 135-0064, Japan
Tel: 080-3301-5860, E-mail: nahum.alvarez@aist.go.jp

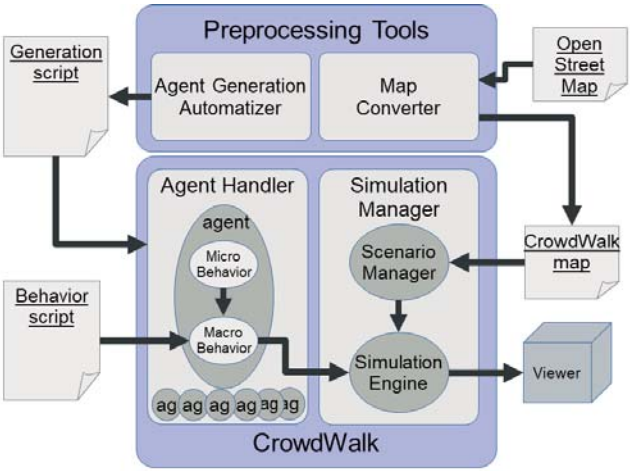


Figure 1: Architecture diagram of CrowdWalk. It has two main modules: one managing the agents and other in charge of the environment simulation.

and policies of agents. The architecture of CrowdWalk is depicted in Figure 1, and shows its principal work modules. We omitted from the diagram the modules related to the IRL process as in this section we want to describe in depth the application where we built learning agents on. We will focus in the IRL process flow and the new agents with detail in the next section.

CrowdWalk has two main working sub-systems: an Agent handler and a Simulation manager. The Agent handler contains an agent factory, that generates one agent per pedestrian. Each agent contains its own decision model that its composed by the micro and macro behavior modules. The micro behavior module in each agent takes care of micro movements automatically, calculating when an agent has to stop, walk slower or even try take other route due to be unable to continue its original path. However, the final decision of selecting other path is left to the macro behavior module, and actually, the macro behavior module is able to override any orders from the micro movements module if deems so.

The macro behavior module is the one in charge of calculating the agent's route to its goal, and updating it if necessary. This module contains some predefined behaviors, built using a nested hierarchy where the most basic behavior consists in an agent that just calculates the shortest path to the goal without taking in account the degree of agglomeration of each link, and other behaviors increase in complexity by changing the path if there is too much agent density, or avoiding roads it used previously. On the top of the most complex class, there is a special class that enables the agent to be controlled externally, the agents' Behavior Script. In our current research we created an IRL agent for this class that will be described in depth in the next section.

To create the agents, the agent handler reads from the agent generation script, a file containing the rules of agent generation containing the number of agents needed, which type of agent will they be, which agent behavior script will use (if any), which point they come from, and which point they are going to. CrowdWalk also has a tool to automatically generate this file by providing some simple rules and the map model.

The other important sub-system is the Simulation Manager, which is the one in charge of actually run the simulation. It receives as input a configuration file containing the scenario information and recreates it as a virtual environment. Internally, CrowdWalk uses a Network-based model capable of high speed simulations of large numbers of agents. The model of the map received by the Simulation Manager consists in a custom xml that describes the map in the form of a road network represented by nodes (intersections) and links (road paths) composing a graph. A link has length (how long agents need to walk from a end to another) and width (how many agents can walk in parallel), and can be two-way or one-way. Nodes and links have labels to indicate goals and other features information, like what kind of facilities are on that location. The xml model can be created automatically using a tool included in CrowdWalk that converts maps obtained from the open source software Open Street Map into our custom format. This allows us to use any possible city map in the world with no additional effort.

The Agent handler is called by the Simulation manager in order to generate the agents in the virtual environment following the rules given in the agent generation script. When running, the simulation engine represents the scenario as a graphic simulation where the agents will behave according to each one's own behavior modules, allowing pausing the simulation at any moment and inspecting every element part of it.

4. Agent Model

Reinforcement learning techniques work on domains that can be modeled by a Markov decision process (MDP, from here on after). MDP are defined by a tuple M = {S, $\mathcal{A}$, $\mathcal{T}$, γ, r}, where S is the state space of the model, $\mathcal{A}$ is the set of actions that can be performed, $\mathcal{T}$ is the transition function, which returns the probability of transition from one state to other given a concrete action, and usually is given in the form of a matrix, r is the reward function that generates a reward value from reaching a state, and γ is a discount factor, that is applied when calculating accumulated reward through consecutive actions. When working with models with an unknown reward function, IRL methods provide us a way to obtain it. In order to get r, it is also provided a set of expert trajectories T, consisting of “paths” composed of pairs of states and actions.

We developed an automatic module that converts the city map used in CrowdWalk into a MDP, ready to be used by our IRL method. This tool translates map nodes into states, and creates a possible action for each link that it has. Also, in order to optimize the model, all the nodes that only have two links are trimmed, as there are no other possible decisions once a pedestrian enter in one other than continue walking or going back. Once we have the MDP model for the map, we run the CrowdWalk IRL module, that consists on a modified version of the maximum entropy IRL method found in [Alger, 2015], adapted in order to use a variable number of possible actions on each state, as each map node has a different number of possible links to take. The input of this module is the MDP representing the current map, and a file containing the training trajectories (i.e., the pedestrian behavior) we want to train. The resulting product of the module is a file containing the optimal policy function derived from the reward function generated by the IRL algorithm. This policy function takes the form of a lookup table stored in a file, which will be used by the system's agents.

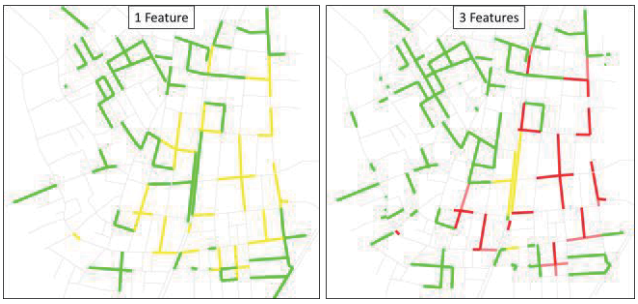


Figure 2: The rewarded links in the map when training with one and three different types of features.

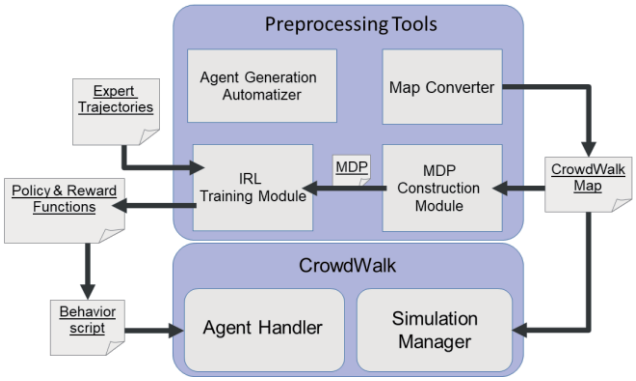


Figure 3: The IRL process integrated in the system. We added two modules to the system in order to train the agents.

An example of how the policy influence the map navigation can be seen in Figure 2. The maps shows a portion of the city of Tokyo containing features that were classified in three groups: shops, restaurants or entertainment. In the leftmost map we trained only shopping behavior, and in the rightmost map we trained all the three features. Links in red have a probability greater than 80% to be selected as the next path, in yellow when is between 40% and 80%, and in green when it is lower than 40% but greater than 20%. As we can see in the figure, when training with three groups of features, new colored links appear compared to the one-featured map, and also increases the probability of taking the links in areas with different features are overlapping. We want to note that colored links appear over the whole map, and not only in the areas covered by trained routes, which where a 60% of the map.

The generation of the MDP model and the reward and policy functions is performed before the simulation as a pre-processing task. Thus, even if this pipeline can take a long time depending of the complexity of the map, it does not represent a big impact in the simulation speed. The process flow once included in the architecture we explained in the previous section is depicted in Figure 3.

We developed a type of agent, called IRL agent, that works with an input behavior script and the IRL's resulting policy and decides which link to take on the probabilities contained in it. The agent follows a BDI architecture, having a list of desires defined in the input behavior script as goals (that should be in line with the trained behavior), and a memory where its beliefs are stored and consisting in the optimal policy obtained from the

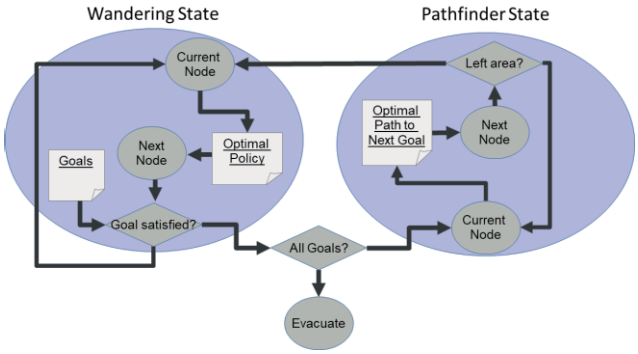


Figure 4: The algorithm followed by the IRL agents.

IRL process (stored as a lookup table), and the goals and features previously visited. The goals can be generic, like "visiting any restaurant", or concrete, like "visiting the restaurant located in the node labeled as nd00327". Each goal in the list also contains the conditions for its satisfaction, which can be reaching the goal, staying in the goal a defined time, reaching a number of goals of that type (in case of the generic goal), or a combination of them. Also, the script contains an evacuation point, where the agent will go after completing its goals. The decision making algorithm is shown in Figure 4. An agent starts in the state called "wandering", where he obtains from the policy table a list containing the probabilities of taking each one of the available links on its current node. Then the agent chooses which path it will take based on that probability list. Whenever the agent visits a goal node, it checks and updates its satisfaction conditions. If that goal is satisfied, the agent enters into another state, called "pathfinder", which makes it go to its next goal using the most optimal path. However, it leaves this state as soon as it has left the area containing the previous goal, and returns to the "wandering" state. The agents decide they left the area of a goal if they surpassed a distance threshold from that goal. Also, goals already visited do not count as new goals when returning to them (in case the agent has to visit a concrete number of them). Once all the goals have been completed, the agent enters again in "pathfinder" mode and goes straightly to its evacuation point, leaving the map.

5. Preliminary Validation

We performed a preliminary set of tests to validate if the intended behavior is observed in the agents. We selected a map from a portion of Tokyo were we located a total of 36 features, classified in three groups: shops, restaurants or entertainment. We generated by hand 3000 routes representing pedestrians making errands (we observed in previous tests that using bigger data sets did not generated better performance). Then, we performed three different sets of simulations using 3000, 6000 and 10000 IRL agents. The agents started from 20 different random points and have the goal of visiting 4 featured spots. Also, in order to compare the agents behavior, we performed a parallel simulation using other type of agent called "pathfinder agent", capable of calculate optimal routes and going directly to its goals (so it is always in the pathfinder state). We designed routes for those agents placing waypoints on certain featured

Table 1: Agent coverage of the featured nodes in the map.

Agent Type	Total Nodes Visited	Average per Agent
IRL	100%	7.11
Pathfinder	75%	2.23

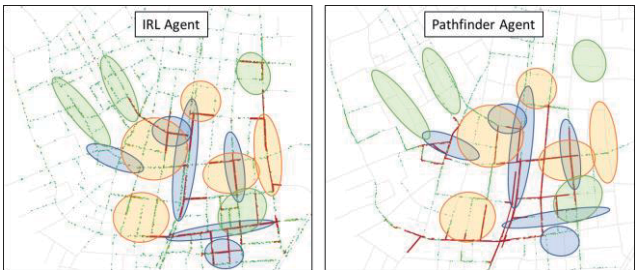


Figure 5: Comparison between the behavior of the agents. The colors used mark different areas: yellow for shops, blue for restaurants, and green for entertainment.

areas, making them to walk to those points in order and then evacuate at the final point.

Figure 5 shows a caption of the simulation with the three types of featured areas marked with different colors. As the pathfinder agents are programmed to only follow the best path, they avoid other similar featured areas that are not part of it. They also concentrate in other areas that do not contain features, but are just the optimal path to the goal (for example, the big avenue that runs vertically across the map, which is a navigational hub). On the other hand, IRL agents tend to disperse themselves when they are searching for featured areas, and concentrate in all the featured areas in the map, especially if they overlap. Even untrained areas are populated. Also, by observing the reward values of the links on the map, we can detect which places are more optimal for certain business.

We also extracted some population density numbers from our tests, which can be seen in Table 1. The IRL agents visited all the 36 featured nodes while the pathfinder agents left 9 nodes untouched. Not only that, each IRL agent visited more than three times the average number of nodes per agent than the Pathfinder agents. Naturally, the pathfinder agents only went to the featured nodes that were by chance in their path to the goal, but this means that in the real world, not all features are in the most optimal paths and agents that does not take in account behavioral patterns will ignore places that may be important.

6. Conclusions

In this paper we presented an agent-based pedestrian simulator that uses inverse reinforcement learning in order to imitate behavior patterns learned from expert's trajectories. Our goal is to provide better understanding of crowd simulation and applying it to city and business smart planning. We performed a set of preliminary experiments obtaining promising results, especially when replicating the intended behavior. Our IRL agents visit spots in the map that are ignored by agents that only calculate the most optimal route to the goal, generating more realistic behavior. We are planning to validate the behavior of our agents by comparing them with live data from real pedestrians in the next steps of our research. We think IRL techniques opened an interesting path that was not enough explored although they are well known from long ago, maybe because a lack of simulation technology.

References

[Abbeel & Ng, 2004] Pieter Abbeel and Andrew Y Ng. Apprenticeship learning via inverse reinforcement learning. In Proceedings of the twenty-first international conference on Machine learning, page 1. ACM, 2004.

[Alger, 2015] Matthew Alger. Deep inverse reinforcement learning. 2015.

[Crociani et al., 2016] Luca Crociani, Giuseppe Vizzari, Daichi Yanagisawa, Katsuhiro Nishinari, and Stefania Bandini. Route choice in pedestrian simulation: Design and evaluation of a model based on empirical observations. Intelligenza Artificiale, 10(2):163-182, 2016.

[Faccin et al., 2017] João Faccin, Ingrid Nunes, and Ana Bazzan. Understanding the Behaviour of Learning-Based BDI Agents in the Braess' Paradox, pages 187-204 Springer International Publishing, Cham, 2017.

[Luo et al., 2008] Linbo Luo, Suiping Zhou, Wentong Cai, Malcolm Yoke Hean Low, Feng Tian, Yongwei Wang, Xian Xiao, and Dan Chen. Agent-based human behavior modeling for crowd simulation. Computer Animation and Virtual Worlds, 19(3-4):271-281, 2008.

[Martinez-Gil et al., 2017] Francisco Martinez-Gil, Miguel Lozano, and Fernando Fernández. Emergent behaviors and scalability for multi-agent reinforcement learning based pedestrian models. Simulation Modelling Practice and Theory, 74:117-133, 2017.

[Ng et al., 2000] Andrew Y Ng, Stuart J Russell, et al. Algorithms for inverse reinforcement learning. In Icml, pages 663-670, 2000.

[Šošić et al., 2017] Adrian Šošić, Wasiur R KhudaBukhsh, Abdelhak M Zoubir, and Heinz Koeppl. Inverse reinforcement learning in swarm systems. In Proceedings of the 16th Conference on Autonomous Agents and MultiAgent Systems, pages 1413-1421. International Foundation for Autonomous Agents and Multiagent Systems, 2017.

[Torrens et al., 2012] Paul M Torrens, Atsushi Nara, Xun Li, Haojie Zhu, William A Griffin, and Scott B Brown. An extensible simulation environment and movement metrics for testing walking behavior in agent-based models. Computers, Environment and Urban Systems, 36(1):1-17, 2012.

[Yamashita et al., 2009] Tomohisa Yamashita, Shunsuke Soeda, and Itsuki Noda. Evacuation planning assist system with network model-based pedestrian simulator. In PRIMA, pages 649–656. Springer, 2009.

[1O1] [General Session] 10. Vision / Speech

座長:石寺 永記（NECソリューションイノベータ）

Tue. Jun 5, 2018 1:20 PM - 3:00 PM Room O (2F Kaimon)

[1O1-01] Banner Click Through Rate Classification Using Deep Convolutional Neural Network

Nicolas Michel[2,3], ○Hayato Sakata[1], Keita Kurita[3], Toshihiko Yamasaki[3] （1. So-net Media Networks Corp., 2. Institut Mines-Télécom Atlantique, 3. The University of Tokyo）

1:20 PM - 1:40 PM

[1O1-02] Turn Signal Recognition by Convolutional Recurrent Neural Network

○Ryota Hagi[1], Keisuke Yoneda[1], Naoki Suganuma[1] （1. Kanazawa University）

1:40 PM - 2:00 PM

[1O1-03] Bidirectional recognition between motion context on long-term observation and human motion

○Tadashi Ogura[1], Tetsunari Inamura[1,2] （1. SOKENDAI(The Graduate University for Advanced Studies), 2. National Institute of Informatics）

2:00 PM - 2:20 PM

[1O1-04] On Simultaneous Recognition of Multiple Paper Sticky Notes with Position Detection and High-resolution

○Eishun Ito[1], Tadachika Ozono[1], Toramatsu Shintani[1] （1. Nagoya Institute of Technology）

2:20 PM - 2:40 PM

[1O1-05] ATM Anomaly Behavior Detection with Machine Learning: A Study

○TRONG HUY PHAN[1], Reiko Kishi[1], Kazuma Yamamoto[1], Makoto Masuda[1] （1. Corporate Research and Development Center, Oki Electric Industry Co., Ltd.）

2:40 PM - 3:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

Banner Click Through Rate Classification Using Deep Convolutional Neural Network

Nicolas MICHEL † ‡ Hayato SAKATA * Keita KURITA† Toshihiko YAMASAKI†

† Department of Information and Communication Engineering, The University of Tokyo 7-3-1 Hongo, Bunkyo-ku Tokyo, 113-8656

‡ Département Informatique, Institut Mines-Télécom Atlantique, 2 rue Alfred Kastler, 44300 Nantes, France

* 2-11-1 Osaki, Shinagawa-ku, Tokyo, 141-0032 Japan, a.i lab., So-net Media Networks Corp.

E-mail: † nicolas.michel@imt-atlantique.net, ‡ {kurita, yamasaki}@hal.t.u-tokyo.ac.jp * hayato_sakata@so-netmedia.jp

ABSTRACT

In banner advertising, Click Through Rate (CTR) is one of the most important indicators to evaluate one advertisement's quality. Advertisers create massive number of banner candidates in empirical ways, then proceed to actual tests by delivering advertisement to measure each banner's effectiveness. This process is expensive and therefore our CTR prediction helps reducing online advertising costs. In this work, we propose a method to classify 'effective' and 'ineffective' advertising banners based on image processing using state-of-the-art CNN. We first focus only on images then conduct experiments including metadata (product, advertiser, etc) to increase the CTR prediction accuracy and demonstrate which metadata is the most influential. Subsequently, each approach is compared to human performance. In the second part of our work, we detect which parts of the image contribute predominantly to increase the CTR by generating heat maps for each classes. This work leads to a deeper understanding of a banner advertising success and helps making decisions on how to improve it.

1 INTRODUCTION

In the field of banner advertising, Click Through Rate (CTR) is one of the core indicators to describe one advertisement's efficiency [10]. Scoring each banner's real quality is very expensive and time consuming as advertisers rely on concrete trials over a tremendous number of banners to infer. Moreover, in some cases, promising candidates are not used, because advertisers filter out many of them without use to decrease advertising costs, and this process strongly depends on intuition of staffs. Accurate CTR prediction helps reducing online advertising costs and improving its performance.

In this work, we propose a CTR prediction method based on image processing using a state-of-the-art CNN [5, 6], and demonstrate that a machine learning technology overcomes human performance. CTR prediction using visual features such as CNN is emerging and further study is needed. In addition, current research in Deep Learning gave impressive results for Image Classification and more precisely for feature extraction [5, 6, 11]. As in banner advertisement, visual feature is highly correlated to attractiveness [4], recent studies addressed CTR prediction based on CNN as feature extractor [3, 7]. Throughout this study, a CTR classification model is proposed.

The organization of the paper is as follows. In section 2, related works are summarized. The methods and experiments adopted for this work are described in section 3. Data cleaning process is explained in subsection 3.1. In subsections 3.2 and 3.3, the architectures and the experimental results are outlined. Moreover, training details are developed in subsection 3.4. In section 4, experimental results are interpreted in regard to our knowledge. Eventually in section 5, our conclusions are established and we discuss our future work.

2 RELATED WORK

This work is related to Image Recognition using Deep Learning as well as CTR prediction. In the past few years CNN have demonstrated high capabilities to process images [5, 6, 11]. In 2012, the first CNN was used to win ILSVRC, a well-known Image Classification challenge based on ImageNet dataset. Since then, Deep Learning techniques evolved and their performances drastically improved to eventually overcome human-level performance [14]. Considering such technological advances, several studies soon started to explore CNN techniques for Online Advertising, and specifically Banner Advertising [1-3, 7].

In this regard, Fire et al. [1] experienced an ImageNet pre-trained CNN to automatically determine banner categories. Fortunately, banners included in our dataset had been manually categorized already. Nevertheless, ImageNet classification can still be of use to enhance the image description and give more impact to the visual information [12]. Thus, our work explores CTR classification using an architecture similar to Chen et al.'s study [2] and proposes an alternative by introducing ImageNet 1,000-class log-probabilities as CNN input. Moreover we use variable number of metadata and interpret their impacts, constructing a metadata-expandable architecture. Eventually we compare those results to human performance which, to the best of our knowledge, has never been conducted in others studies.

3 METHODS

3.1 Data Sets and Cleaning

For this study, we used images collected over two years by So-net Media Network Corporation (SMN), an advertisement delivering company, for a total of 115,250 advertisement banners. The dataset in itself is widely heterogeneous on many aspects as it was gathered from 2,585 different advertising companies, 105 product categories (rent, sale in lots, newly-built, etc), 20 product category groups (real estate, etc) and 13 different sizes of banners. These product categories and product category groups are manually defined by human. As a consequence, data-

preprocessing was essential and mainly impacted the quality of our results.

The first step was to prevent leakage issue. In banner advertising, it is common to create several near identical images to fit different displayed sizes and identify the impact of minor modifications. This process implies that a large number of banners are near-duplicate. This number is difficult to estimate and in many cases induces leakage. Indeed near-duplicates are repeatedly present in the training set and test set and usually have close CTR values to each other. In practice we sorted our sets in a way that every near-duplicate banners are in the same set. This prevents the model to be tested on a banner where near-duplicate was in the train set.

The second step was disposing of duplicate banners. Conversely, same banners can also have very different CTR depending on the commercial strategy or the device on which it is displayed. This results in admitting in our dataset several possible CTR values for the same banner. Though those information might give decisive clues to advertisers, this makes CTR prediction even more complex. Hence, duplicate banners were removed from our dataset reducing their number to 85,255. The CTR value selected among duplicate was the one corresponding to the highest number of impressions, as its value is more representative of the overall banner effectiveness.

The third step was to select images whose aspect ratios are similar. When using a deep learning algorithm, considering images of variable input size can be delicate. The common practice is to re-scale the input image, which can induce huge distortions when the banner aspect ratio differs from 1:1. In that sense, only banners being close to square were considered, with ratio between 6:5 and 1:1. A majority of the banners used for online advertisement are long-shaped, shrinking the dataset size to 35,108 banners. Every experiment described in this study has been conducted on this dataset

3.2 Network Design

Our first approach was to fine-tune a ResNet-101 architecture [6] to classify the banners. Here the final fully connected layer has simply been truncated and replaced with another fully connected layer with two output nodes in the output layer. Each node returns a value corresponding to ‘effective’ and ‘ineffective’ classes respectively. This output can be interpreted as the overall effectiveness of the banner (see Fig. 1).



Figure 1: Simple architecture using a fine-tuned ResNet-101 to extract image features.

As the CTR distribution significantly changes for each device (smartphone or PC), the device in which the banner will be displayed is later included in the model. Progressively the same process is repeated, using an increased number of metadata such as the category of the advertisement and the image size. Metadata are processed using a Multilayer Perceptron (MLP). In the last fully connected layer (FC) the ResNet-101 and MLP outputs are concatenated to compute the effectiveness (see Fig. 2).

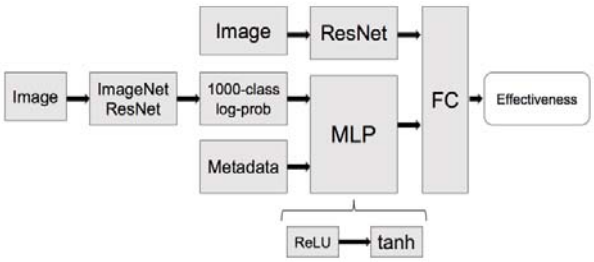


Figure 2: Architecture using fine-tuned ResNet-101 and metadata.

The last architecture uses the device, the size and the category as metadata plus the log-probability for each ImageNet label, obtained by the mean of another ResNet-101 trained on ImageNet dataset (see Fig. 3).

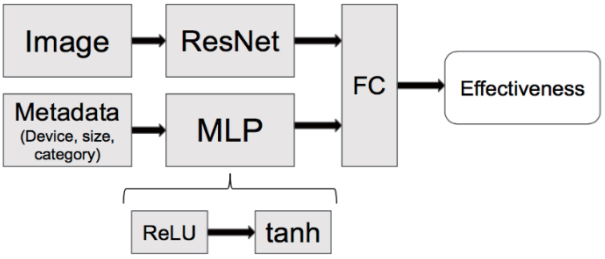


Figure 3: Architecture using fine-tuned ResNet-101, metadata and ImageNet-trained ResNet-101 1,000 log-probabilities.

For comparison and to understand the impact of metadata for our task, we also considered an architecture composed solely of metadata and ImageNet 1,000-class log-probabilities (see Fig. 4).

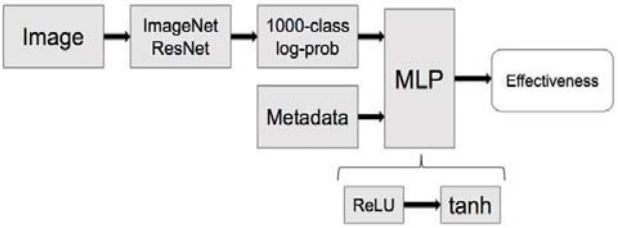


Figure 4: Architecture using image metadata and ImageNet 1,000 log-probabilities only.

4 EXPERIMENTS AND TRAINING DETAILS

4.1 Experiments

As aforementioned, the main objective of this work is to help advertisers and banner advertising experts having a hint concerning a banner’s quality. We used a state-of-the-art ResNet architecture pre-trained on ImageNet dataset. Therefore, we focused on a simpler task consisting in predicting a banner as ‘effective’ or ‘ineffective’. We define a banner as ‘effective’ when admitting a CTR above a specific threshold and ‘ineffective’ when under a second specific threshold. Practically, we set those threshold as to divide our dataset between the 30% most effective and 30% most ineffective banners. To prove

superiority of machine learning over human, we asked seven members of SMN to try classifying manually few banners. In that sense, we train several architectures and measure the impact of .adding data others than image features to the model. Our intuition here is that an image itself cannot contain enough information to make the prediction accurate, additional metadata are needed. In this regard, we gradually include metadata in the model and evaluate the performances thereafter. Our latest experiment includes ImageNet labels as log-probabilities. Further we use grad-CAM technique [8] to generate heat-maps corresponding to each 'effective' and 'ineffective' classes. Thus, we visualize which part of the network is mostly decisive in the last convolutional layer of our network. This technique is applied to the entire test set. However, due to copyright issues only one sample can be displayed in this paper.

4.2 Training Details

For each architectures we used a dataset composed of 35,108 banners as described in subsection 3.1. Therefore we divided our dataset in two splits of which represents 80% and 20% of the dataset for the train set and the test set respectively.

Furthermore, to transform our problem into a classification problem two CTR threshold values are determined on the train set such that two different classes are obtained: the 30% highest and lowest CTR values, referred as top30 and bottom30 classes. As a consequence, the dataset size is reduced to 60% of its original size corresponding to 21,064 banners.

For the training itself, we implemented the model using PyTorch framework and used one TITAN Xp as GPU. Moreover, we used SGD with momentum of 0.9 as optimizer and Cross Entropy as loss. We used a learning rate of 1e-4, with weight decay of 1e-3 and a batch size of 32 to try reducing overfitting [9]. Regarding the implementation, we incorporate metadata in the form of a one-hot vector as input of the MLP.

5 RESULTS AND DISCUSSION

5.1 Results

In the following section we present the results obtained after training different architectures described in the above section. The results show the accuracy obtained after the training of several models on our dataset, considering top30 and bottom30 classes. Each architecture's tag described in Table 1 corresponds to the data used during training. During this study, we trained 4 different architectures described in subsection 3.2, gradually increasing the amount of metadata. As a result, 61.9% accuracy is obtained using metadata and log-probabilities compared to 64.1% when using image features only.

Further, when using devices as metadata and image features at the same time an even higher accuracy of 66.5% is achieved. Next, we increase the number of metadata, including the device, size and category group of the image. In this scenario, the metadata input size is 35 and the accuracy reaches its peak of 69.3%. The last experiment includes the maximum number of information: size, device, category group, ImageNet log-probabilities as MLP input, as well as the image features. In this case, the accuracy falls to 64.6% (see Fig. 5). In addition we conducted several experiments using marginal thresholds values (see Table 1).

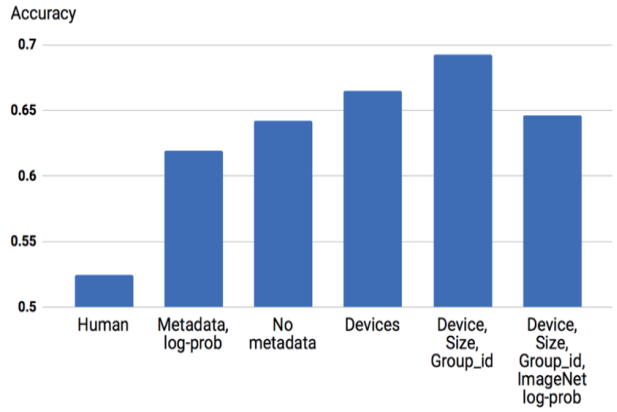


Figure 5: Accuracy obtained with different architectures.

Threshold (%)	Accuracy (%)
50	58.691
40	58.604
30	69.258
20	69.211
10	66.272

Table 1: Accuracy obtained for different threshold values.

Once the previous results obtained, we generate two heat maps using grad-CAM technique [8] for each banners of the test set. Each heat map highlights the part of the image that contributes to either being 'effective' of 'ineffective'. On Fig. 6, the part of the banner where it is written "Machine Learning" in Japanese is highlighted as contributing to make the CTR higher. Same process demonstrate that the part where "Full-scratch" in Japanese is highlighted as contributing to make the CTR lower.

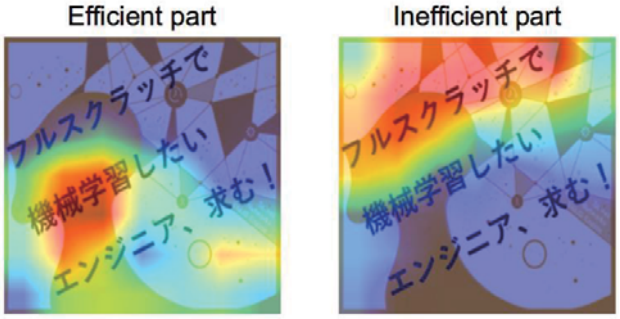


Figure 6: grad-CAM application.

Finally, manual classification were directed by seven members of SMN among 100 randomly chosen pictures from the test set. Three of those members have been Artificial Intelligence Laboratory members for 3 years, two have been working in SMN for around 1.5 year and the last two members are working in "Advertising Banner Team" for less than a year. Manual classification resulted in 52.7% accuracy.

5.2 Discussion

In this subsection we discuss the results obtained in the preceding one. First, we noted that the accuracy using only metadata is lower than when using only image features. This suggests that

the banner itself contains more decisive information than advertisement metadata and ImageNet labels.

Moreover, Fig. 6 demonstrates the significance of metadata for CTR classification as the accuracy steadily increases with the quantity of metadata. Even though some redundant information can be found in the image features and the metadata, the accuracy obtained using both combined demonstrates that each feature is separately decisive and must be included.

However, the last model including the most important amount of data as input shows an accuracy of 64.6 % slightly higher than 64.1% obtained with image features only. Our explanation is that the information contained within the 1,000 log-probabilities is somehow redundant with the feature-extracted information. Adding those information increased overfitting. Better regularization could help solving this problem, unfortunately this was not conducted in this study due to time constraints.

Therefore, using grad-CAM technique [8] to understand deeper the model decision-making [13] appears promising. Here the result is coherent with actual job market. As machine learning is currently popular, job-seekers might be appealed by those words. Nonetheless, implementing machine learning from scratch is not common as most user prefer utilizing framework and other ready-to-use tools.

Furthermore, Table 2 shows that the accuracy is higher for smaller threshold values. This is expected as a lower threshold implies important visual differences between banners. The exception is the accuracy observed for top10 and bottom10. In this scenario, only 20% of the total dataset is used and smaller dataset have been proven to impact unfavorably deep learning models.

Overall, every result obtained is significantly higher than human performance. This situation expresses the actual difficulty of the task and even though our model still has a considerable margin of progression, it seems to surpass human capabilities.

6 CONCLUSIONS AND FUTURE WORK

Through this study, we addressed a key point of banner advertisement that CTR prediction is. In this field, the common way to estimate any banner efficiency without actually delivering them is empirical. As it is, this process in time-consuming and expensive for advertisers. Thus, offering decisive clues to dissociate different banners is primordial. While many factors influence an image's CTR, our experiments expose the adversity of CTR prediction. As results subsection 5.1 highlights, advertisement-related professionals cannot produce a good estimation off-hand. Concerning our best classifier, an accuracy approaching 70% can be achieved and outperforms considerably human performance. The impact of metadata have been demonstrated, improving by 7% point the prediction accuracy. Additionally, metadata by itself can be used to achieve 61,9% accuracy compared to 62,8% when using image features only. This points out that even though the image itself contains more decisive information than metadata, both have separated impact and need to be taken into account simultaneously.

Furthermore we believe that our results can fairly be improved using other visual recognition technologies such as Optical Character Recognition (OCR). All the banners used were provided by Japanese advertisement companies. This implies that content information can be extracted as well as visual information using OCR. Eventually, we have the intention to forthwith conduct real-world experiments to validate our model.

ACKNOWLEDGMENTS

We thank So-net Media Corp. for providing the ad image dataset.

REFERENCES

[1] Michael Fire and Jonahtan Schler. 2015. Exploring Online Ad Images Using a Deep Convolutional Neural Network Approach, arXiv:1509.00568. Retrieved from https://arxiv.org/abs/1509.00568.

[2] Junxuan Chen, Baigui Sun, Hao Li, Hongtao Lu and Xian-Sheng Hua. 2016. Deep CTR prediction in display advertising. arXiv:1609.06018. Retrieved from https://arxiv.org/abs/1609.06018.

[3] Kaixiang Mo, Bo Liu, Lei Xiao, Yong Li and Jie Jiang. 2015. Image Feature Learning for Cold Start Problem in Display Advertising. In IJCAI'15 *Proceedings of the 24th International Conference on Artificial Intelligence*. AAAI Press, Buenos Aires, Argentina, 3728–3734.

[4] Haibin Cheng, Roelof van Zwol, Javad Azimi, Eren Manavoglu, Ruofei Zhang, Yang Zhou, Vidhya Navalpakkam. 2012. Multimedia Features for Click Prediction of New Ads in Display Advertising. In *Proceedings of the 18th ACM SIGKDD international conference on Knowledge discovery and data mining*. ACM Press, 777–785.

[5] Alex Krizhevsky, Ilya Sutskever and Geoffrey E. Hinton. 2012. ImageNet classification with deep convolutional neural networks. In *NIPS'12 Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1*. Curran Associates Inc., Lake Tahoe, Nevada, 1097-1105.

[6] Kaiming He, Xiangyu Zhang, Shaoqing Ren and Jian Sun. 2015. Deep Residual Learning for Image Recognition. arXiv:1512.03385. Retrieved from https://arxiv.org/abs/1512.03385.

[7] Tiezheng Ge, Liqin Zhao, Guorui Zhou, Keyu Chen, Shuying Liu, Huiming Yi, Zelin Hu, Bochao Liu, Peng Sun, Haoyu Liu, Pengtao Yi, Sui Huang, Zhiqiang Zhang, Xiaoqiang Zhu, Yu Zhang, Kun Gai. 2018. Image Matters: Visually modeling user behaviors using Advanced Model Server. arXiv:1711.06505v2. Retrieved from https://arxiv.org/abs/1711.06505.

[8] Ramprasaath R. Selvaraju, Michael Cogswell, Abhishek Das, Ramakrishna Vedantam, Devi Parikh, Dhruv Batra. 2016. Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization. arXiv:1610.02391. Retrieved from https://arxiv.org/abs/1610.02391.

[9] Nitish Shirish Keskar, Dheevatsa Mudigere, Jorge Nocedal, Mikhail Smelyanskiy, Ping Tak Peter Tang. 2017. On Large-Batch Training for Deep Learning: Generalization Gap and Sharp. arXiv:1609.04836v2. Retrieved from https://arxiv.org/abs/1609.04836.

[10] Jun Wang, Weinan Zhang, Shuai Yuan. 2017. Display Advertising with Real-Time Bidding (RTB) and Behavioural Targeting. arXiv:1610.03013v2. Retrieved from https://arxiv.org/abs/1610.03013.

[11] Karen Simonyan, Andrew Zisserman. 2014. Very deep convolutional networks for large-scale image recognition. arXiv:1409.1556. Retrieved from https://arxiv.org/abs/1409.1556.

[12] Corey Lynch, Kamelia Aryafar, Josh Attenberg. 2015. Images Don't Lie: Transferring Deep Visual Semantic Features to Large-Scale Multimodal Learning to Rank. arXiv:1511.06746v1. Retrieved from https://arxiv.org/abs/1511.06746.

[13] Matthew D Zeiler, Rob Fergus. 2014. Visualizing and Understanding Convolutional Networks. arXiv:1311.2901. Retrieved from https://arxiv.org/abs/1311.2901.

[14] Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun. 2015. Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification. arXiv:1502.01852v1. Retrieved from https://arxiv.org/abs/1502.01852.

Convolutional Recurrent Neural Network による方向指示器の認識

Turn Signal Recognition by Convolutional Recurrent Neural Network

萩 亮太 [*1] 米陀 佳祐 [*1] 菅沼 直樹 [*1]
Ryota Hagi Keisuke Yoneda Naoki Suganuma

[*1] 金沢大学
Kanazawa University

Autonomous vehicle is effective in reducing traffic accidents. A behavior prediction for surrounding vehicle is one of the important functions for autonomous vehicle. This behavior prediction is generally based on moving and posture information which are recognized using range sensors such as laser and radar sensors. This study focused on the behavior prediction about lane changes and intersection driving for surrounding vehicles. When the surrounding vehicles change lane and turn left-or- right, they turn on their turn signal. To adopt turn signal information lead to predict such behavior in advance. This paper describes the method to recognize blinking turn signal using Convolutional Neural Network (CNN) and Recurrent neural networks(RNN). Two types of network models are investigated and evaluated the performance for daytime dataset during public load driving. As a result, one of networks operate with 6.25[FPS] and obtain almost 90[%] of recognition accuracy.

1. 緒言

近年, センサやカメラを使用した衝突回避システムなどの自動車の安全に対する技術の向上により交通事故の件数が減少している. さらなる交通事故件数の減少を目的として自動運転自動車の開発が行われている.

自動運転自動車に使用されている要素技術として, 周辺環境認識が挙げられる. 周辺環境認識において周囲の移動物体の位置と運動を考慮しながら自動運転自動車の走行軌道を最適化するにあたり, 周辺車両の行動予測が重要な技術である. その周辺車両の行動予測において従来の手法では, レーザレーダやミリ波レーダなどの距離センサの情報から周辺車両の速度や加速度及び姿勢角などを認識し, この運動情報を用いて数秒先の状態を算出している. 本研究は方向指示器という運転者が周囲に行動を示す手段を従来手法に取り入れることにより, より早い行動予測を目指す. 方向指示器の情報を使用することで, 路肩停止中の車両や対向車がいる場合での交差点での右折待ちの車両に対して効果が期待できる.

方向指示器認識の先行研究として [Fröhlich 2014]がある. Fröhlich らはステレオカメラの画像から車両位置を特定し, 差分画像を用いて方向指示器の点灯を認識する. その認識結果を時系列に収集したものに高速フーリエ変換(FFT)を行うことで周波数のスペクトルを算出する. 算出した周波数スペクトルに対して AdaBoost[Freund 1997]に適用することで方向指示器の点滅を認識していた. AdaBoost を学習するにあたり, 車両画像からの周波数スペクトルだけでは方向指示器の認識をするのには学習データ数として不足である. そのため, 収集した周波数スペクトルとは異なる, ランダムに生成した周波数スペクトルを学習に使用することで精度の向上を行っている. 一方で, この手法ではステレオカメラを使用しており, システムが大規模になる課題もある. そこで先行研究[Yoneda 2017]では, 単眼カメラを使用した方向指示器の認識を行ってきた.

先行研究[Yoneda 2017]では, 車に搭載された単眼カメラの画像から手動で切り出した車両画像を Deep Neural Network(DNN)に入力し点灯判定を行い, その結果を収集したものに FFT を行うことにより周波数推定を行っていた.[Yoneda 2017] この手法では時系列の特徴を考慮せず画像 1 枚からの点灯情報のみで判断するため, FFT による周波数推定において誤認識につながりやすい. そこで, 本研究ではフレームからの情報を増やし, 直近 10 フレームの情報を Recurrent Neural Network(RNN)を使用したネットワークに通して方向指示器の認識を行うことで精度の向上を目指す.

連絡先: 萩亮太, 金沢大学, 〒920-1192 石川県金沢市角間町,
Email:hagi@stu.kanazawa-u.ac.jp

2. 先行研究

先行研究[Yoneda 2017]では, 以下のような手順により方向指示器の認識を行っていた.

1) 左右に分割した車両画像を DNN に入力し方向指示器の点灯を判定
2) 直近 10 フレームでの点灯判定に対し FFT を行い, 方向指示器の周波数を推定
3) 推定結果が方向指示器の周波数である約 1.5[Hz]であるかより方向指示器の点滅を判断

この手法において車両画像を左右に分割することにより, 左右どちらが点灯しているかを判断する必要をなくし, 認識が複雑になることを防いでいる. また, このアルゴリズムにおいて, 方向指示器の点灯認識に使用する DNN には AlexNet[Krizhevsky 2012]の構造において各層のサイズを変更したものを使用し, 概略図を図 1 に示す. また, 方向指示器の点灯認識を行うために出力クラスを方向指示器の点灯/消灯の 2 クラスに変更して学習を行っている. この方向指示器認識ネットワークは手動で切り出された車両画像においては 90[%]近い認識精度が得られる. しかし, 3.1 節で述べる DNN により検出した車両画像では認識精度が 72[%]であり, 更なる精度の向上が求められる. この精度低下の原因として, 各フレームでの情報が点灯/消灯のみであり, 1 フレームの誤認識が FFT での周波数推定に大きな影響をもたらすことが挙げられる. そのため, 本研究では各フレームでの情報を増やし, 直近 10 フレームの情報を RNN を使用したネットワークに入力することで方向指示器認識を行い, 精度の向上を目指す.

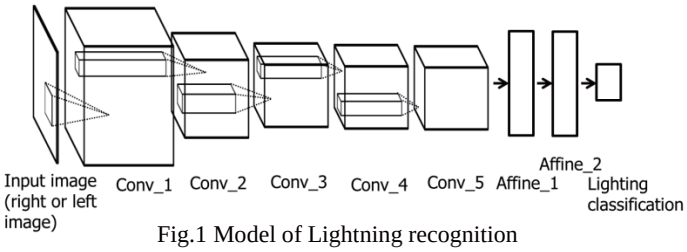


Fig.1 Model of Lightning recognition

3. 提案手法

本研究では，方向指示器の認識に先行研究と同様に車両の連続画像を使用する．そのため，カメラの画像から車両画像を取得する必要がある．先行研究ではこの部分を手動で行っていたため，本研究では認識精度の向上とともに，認識アルゴリズム全体の自動化を目指す．

3.1 方向指示器認識ネットワークの自動化

この節ではカメラ画像を取得してから車両の連続画像を取得するまでの流れを示す．この車両の連続画像を取得するために以下の作業を行う．

- カメラ画像における車両位置の特定
- フレーム間における同一車両の特定

まず，車両画像を切り出すために，カメラ画像内での各車両の位置を特定する必要がある．そのために，本研究では一般物体認識のネットワークである Shot Single MultiBox Detector(SSD) [Liu 2016]を使用し，車両位置の特定を行う．

また，方向指示器の認識には各車両の連続画像が必要となる．そのため，SSD で取得した各車両の位置情報を次のフレームと照らし合わせ，領域の重複度を Intersection over Unit(IoU)から計算する．この重複度が閾値より高いものを同一車両として判断する事で車両ごとにデータの収集を行う．

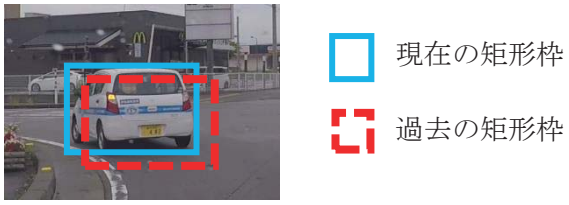


Fig.2 Judgement of same vehicle

3.2 方向指示器認識モデル

この節では，得られる連続画像に対して，RNN を使用した方向指示器の認識ネットワークについて述べる．作成するモデルを図 3, 4 に示す．

本研究ではフレームごとの特徴を[Yoneda 2017]で方向指示器の点灯認識に使用した AlexNet の途中の層の出力から得る．AlexNet の途中の層の出力を使用することで各フレームでの情報量を増やし，精度の向上を目指す．作成するネットワークには，図 1 において画像内での位置に関係した特徴量を持つ Conv_5 から特徴を取り出したモデル，方向指示器の点灯認識に使用している Affine_2 から特徴を取り出したモデルの 2 種類を作成し検証を行う．

作成する 2 種類のモデルはそれぞれ取り出した特徴量 10 フレーム分を収集し，RNN を含んだネットワークに入力し方向指示器の認識を行う．本研究では RNN に Grid Recurrent Unit(GRU)[Cho 2014]を使用する．

(1) Affine Layer の出力を使用したモデル

このモデルでは，本研究室の先行研究において，点灯を認識するために重要な Affine Layer の情報を使用することで，各フレームでの情報量を増やし，方向指示器の認識を行う．

(2) Convolution Layer の出力を使用したモデル

このモデルでは，左右に分割した車両画像をそれぞれ AlexNet に入力し，Convolution Layer から特徴を取得する．この特徴は Affine Layer から取り出す特徴よりも浅い層からの特徴であるため，方向指示器の点灯との関係性の高くない特徴も含まれている可能性がある．しかし，位置情報を持つ特徴を取り出すことができるため Convolution Layer から取得した特徴を左右で結合することで車両画像全体での特徴を作成し方向指示器の点滅の認識に使用する．この特徴を 10 フレーム分取得し，3 次元に畳み込みを行った後，GRU に入力することで方向指示器の点滅を認識する．3 次元での畳み込みは入力に使用している車両の連続画像内で方向指示器の座標の変化を吸収するために使用する．

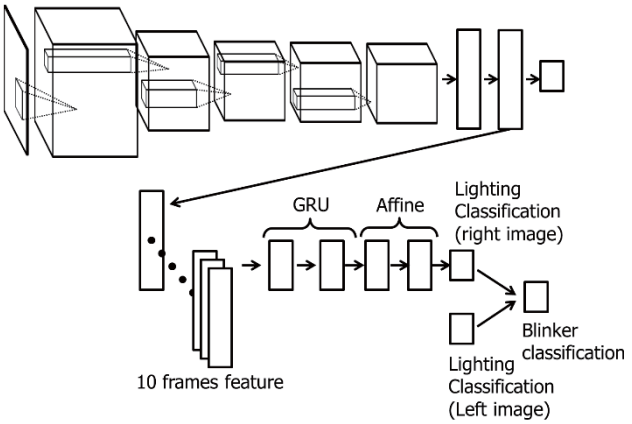


Fig.3 Affine model

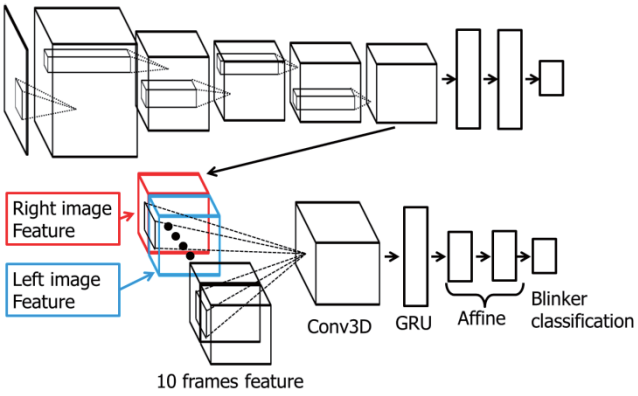


Fig.4 Conv model

3.3 データセット

本研究で行う方向指示器の認識用のデータセットは存在していないため，自作する必要がある．まず，車両の連続画像の切り出しにおいては 3.1 節で述べた SSD による車両画像位置の特定と IoU による同一車両の特定を行うことにより収集を行う．

また正解ラベルを付ける作業において，すべてを手作業で行うには効率が悪いため，先行研究[Yoneda 2017]を使用して方向指示器認識を行う．この方法では間違ったラベルが付いたデータも含まれているため，その部分においては目視で修正を行う．この収集方法により方向指示器の認識に必要な 10 フレーム

の連続画像を No signal:587 本, Right:457 本, Left:361 本, Hazards:2 本の合計 1407 本収集した.

しかし, これだけでは学習に必要なデータ数にはとどかないため, データを拡張することで不足を補う. 本研究では, 拡張方法として, 基本的な方法である,

- 回転
- 明るさ
- コントラスト

の変更に加え, 方向指示器の認識精度向上のため下記の対策を行うことで過学習を抑え, 精度の向上を試みる.

- 太陽光の対策
- 異なる周波数の対策

画像の基本的な拡張結果は図 4 のようになる. 回転は, 道路のうねりなどで実際に傾く可能性がある範囲である±4度に回転させたものを使用する. これに明るさとコントラストそれぞれ元画像を含む, 3 倍に拡張させたものを組み合わせることで収集データ 1407 本を 27 倍の 37989 本に拡張を行った.



original× 0.6　Original　Original× 1.5

(a) Change brightness



Original-4deg　Original　Original+4deg

(b) Change rotate

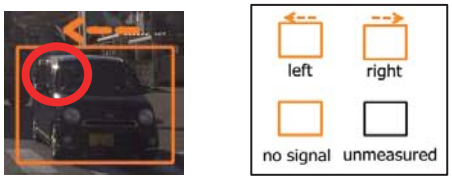


Original× 0.6　Original　Original× 2.0

(c) Change contrast

Fig.4 Example images for data augmentation

上記の基本的な拡張方法を行ったデータにおいて学習を行ったモデルにおいて, 図 5(a)の赤丸で囲った部分に見られるような太陽光への反射を方向指示器の点灯として誤認識しているものが見られた. この対策として, 学習データにランダムで図 5(b)のような白色円の入った画像を重ね合わせたものを消灯として学習を行った.



(a) Example of False recognition by sunlight



(b) Method of Sunlight measure

Fig. 5 Sunlight measure

また, 方向指示器の点滅を認識するにあたり, 0[Hz]付近は消灯, 方向指示器の点滅周波数である 1.5[Hz]は点滅として学習を行うが, それ以外の周波数において学習を行っていないため, 誤認識につながる. この対策に, Fröhlich らが AdaBoost の学習時に行っていた拡張と同様のデータ拡張を行う. Fröhlich らは, 車両の差分画像から点灯を認識し, FFT の出力周波数スペクトルに加えてランダムに周波数スペクトルを作成することで広範囲の周波数への対策を行った. 本研究では図 6 に示すように点灯画像と消灯画像をランダムに並び替えた連続画像を作成し, 消灯として学習を行うことで誤認識の減少を目指す. 本研究では点灯画像と消灯画像を 10:0, 9:1, 8:2 の割合で並び変えた連続画像 5824 本と回転などの拡張により得た 37989 本を合わせた 43813 本の連続画像で学習を行った.

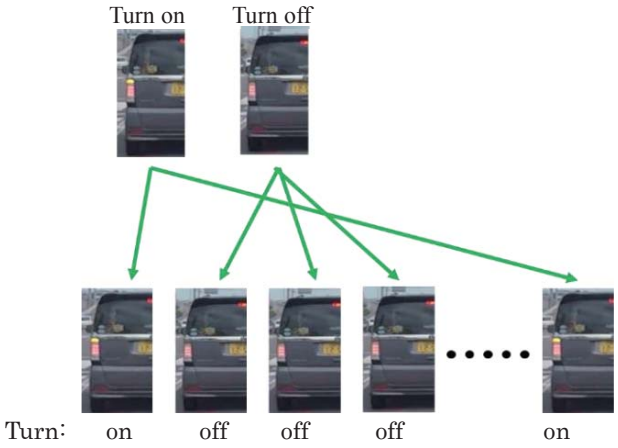


Fig.6 Frequency measure

4. 実験

4.1 学習と評価方法

学習時のハイパーパラメータの条件を表 1 に示す. また, GPU は NVIDIA の GeForce GTX 1080 Ti を 1 台使用して学習と評価を行った.

Table 1 Learning condition

学習方式	ミニバッチ学習
最適化関数	SGD
損失関数	Categorical crossentropy
学習率	0.01
バッチサイズ	8
エポック	30
トレーニングデータ	43813

評価に使用するデータとしては日中の 11 動画 1334 フレームを使用し, no signal: 924 回, right: 783 回, left:425 回の合計 2132 回での精度の比較を行う. 今回使用しているテストデータでは出現回数の低い hazards を収める事ができなかったため, No signal, Right, Left の 3 クラスでの精度とクラス精度の平均精度(Accuracy)の 4 種類において精度の比較を行う. 評価方法として Accuracy を使用することでクラスごとの検出数の差に影響されにくい精度の比較を行う.

4.2 各ネットワークでの精度の比較

テストデータにおける本研究で作成したモデルと先行研究[Yoneda 2017]のモデル(FFT model)での精度を表 2 に示す. Accuracy を比較すると Conv model が最も高い精度を示してお

り, 約 90[%]近くを示している. また, 各クラスでの精度の比較を行うと, FFT model での精度は Right と Left での精度が 50~65[%]であるが, 提案手法ではどちらとも 80[%]を上回っていることから, 20~35[%]の精度の向上が得られた. また, No signal の精度も 90[%]を超えていることから, 全体的な精度の向上を行えた.

Table 2 Accuracy evaluation of networks

	FFT model	Conv model	Affine model
No signal	0.989	0.904	0.929
Right	0.659	0.831	0.890
Left	0.500	0.825	0.864
Accuracy	0.716	0.852	0.894

4.3 学習データの拡張方法での精度の比較

Affine Layer の特徴を使用したネットワークにおいて, 基本的な拡張である, 回転, 明るさ, コントラストの拡張を行ったもの(Base), 太陽光への対策を行ったもの(Shine), 周波数への対策を行ったもの(Freq), 太陽光と周波数の両方の対策を行ったもの(Shine+Freq)の 4 種類において精度の比較を行ったものを表 3 に示す. Accuracy において, 太陽光と周波数両方の対策を行ったものがもっとも精度が高くなっている. 各クラスでの精度を見ると, 太陽光への対策を行うことで No signal の精度を向上しており, 周波数の対策を行うことで, Right, Left の精度の向上が見られた結果両方の対策を行ったものがどのクラスにおいても基本の拡張より精度の向上が見られていることがわかる.

Table 3 Accuracy evaluation of data augmentation method

	Base	Shine	Freq	Shine+Freq
No signal	0.879	0.940	0.885	0.904
Right	0.810	0.736	0.839	0.831
Left	0.741	0.769	0.830	0.825
Accuracy	0.810	0.815	0.851	0.852

4.4 処理速度

今回使用しているカメラは, 7.5[FPS]で動作しており, 各フレームでリアルタイムに処理するための最大時間は$1/7.5[\mathrm{FPS}] = 133[\mathrm{msec}]$となる. 本研究で作成したモデルの平均処理時間は約 160[msec]でフレームレートは 6.25[FPS]となり, リアルタイム処理を行うには改善が必要である. また, 各フレームでの処理時間の内訳において, 方向指示器の認識に 41[%]と半分近くかかっているため, この部分のネットワークの軽量化を行うことで処理時間の向上を目指していきたい.

5. 結言

単眼カメラによる方向指示器の認識において, 本研究では方向指示器の認識システム全体の自動化と方向指示器の認識精度の向上のため, RNN を使用したアルゴリズムの作成を行い, 日中において識別精度約 90[%]を得ることができた.

今後の展望としては, 下記のことを目指す.

- ネットワークの軽量化
- 精度の向上
- 夜間での方向指示器の性能評価

参考文献

[Fröhlich 2014] Frohlich, B., Enzweiler, M., and Franke, U.: Will this car change the lane?-Turn signal recognition in the freqyency domain, in *Intelligent Vehicles Symposium Proceedings*, IEEE, pp.37-42 (2014)

[Freund 1997] Freund, Y., and Schapire, R. E.: A decision-theoretic generalization of on-line learning and an application to boosting, in Journal of computer and system sciences, pp.119-139, (1997)

[Yoneda 2017] Yoneda, K., Hagi, R., Kuramoto, A., Aldibaja, M., Yanase R., and Suganuma, N.: Convolutional Neural Network Based Vehicle Turn Signal Recognition, in *Journal of Advanced Control, Automation and Robotics*(*JACAR*), pp. 102-106 (2017)

[Krizhevsky 2012] Krizhevsky, A., Sutskever, I., and Hinton, G. E: ImageNet Classification with Deep Convolutional Neural Networks, In Advances in *neural information processing systems*(*NIPS*), pp. 1097-1105 (2012)

[Liu 2016] Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., and Berg, A. C.: SSD: Single Shot MultiBox Detector, In *European conference on computer vision*(*ECCV*), pp. 21-37 (2016)

[Cho 2014] Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., and Bengio, Y.: Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation, in *Empiricial Methods in Natural Language Processing*(*EMNLP*), pp. 1724-1734 (2014)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

長時間動作の文脈と身体動作の相互認識

Bidirectional recognition between motion context on long-term observation and human motion

小椋 忠志 *1　稲邑 哲也 *1*2
Tadashi Ogura　Tetsunari Inamura

*1総合研究大学院大学
SOKENDAI(The Graduate University for Advanced Studies)

*2国立情報学研究所
National Institute of Informatics

This paper describes a motion recognition method to reduce recognition error, which has two-layered structure; motion recognition is affected by context estimation in the first layer, and context estimation is affected by motion recognition in the second layer. We introduce an algorithm to integrate the motion recognition by conventional HMM and motion label production by the topic model in the first layer. We also introduce particle filter to estimate and update the context based on the result of motion recognition in the second layer. A set of particles present a probabilistic distribution of motion topics, and motion recognition and particle update procedures are performed on each particle. In an evaluation experiment, we used a sequential motion which is a sequential connection of 33 motion primitives as a long-term observation target. The results showed that the proposed method reduced recognition errors and tracked motion context by topic probability compared with conventional methods.

1. はじめに

長時間人の動作を観測した場合，個々の動作はランダムに発生しているのではなく，とある文脈のもとで実行されている．その個々の動作において，ここでは身体の動作を文章化できる最小の単位を動作プリミティブと呼ぶことにする．具体的には，ホコリをはたく，床を掃く，バイバイする，と言った意味のある時間長で区切った動作のことである．上記の 3 つの動作を例にとると，それらの動作は，掃除という文脈のもとで実行されている動作プリミティブであると言える．また，観測者が掃除をしているという文脈を知ることが出来れば，上記の 3 つの認識結果のうち，バイバイするは誤認識で，似た動作である「窓を拭く」という掃除の文脈の動作プリミティブであったと，認識を改めることが出来る．この例は，ホコリをはたく，床を掃くという動作プリミティブの観測情報から，対象が掃除をしているという文脈を認識し，その文脈情報を基に動作プリミティブの認識を改めるという，相互的な認識が行われている．本研究では，文脈認識と動作認識が相互に影響しあう関係性を利用して長時間の動作に対する文脈推定とそれに基づく動作プリミティブの誤認識低減を目指す．

文脈を用いた動作認識に着眼点を置いた研究をいくつか紹介する．[Sminchisescu 06] は CRF に基づいて時系列データの前後関係性をモデル化し動作の認識を改善している．[Zhang 08] は Shape Context と呼ばれる画像の特徴表現を動作の文脈ととらえ，動作認識手法を提案している．しかしながら，これらの研究は認識のために文脈という表現を利用しているものの，本研究の目指す相互に影響しあう関係性を用いていない．

関連研究との違いを明確にするため，長時間観察における一連の動作を説明するような概念となる文脈をここではトピックと呼ぶことにする．このトピックという表現は，Blei らが提案したトピックモデル [Blei 03] の考え方に基づいている．すなわち，単語認識や文章理解をするために文脈に注目する考え方を，動作認識に応用する．トピックモデルを動作認識に応用する例では，[Wang 09]，[Tavenard 13]，[Ogura 16] が挙げられる．しかし，これらの手法もトピックと動作認識の 2 層が相互に影響しあう関係性を扱っていない．

本研究では，トピックの推定と動作プリミティブの認識の 2 つのプロセスが相互の関係性をもつ仕組みを実現することを目的とする．本稿では，相互認識の計算モデルを提案するとともに，長時間の時系列データに対して認識を行い，文脈情報を用いない手法と比較して，動作の誤認識の低減に効果があることを示す．

連絡先: 小椋忠志，総合研究大学院大学，東京都千代田区一ツ橋 2-1-2，t-ogura@nii.ac.jp

2. 提案手法

図 1および Algorithm 1 に提案する認識手法の処理手順を示す．今どんなトピックであるかという確率を離散の粒の集合で表現し，その 1 粒をパーティクルフィルタの概念と同様にパーティクルと呼ぶ．本手法では動作の文脈を表現するトピックの分布をパーティクルの集合として表現する．k 番目のパーティクル k が所属するトピック q_k は次のようなトピックのインデックスを持つ．

$$j \in \{1, 2, \cdots, J\} \tag{1}$$

ここで J はトピックの総数である．また，パーティクルの集合 $\boldsymbol{Q}$ は次のようになる．

$$\boldsymbol{Q} = \{1, 2, \cdots, K\} \tag{2}$$

ここで，K はパーティクルの個数を表す．このパーティクル集合を用いて現在注目している時刻におけるトピックが j である確率 $P(j)$ を次のように求める．

$$P(j) = \frac{n(\boldsymbol{R})}{K} \tag{3}$$

$$\boldsymbol{R} \in \{k; q_k = j\} \tag{4}$$

ここでの $n(X)$ は X の個数を数える関数で，$\boldsymbol{R}$ は $\boldsymbol{Q}$ のうち q_k が j となる部分集合である．今後の処理はパーティクルごとに動作認識とそのパーティクルの更新が行われる．

各動作ラベル m_i ごとに HMM によってパラメータ λ_i を求めておく．また，トピック j ごとの m_i の出現確率 $P(m_i|j)$ は

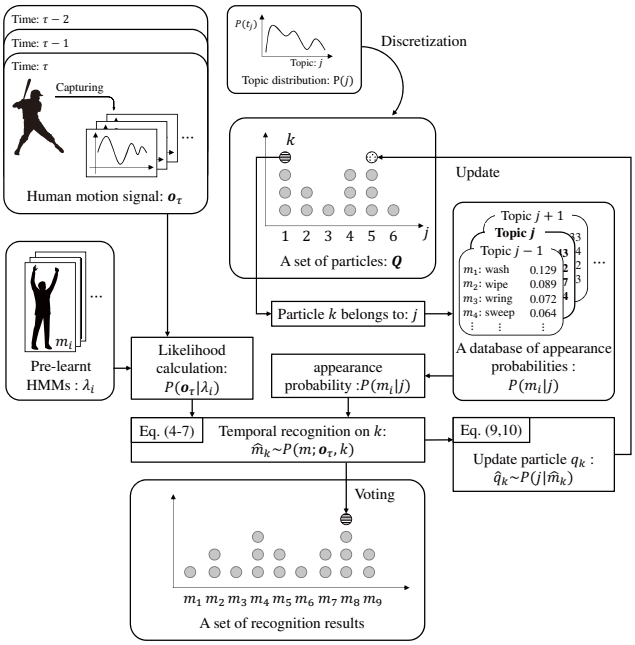


図 1: パーティクルによるトピック情報を用いた動作認識とトピック分布の更新手順

Algorithm 1 Recognition and topic update with particles

for $\tau = 1$ to End of data **do**
  for $k = 1$ to K **do**
    $j = q_k$
    $C = 2\,|\max \log L(o_\tau|\lambda_i)|$ ▷ Eq. (6)
    Calculate α using Eq. (7) ▷ Eq. (7)
    Calculate $S(o_\tau, i, k)$ using Eq. (5) ▷ Eq. (5)
    $P(m; o_\tau, k) = S(o_\tau, i, k) / \sum_i S(o_\tau, i, k)$ ▷ Eq. (9)
    $\hat{m}_k \sim P(m; o_\tau, k)$ ▷ Eq. (8)
    $P(\hat{m}_k) = \sum_{j=1}^{J} P(\hat{m}_k|j)$ ▷ Eq. (12)
    $P(j|\hat{m}_k) = P(\hat{m}_k|j)P(j)/P(\hat{m}_k)$ ▷ Eq. (11)
    $\hat{q}_k \sim P(j|\hat{m}_k)$ ▷ Eq. (10)
  end for
  Update $\boldsymbol{Q}$ using $\{\hat{q}_1, \hat{q}_2, \cdots, \hat{q}_K\}$
  $i_{result} = \arg\max_i n((\hat{m}_k = m_i); \{\hat{m}_1, \hat{m}_2, \cdots, \hat{m}_K\})$
end for

あらかじめ用意することとする [Ogura 16]．次に，時刻 τ で観測された身体動作信号 o_τ に対する尤度 $L(o_\tau|\lambda_i)$ を求める．HMM による認識尤度 $L(o_\tau|\lambda_i)$ および文脈に基づく動作出現確率 $P(m_i|j)$ を用いて，認識スコア $S(o_\tau, i, k)$ を次式のように計算する．

$$\log S(o_\tau, i, k) = \alpha\,(\log L(o_\tau|\lambda_i) - C) + \log P(m_i|j) \quad (5)$$

ここで定数 C は式 (9) で計算する際に相殺されるため任意の値を用いても構わないが，本手法では，$\log L(o_\tau|\lambda_i)$ がすべての場合において負の値になるよう，定数 C を次のように設定する．

$$C = 2\,|\max \log L(o_\tau|\lambda_i)| \quad (6)$$

式 (5) における α は，HMM による認識尤度とトピックごとの動作出現確率の影響度を調整する役割を持ち，本稿では試験的に次のように設定した．

$$\alpha = \frac{\max(\log P(m_i|j) - C)}{\max \log L(o_\tau|\lambda_i)} \quad (7)$$

これは，HMM による認識尤度とトピックごとの動作出現確率の最大値を基準として，両者を統合する際の重みが同一になることを狙ったものである．

続いてパーティクル k における動作認識結果 $\hat{m}_k$ を次のようにサンプリングする．

$$\hat{m}_k \sim P(m; o_\tau, k) \quad (8)$$

ここで，認識結果が m_i となる確率 $P(m; o_\tau, k)$ は次のように求める．

$$P(m; o_\tau, k) = \frac{S(o_\tau, i, k)}{\sum_i S(o_\tau, i, k)} \quad (9)$$

動作認識結果 $\hat{m}_k$ は，パーティクル k と同様に K 個出力され，認識結果の分布を得る．

最後にパーティクルの更新を次のように行う．

$$\hat{q}_k \sim P(j|\hat{m}_k) \quad (10)$$

ここで，動作 $\hat{m}_k$ に基づいて，それが属するトピック j が選ばれる確率 $P(j|\hat{m}_k)$ は次のように求める．

$$P(j|\hat{m}_k) = \frac{P(\hat{m}_k|j)P(j)}{P(\hat{m}_k)} \quad (11)$$

上記の式における $P(\hat{m}_k)$ は $P(\hat{m}_k|j)$ を j について次のように周辺化して求める．

$$P(\hat{m}_k) = \sum_{j=1}^{J} P(\hat{m}_k|j) \quad (12)$$

これらの処理をすべてのパーティクルにおいて実施し，認識結果の出力とパーティクル集合 $\boldsymbol{Q}$ の更新を行う．また，更新されたパーティクル集合 $\boldsymbol{Q}$ を用いて，次の時刻の認識および更新を実行する．

このループ構造を用いることで，トピックの推定とその時間的変化を捉え，動作の認識へ役立てる仕組みを実現する．

3. 検証実験

提案する認識手法により，トピックを推定し認識性能が高まることを確認し，提案手法の有効性を検証する実験を行う．この実験では，時系列に観察される動作を対象として，長時間観察の動作認識におけるトピックの有用性と，トピックの変化に対する本文脈認識法の追従性に焦点を当てる．表 1に実験に使用した動作のラベルとその動作の所属するトピックを示す．また，図 2に実際にキャプチャした動作の様子を示す．対象の動作の中では図 2(a) と図 2(b) の様によく似た身体動作を含んでいる．身体動作信号は，頭・両肩・両手首の各 3 次元と，肘・全指の各 1 次元を対象とした，合計 27 次元の関節角で，モーションキャプチャデバイスを用いて収集される．各動作ラベルにおいて 22 サンプルを収集し，21 サンプルを学習データとして用いる．各動作は 60[Hz] でキャプチャされ，約 4 秒間の長さとする．Left-to-right モデルの HMM を用い，状態数は 16，GMM の混合数は 5 で学習を行った．また認識対象となるテストデータは，収集した 22 サンプルのうち学習データに用いなかった 1 サンプルを，動作ラベル m_1 から m_{33} まで順番に時系列に繋げたものを用いる．

表 2に本実験で使用するトピックごとの動作出現確率 $P(m_i|j)$ の一部を示す．これらは実験者の主観に基づいて手動で作成し

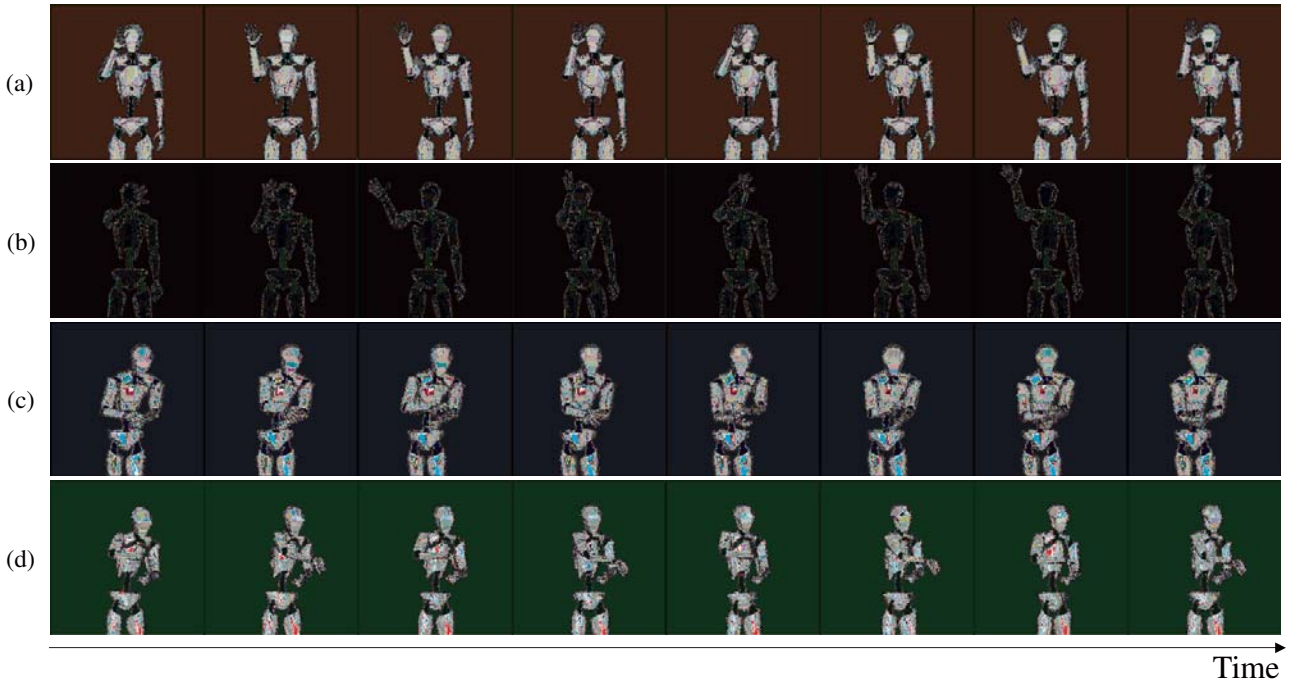


図 2: 対象の動作の様子とよく似た動作の例．(a) m_6: wiping window．(b) m_{33}: waving hand．(c) m_8: washing．(d) m_{13}: frying with pan．(a) と (b) の動作，(c) と (d) の動作はそれぞれよく似ており，誤認識を引き起こしやすい．

表 1: 対象の動作と所属するトピック

m_i: Label name	j: Topic
m_1: dusting off	1: cleaning
m_2: dustpan	
m_3: sweeping floor	
m_4: vacuuming	
m_5: washing	
m_6: wiping window	
m_7: wiping table	
m_8: wringing cloth	
m_9: cutting	2: cooking
m_{10}: dishing foods	
m_{11}: breaking egg	
m_{12}: opening fridge	
m_{13}: frying with pan	
m_{14}: igniting	
m_{15}: mixing	
m_{16}: pouring oil	
m_{17}: replacing	
m_{18}: seasoning	
m_{19}: tearing	
m_{20}: check temperature	
m_{21}: air hockey	3: game center
m_{22}: inserting coins	
m_{23}: driving	
m_{24}: playing drum	
m_{25}: gun shooting	
m_{26}: playing slot	
m_{27}: playing taiko	
m_{28}: victory pose	
m_{29}: bowing	4: greeting
m_{30}: beckoning	
m_{31}: exchanging card	
m_{32}: shaking hands	
m_{33}: waving hand	

た．ここでは，表 1で示した分類と同様にトピックの数 J は 4 で，それぞれのトピック上で動作出現確率の高いもの記載した．またこの実験ではパーティクルの数 K は 400 とし，トピック分布の初期分布として一様分布を用いた．

比較対象として次式のようにパーティクル，トピックを用いずに HMM のみを用いた手法と比較する．

$$i_{result} = \arg\max_i L(\boldsymbol{o}_\tau|\lambda_i) \tag{13}$$

表 2: トピック j ごとの動作出現確率 $P(m_i|j)$ の例

j	m_i:$P(m_i\|j)$	j	m_i:$P(m_i\|j)$
1	m_6: 0.112	3	m_{28}: 0.111
	m_8: 0.110		m_{24}: 0.111
	m_7: 0.109		m_{22}: 0.111
	m_4: 0.107		m_{23}: 0.109
	m_5: 0.106		m_{26}: 0.109
	m_2: 0.105		m_{21}: 0.108
	m_3: 0.104		m_{25}: 0.107
	m_1: 0.104		m_{27}: 0.106
	m_{16}: 0.008		m_2: 0.007
	m_{13}: 0.007		m_3: 0.006
	⋮		⋮
2	m_{17}: 0.076	4	m_{30}: 0.157
	m_{10}: 0.075		m_{32}: 0.154
	m_{12}: 0.075		m_{33}: 0.153
	m_{19}: 0.074		m_{31}: 0.153
	m_{18}: 0.074		m_{29}: 0.150
	m_{15}: 0.074		m_2: 0.013
	m_{11}: 0.074		m_8: 0.013
	m_{20}: 0.073		m_3: 0.011
	m_9: 0.073		m_7: 0.011
	m_{13}: 0.073		m_6: 0.010
	⋮		⋮

ここで i_{result} は認識した動作ラベルのインデックスを指す．図 3にこの手法による認識結果を示す．縦軸は i_{result}，横軸はテストデータに対して区切られた区間のインデックスを示す．青いプロットは認識成功を表し，赤いプロットは認識誤りを表す．この際の認識率は 51.5[%] であった．動作の認識誤りを確認すると，例えば m_6 の窓を拭くという動作 (図 2(a)) と m_{33} のバイバイするという動作 (図 2(b)) は非常によく似た動作であり，それぞれ誤認識が生じていることがわかる．図 4に提案手法を用いた認識結果を示す．認識誤りの数が減り，認識率は 72.7[%] に向上した．その際のトピックの分布の推移を図 5に示す．横軸は同様で，縦軸は式 (3) で計算されるトピックの確率である．また，判例の数字はトピックのインデックスを示している．確率の推移を追うと，おおよそ正しいトピックを追従

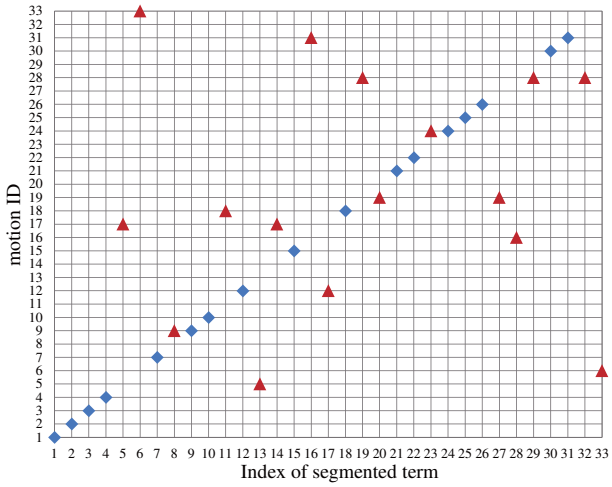


図 3: 提案手法を用いない手法による認識結果

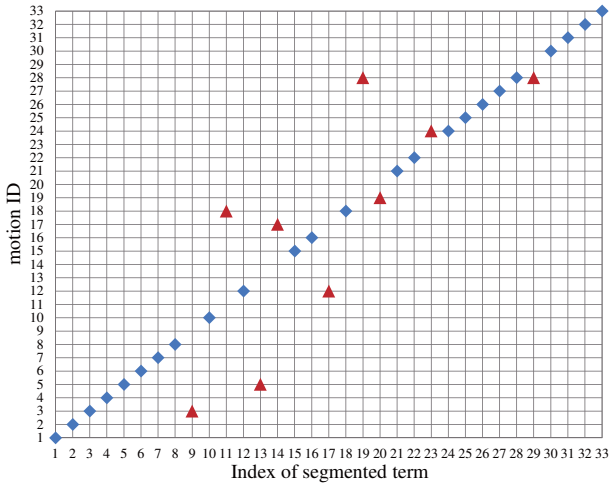


図 4: 提案手法による認識結果

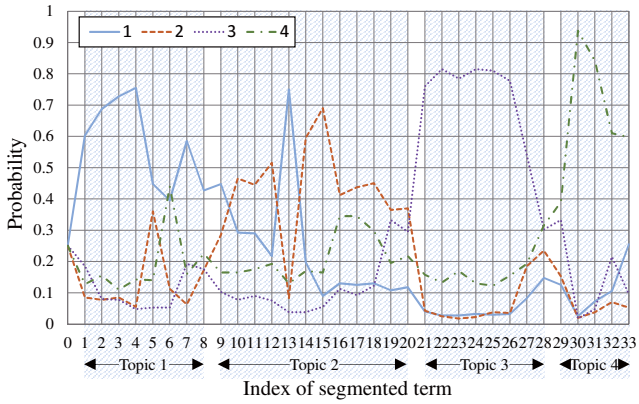


図 5: トピックの分布の推移

できていることが確認できる．また，トピックの情報を基に図 4における m_6 および m_{33} の誤認識を防ぎ，正しい認識を実現していることがわかる．一方で図 5の 13 番目のトピックの確率が突然変動していることが確認できる．図 4の該当箇所を確認すると m_{13} と認識するべきところ m_5 と誤認識している．実際の動作は図 2(c) と図 2(d) に示すように似ている．この誤認識の要因の 1 つは，HMM による認識尤度 $L(\boldsymbol{o}_\tau|\lambda_i)$ において，$L(\boldsymbol{o}_\tau|\lambda_5)$ と $L(\boldsymbol{o}_\tau|\lambda_{13})$ が大きく離れていたため，式 (5) を計算する際にトピックの持つ情報の影響力が少なかったこと挙げられる．これを解決する手段として，HMM の認識尤度に対して，トピックが与える影響力が大きくなるように α の値を調整することが挙げられる

4. おわりに

本稿は，長時間にわたる一連の動作に対して文脈と動作の認識が相互に影響しあう関係性を持つ認識手法を提案し，その有効性を検証した．トピックの分布はパーティクルの集合で表現し，パーティクルごとに動作の認識とパーティクル更新を行う手法を提案した．実験では，4 つのトピックに所属する 33 種の動作を時系列に順番に実施した長時間動作を仮定したテストデータを対象とし，トピック情報を用いない従来手法と比較して，認識率を向上させた．また，長時間観察においてトピックの変化を追従できることを確認した．

今後は，式 (5) における α の値をより認識性能が向上するように調整し，トピック認識に対する影響度の検討を行う．また，道具などの環境とのインタラクションや身体部位ごとの動作情報をトピック情報へ影響させることで，本手法の特性を生かした認識を実現する．

謝辞

本研究は，JST，CREST（グラント番号 JPMJCR15E3）の支援を受けたものである．

参考文献

[Sminchisescu 06] Sminchisescu, C., Kanaujia, A., and Metaxas, D.: Conditional models for contextual human motion recognition, Computer Vision and Image Understanding, Vol. 104, Iss. 2, pp. 210–220, (2006).

[Zhang 08] Zhang, Z., Hu, Y., Chan, S., and Chia, L.-T.: Motion Context: A New Representation for Human Action Recognition, In Proceedings of the European Conference on Computer Vision (ECCV), pp. 817-829, (2008).

[Blei 03] Blei, D. M., Ng, A. Y., Jordan, M. I.: Latent Dirichlet Allocation, Journal of Machine Learning Research 3, pp. 993–1022, (2003).

[Wang 09] Wang, Y., and Mori, G.: Human action recognition by semilatent topic models, IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI), Vol. 31 No. 10, pp. 1762–1774, (2009).

[Tavenard 13] Tavenard, R., Emonet, R., Odobez, J.-M.: Time-sensitive topic models for action recognition in videos, In Proceedings of Conference on Image Processing (ICIP), pp. 2988–2992, (2013).

[Ogura 16] Ogura, T., Sakato, T., and Inamura, T.: Human motion recognition based on topic model, In Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), pp. 3533–3534, (2016).

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

紙付箋抽出における位置取得と解像度を両立する付箋抽出機構の試作

On Simultaneous Recognition of Multiple Paper Sticky Notes with Position Detection and High-resolution

伊藤 栄俊 *1　大囿 忠親 *1　新谷 虎松 *1
Eishun Ito　Tadatika Ozono　Toramatsu Shintani

*1名古屋工業大学大学院工学研究科情報工学専攻
Department of Computer Science, Graduate School of Engineering, Nagoya Institute of Technology

We are implementing a system that digitizes paper sticky notes. In order to recognize the positional relationship of sticky notes, it is necessary to take a picture from a position where the sticky note can be viewed from the top. However, the distance between the camera and the sticky notes affects the precision of the extraction of the content of the sticky note.When photographing nearby to accurately read the contents of the sticky notes, information around the sticky notes is lost, making grasping the positional relationship between the sticky notes difficult.There is a trade-off relationship between the extraction precision of the sticky notes and acquisition of the positional relationship between the sticky notes. Therefore, in this paper, we estimate the positional relationship between sticky notes by using a visual inertial odometry. By recognizing the position information at the time of photographing in the virtual space and integrating the extracted information after the photographing in the virtual space by the visual inertial odometry, the relationship between the extraction accuracy and the acquisition of the position information in a trade-off relationship problem.

1. はじめに

会議において，作業中に紙の付箋を利用し，その後，再利用のために紙の付箋の情報を電子化することが望まれている．紙の付箋は，発想時おける利便性に優れている反面，再利用性が劣るという欠点がある．本研究では，実世界型電子付箋システム Mahoca を開発している．Mahoca は，紙の付箋（物理付箋）を電子化し，付箋の再利用を支援するシステムである．電子化された付箋情報をもとに関連情報の推薦などを実現している [Ito 18]．付箋の電子化に関する従来手法では，付箋の絶対位置の取得および重なった付箋の認識に課題が残っていた．本稿では，自己位置認識技術を利用することで，これらの問題点を解決した，新たな付箋の電子化手法を提案する．

2. 付箋の電子化における課題

本研究の目標は，物理付箋と電子付箋の境界をできるだけ小さくし，電子付箋も物理付箋と同じように扱えることである．これまで，物理付箋を電子化する際，物理付箋をカメラで撮影し，付箋の情報を抽出する機構を開発した．

ここで付箋の利用される具体的な例として，アイディア出しなどを行うブレインストーミングを想定する．ブレインストーミングなどの状況において紙の付箋が利用される場合，紙の付箋間の位置関係に意味が付与されていることがある．例えば，並列した概念であれば横に並べ，繋がる出来事であれば縦に並べるなどがある．

付箋の抽出精度と付箋間の位置関係の取得は，トレードオフの関係にある．こうした，互いの紙の付箋の位置関係を把握するためには，付箋が置かれている面を俯瞰できる位置から撮影する必要がある．しかし，カメラの位置と付箋の位置の距離に比例して，付箋の内容の抽出の精度が落ちる．逆に，付箋の内容を正確に読み取るために近くで撮影した場合，付箋周辺の情報が失われ，付箋間の位置関係が取得できない．

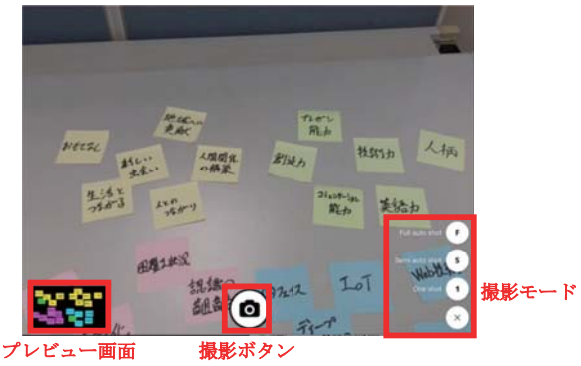


図 1: 付箋を撮影している時の画面

そこで，本研究では，自己位置認識機能を用いて付箋間の位置関係の推定を行う．自己位置認識により，撮影時の位置情報を仮想空間上で把握し，撮影後の抽出情報を仮想空間上で統合することで、トレードオフの関係にある，抽出の精度と位置情報の取得の関係性の問題の解決を行う．

3. 仮想撮影領域を用いた付箋の抽出

付箋間の位置関係を把握するために，自己位置認識を利用した．自己位置認識では，現在の三次元空間上におけるデバイスの位置とカメラを向けている方向を認識することができる．本手法では，Apple の ARKit[ARKit] を利用し，自己位置認識を行った．ARKit による自己位置認識では，現実空間の平面を認識し，画像上の任意の座標を現実空間を想定した三次元仮想空間に射影することができる．これにより，付箋を電子化するために撮影を行った位置だけでなく，撮影した領域が現実世界のどこの平面に相当するのかを求めることができる．本手

連絡先: 伊藤栄俊，名古屋工業大学大学院工学研究科情報工学専攻，愛知県名古屋市昭和区御器所町，052(735)5584，ashun@toralab.org

Algorithm 1 仮想撮影領域の統合

```
plane = createPlane(scene)
cards = extractCards(plane)
if cards.size > 0 then
    attachCardsToPlane(plane, cards)
    planes = popPlanes()
    if planes.size > 0 then
        planes.append(plane)
        mergePlanes(planes)
        pushPlanes(planes)
    else
        pushPlane(plane)
    end if
end if
```

法では，この仮想三次元空間への射影を利用した．撮影した仮想空間上の撮影領域を仮想撮影領域と定義し，電子化された付箋を仮想撮影領域ごとに紐付けることで，相対的な位置関係を決める．仮想撮影領域は以下の式で定義する．仮想撮影領域 $\mathbb{S}$ は，撮影時の画像データ $image$，矩形領域を定める頂点座標 $\mathbb{N}$，抽出された付箋 $\mathbb{C}$ である．

$$\mathbb{S} = \{image, \mathbb{N}, \mathbb{C}\}$$
$$\mathbb{N} = \{p_1, p_2, p_3, p_4\} : \text{平面を定義する矩形の頂点座標}$$
$$\mathbb{C} = \{c_0, c_1, ...c_k\} : \text{抽出された付箋}$$

Algorithm 1 に仮想撮影領域の統合アルゴリズムを示す．撮影された仮想撮影領域同士を統合することで，一つの平面としてまとめることができる．仮想撮影領域の統合アルゴリズムでは，撮影された画像データをもとに仮想撮影領域 $plane$ と，電子付箋群 $cards$ を生成する．撮影した領域内に付箋が存在した時，仮想撮影領域の統合を行う．統合する仮想撮影領域は，作業領域に退避させておき，作業領域に仮想撮影領域が存在しないときは統合処理を行わず，作業領域に退避のみ行う．作業領域に仮想撮影領域が存在する時は，各仮想撮影領域を含む minimum bounding box を求め，新たな仮想撮影領域として生成する．

4. システム構成図

付箋抽出時のシステムの実行例を図 1 に示す．図 1 の下部中央のボタンは，抽出を行う際のトリガーボタンとなっている．右側の赤枠でに示されている部分は，撮影時の方法を切り替えるインタフェースとなっている．撮影モードは，3 種類あり，一度の撮影のみで抽出を行う単発モード，複数回の撮影で仮想撮影領域を統合するセミオートモード，ビデオ撮影と同じように撮影可能なフルオートモードがある．図 1 の左側の画像がプレビュー画面のサムネイル画像である．サムネイル画像を選択すると，プレビュー画面が開き，電子付箋に対する削除や更新が可能となる．

図 2 にシステム構成図を示す．本システムは，センサーデバイス，付箋抽出機構，プレビュー画面，サーバから構成される．センサーデバイスでは，抽出したい付箋を含む画像データの取得や，位置情報に関する取得を行う．特に，本研究では ARKit を使用することを想定しているので，iOS デバイスとなる．付箋抽出機構はセンサーデバイスで取得した情報を元に紙付箋の電子化を行う．主に紙付箋抽出機構と仮想空間管理機構からなる．紙付箋抽出機構では，取得した画像データから，

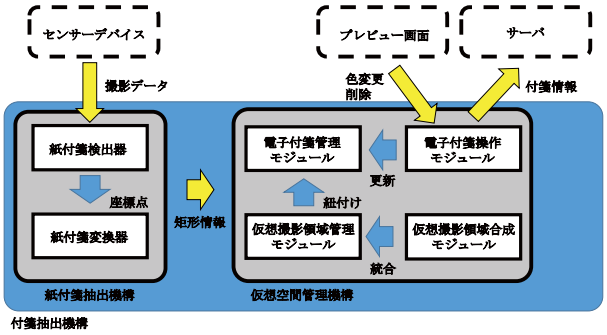


図 2: システム構成図

付箋領域の推定を行う．紙付箋抽出機構ではまず，撮影時の画像情報に加え，現実空間における撮影領域の大きさと画像中での付箋の大きさ情報を元に，画像中の付箋らしい矩形領域を判定する．これは，紙付箋検出機構で行う．検出された結果を元に，　電子化のための情報を整理する．電子付箋は 3 次元空間上の位置情報を元に定義される．よって，撮影時の二次元画像平面情報が仮想空間の三次元空間のどの平面に相当するのかを計算し，付箋の座標点を変換する必要がある．紙付箋変換器では，紙付箋検出器での結果を元に 3 次元空間への変換を行う．変換後の付箋に相当する矩形情報を元に電子付箋を生成するのが仮想空間管理機構である．仮想空間管理機構では，電子付箋の生成と電子付箋群に相当する仮想撮影領域の管理を行う．仮想空間管理機構は 4 つのモジュールからなる．付箋抽出時の撮影情報を元に仮想撮影領域を生成する仮想撮影領域管理モジュール，仮想撮影領域を統合し，電子付箋群の位置関係を定める仮想撮影領域合成モジュール，紙付箋抽出機構から得られる付箋の矩形領域情報を元に電子付箋を作成する電子付箋管理モジュール，電子付箋とプレビュー画面やサーバ間のインタフェースとして働く電子付箋操作モジュールの 4 つである．また，プレビュー画面は抽出結果を確認する画面である．センサーデバイスに iOS デバイスを想定するため，プレビュー画面はセンサーデバイスと同じ端末にフィードバックされることを想定している．プレビュー画面では，誤認識した結果に対して修正を行うことができ，電子付箋の削除や色の変更を行う．作成された電子付箋は最終的にサーバにアップロードされ保存される．

5. おわりに

本研究では，自己位置認識機能を用いて撮影時の位置情報を取得することで，紙の付箋を電子化する際に失われてしまう付箋同士の位置関係を把握することができた．本研究の貢献として，付箋の内容を正確に取得するために付箋の近くで付箋を撮影しつつも，付箋間の位置関係を把握することができるため，精度と位置関係の取得のトレードオフの関係の問題を解決した．

参考文献

[Ito 18] 伊藤栄俊，大囿忠親，新谷虎松: 実世界型電子付箋のための ARKit を用いた自己位置認識による紙付箋認識について．インタラクション 2017，pp.244–248，(2017).

[ARKit] https://developer.apple.com/jp/arkit/

機械学習を用いたATM異常行動検知技術の検討

ATM Anomaly Behavior Detection with Machine Learning: A Study

ファンチョンフィ[*1] Phan Trong Huy　岸礼子[*1] Reiko Kishi　山本一真[*1] Kazuma Yamamoto　増田誠[*1] Makoto Masuda

沖電気工業株式会社 経営基盤本部 研究開発センター
Corporate Research and Development Center, Oki Electric Industry Co., Ltd.

In recent years, a steady increase in ATM (Automatic Teller Machine)-related crimes has been reported overseas. One of which is ATM skimming; the act of installing skimming devices (a.k.a. skimmers) to ATM to illegally copy information from the magnetic stripes of cash cards, credit cards, etc. As skimmers grow smaller and more sophisticated, detecting such devices with conventional sensors is facing great difficulties. With the purpose of strengthening ATM security, we are developing image sensing technologies that detect anomaly behaviors including ATM skimming acts using video feeds capturing the ATM operational area. Machine learning is employed to represent normal behaviors; the degrees of separation from such representation can be used as an indicator for abnormality level. In this article, we discuss the application of well-known methods (Subspace Representation of [Nanri 2004] and Gaussian Mixture Model of [Yu 2006]) to modelling ATM normal behaviors in order to detect ATM anomaly behaviors. Additionally, we also brief several considerations to realize high anomaly detection accuracy in real practice.

Keywords: ATM, Anomaly Detection, Machine Learning

1. はじめに

近年、海外ではATM（Automatic Teller Machine）に対する犯罪の増加が報告されている。犯罪として、キャッシュカードやクレジットカードの磁気記録情報を「スキミングカードリーダー」と呼ばれるスキミング装置を用いて不正に読み取って偽造カードを作成するという行為がある。スキミング装置は小型化する傾向があるため、従来のセンサーによる検知は難しくなってきている。そこで、我々はATMセキュリティの強化を目的に、ATM操作部の映像からスキミング装置取り付け動作などの異常行動の検知を実現するための技術開発を行っている。

ATM 異常行動検知においては、機械学習を用いて正常動作を集約するモデルを生成し、そのモデルからの分離度を基に異常検知を行う。本稿では、代表的な正常モデルの生成方法（[南里 2004]の部分空間法と[Yu 2016]の混合正規分布モデル）を ATM 操作部の映像に適用し、異常の検知ができることについて紹介する。今後、実運用を想定した取り組みとして ATM 取引情報の活用及び追加学習の実現を行っていく。

2. 異常検知技術の概要

機械学習を用いた異常検知は基本的にデータの特徴抽出処理と識別処理の 2 つの工程から成り立つ。

コンピュータビジョン分野では、映像中の動きを解析するための特徴抽出方法が多く存在する。例として、CHLAC 特徴[Kobayashi 2004]・HOOF 特徴[Chaudhry 2009]・MBH 特徴[Dalal 2006]などがある。本稿では、ATM 操作でみられる細かな手の動作を表現するために、ST-Patch（Space-Time Patch）特徴[Murai 2007]を用いる。式(1)に表すように、ST-Patch 特徴は時系列画像の勾配情報を用い、動作の“見え”及び“動き”の変化を表現する特徴である。

$$F = \{ \sum P_x^2, \sum P_x P_y, \sum P_x P_t, \sum P_y^2, \sum P_y P_t, \sum P_t^2 \} \quad (1)$$

ここで、P_u は u 軸での勾配である。（x、y、t）は時系列画像の（横、縦、時間）軸を表す。

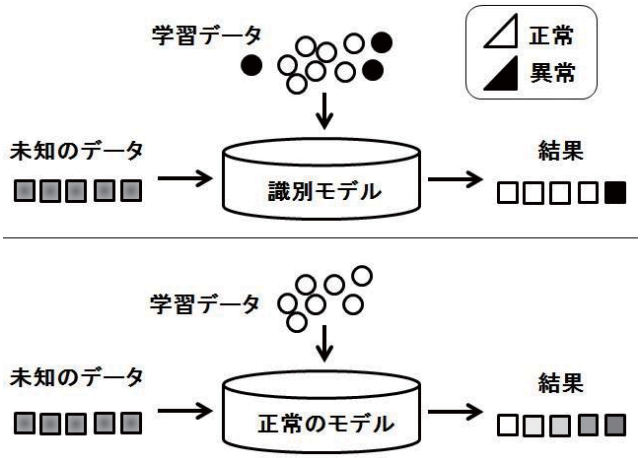


図 1：異常検知のアプローチ
（上）教師あり学習；（下）教師なし学習

識別処理として、教師あり学習（Supervised）・教師なし学習（Unsupervised）といった 2 つのアプローチが存在する[Omar 2013]（図 1）。教師あり学習では、正常データと異常データを別のクラスとして学習し、未知のデータを正常か異常かへクラス分類を行う。教師なし学習では、正常データを用いて正常を表現するモデルを学習する。正常モデルからの分離度を異常度として扱う。

連絡先：ファンチョンフィ、沖電気工業株式会社
経営基盤本部 研究開発センター、埼玉県蕨市中央 1−16−8、
メール：phan586@oki.com

本稿では、教師なし学習のアプローチを選定した。その理由は、ATM 異常行動検知において、スキミング行為以外の未知の異常行動も検知できるためである。我々は、動画での異常検知に実績のある正常モデルの学習手法として、[南里 2004]の部分空間法と[Yu 2016]の混合正規分布を ATM 異常行動検知という問題に適用することを提案する。

2.1 部分空間法

部分空間法はクラス分類手法の一つである。部分空間法を用い正常動作の部分空間を構成し、その部分空間からの距離を異常度として扱うことができる(図 2)。[南里 2004]のように、まず、学習対象の正常データ(*N*次元)を用い主成分分析(PCA)を行う。その結果である固有ベクトル群(主成分) $U=[u_1,..,u_N]$のうち、上位の k 固有ベクトルを使って、正常動作の部分空間 $U_k=[u_1,..,u_k]$を構成することができる(※k はハイパーパラメータである)。正常部分空間からの未知データ xの距離 dは式(2)のように求めることができる。

$$d^2 = x^Tx - x^TU_kU_k^Tx \quad (2)$$

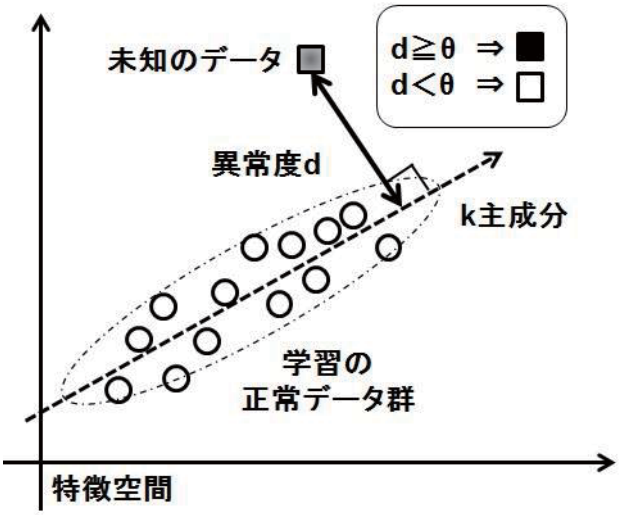


図 2:部分空間法による異常検知

2.2 混合正規分布モデル

混合正規分布モデル(Gaussian Mixture Model)は複数の正規分布の重みづけ和を用いたデータを確率密度分布として表現する手法である。[Yu 2016]のように EM 法(Expectation Maximization)を用いることで、正常データを表す混合正規分布を求めることができる。未知データ xの正常としての確率 $P(x)$は式(3)のように算出することができ、この値を用いて異常判定を行うことができる。

$$P(x) = \sum_{i=1}^{m} w_i p_i(x|\mu_i,\sum_i) \quad (3)$$

ここで、$p_i(x|\mu_i,\sum_i)$は平均 μ_i 分散$\sum_i$を持つ正規分布を表す。w_iは正規分布 iの重みである。ハイパーパラメータ m は正規分布の数を示す。

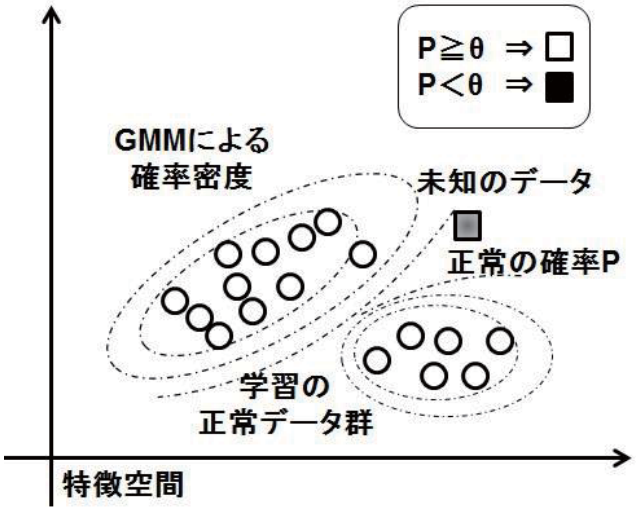


図 3:混合正規分布による異常検知

3. ATM 異常行動の映像データを用いた検証

3.1 検証データ

ATM 異常行動検知への適用可否を検証するために、正常 205 動作(学習用 175 動作＋検証用 30 動作)および異常 24 動作を用いる。本稿では、図 4 のように ATM の上部にカメラを設置し ATM 取引の動作を撮影する。また、カード挿入口付近の領域に絞って検証を行う。

●正常動作として、通常の引きだし・預け入れが含まれた複数パターンのデータを用いる。

●異常動作として、スキミング装置取り付けの複数パターンのデータを用いる。

3.2 検証の結果

表1は手法ごとの AUC(Area Under the Curve)・EER(Equal Error Rate)といった指標[Davis 2006]で評価した結果を表す。AUC は異常検知の全体の良さを表す数値であり、EER は正常を誤検知するエラー率が異常を未検知するエラー率が等しい時のエラー率を示す。

本稿では、部分空間法及び混合正規分布モデルのハイパーパラメータを複数試し、学習・評価を行うことにより最適なハイパーパラメータを選定する。評価結果により、部分空間法と混合正規分布モデルは同等の精度で異常の検知ができることがわかる。それぞれ約 13.5%の正常動作が誤検知されたときに、約 86.5%(=100%-13.5%)のスキミング装置取り付け動作を異常として検知することができる。

表 1:評価結果

指標	部分空間法	混合正規分布モデル
AUC (高いほうが良い)	95.0%	94.4%
EER (低いほうが良い)	13.5%	13.6%

3.3 考察

いずれの手法においても比較的高い異常検知精度となり、実運用への活用が期待できる。しかし、撮影時に想定していない正常の動作パターンは誤検知となる共通の傾向がみられる。例として、柄の財布や紙類を持ちながら ATM 取引を行うという動作などの異常値が高く誤検知されやすい。要因としては、学習対象のデータにこのような動作パターンの割合が非常に低いことが考えられる。全体と比べ割合の少ないパターンに対しては、学習により求める正常モデルに反映されず、評価時の異常値が高くなってしまうためである。

混合正規分布モデルは複数の正規分布で構成されるため、部分空間法よりも多様性のある正常動作を表現することができる。ただし、今回の正常データにはパターンが少ない特異な正常行動が含まれていたため、部分空間法および混合正規分布の手法の得意・不得意に大きな差が見られなかった。しかし、様々なバリエーションに対して大量にデータがある場合は混合正規分布モデルのほうが効果的だと考えられる。さらに、混合正規分布モデルにより、部分空間への変換処理を省略しつつ、比較的高い検知精度が実現できることを確認した。今後、実運用に向けては混合正規分布モデルの検討を進めていく予定である。

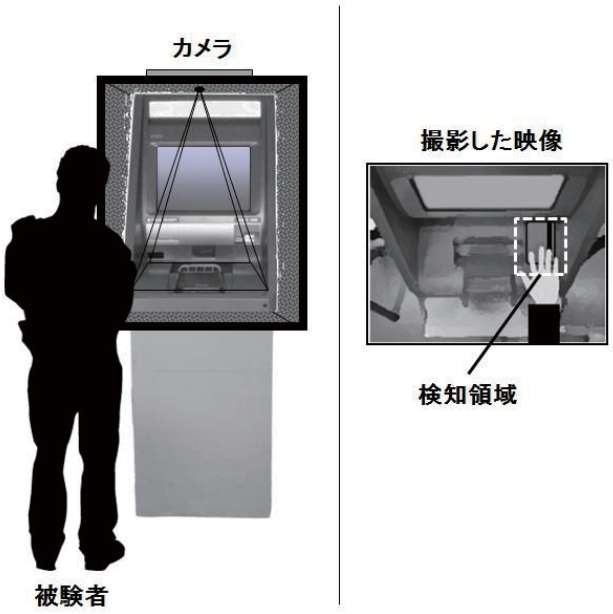


図 4:(左)撮影時のシステム構成;(右)映った操作部の映像

4. 実運用に向けて

4.1 ATM 取引情報の活用

ATM 操作において操作の位置や取引の内容によって起こり得る動作が全く異なるため、単体の正常モデルでの異常検知は困難である。そこで、我々は検知領域を複数設けることと共に、ATM 取引内容に合わせた正常モデルを複数学習することで高い検知精度を実現しようとしている。

4.2 追加学習の実現について

実運用では、設置現場の環境(照明や ATM の外観など)と学習時の環境が異なる状況が生じる。そのため、事前に学習した正常モデルは設置現場で起こる正常動作が表現できなくなり、誤検知につながると考えられる。そこで、我々は設置現場のデータを追加して学習する技術の導入を検討している。

●部分空間法(2.1 節)の場合:CCIPCA[Weng 2003]や IPCA[Skocaj 2003]のアルゴリズムを用いることで、正常動作を構成する主成分を更新することが可能である。

●混合正規分布(2.2 節)の場合:[Engel 2010]や[島田 2007]が提案した手法により、混合正規分布モデルのパラメータ(正規分布の数・重み・平均・分散)を更新し、追加のデータに適応させることができる。

5. おわりに

我々は ATM セキュリティの強化を目的に、ATM 操作部の映像からスキミング装置取り付け動作の検知(異常検知)を実現するための技術開発を行っている。本稿では、機械学習を ATM 操作部の映像に適用することにより、正常と異常の境界線があいまいである端末の操作などに対し、異常行動が検知できることを示した。今後、実運用に向け、ATM 取引情報の活用や追加学習の導入を検討していく予定である。

参考文献

[Weng 2003] Juyang Weng et al., “Candid covariance-free incremental principal component analysis”. PAMI 2003.

[Skocaj 2003] D. Skocaj and A. Leonardis, “Weighted and robust incremental method for subspace learning”. ICCV 2003.

[南里 2004] 南里卓也, 大津展之, "複数人動画像からの異常動作検出" , 電子情報通信学会技術研究報告. PRMU 2004.

[Kobayashi 2004] T.Kobayashi and N.Otsu, “Action and Simultaneous Multiple-Person Identification Using Cubic Higher-Order Local Auto-Correlation”. ICPR 2004.

［Davis 2006］ Jesse Davis et al., “The relationship between Precision-Recall and ROC curves”. ICML 2006.

[Dalal 2006] Navneet Dalal et al., “Human Detection Using Oriented Histogram of Flow and Appearance”. ECCV 2006.

[Murai 2007] Yasuhiro Murai et al., “Combined Object Detection and Segmentation by Using Space-Time Patches”. ACCV 2007.

[島田 2007] 島田敦士、有田大作、“適応的な分布数の増減法を利用した混合ガウス分布による高速な動的背景モデル構築”.信学論 2007

[Chaudhry 2009] Rizwan Chaudhry et al., “Histograms of Oriented Optical Flow and Binet-Cauchy Kernels on Nonlinear Dynamical Systems for the Recognition of Human Actions”. CVPR 2009.

[Omar 2013] Salima Omar, “Machine Learning Techniques for Anomaly Detection: An Overview”. IJCA 2013.

[Yu 2016] Hao Yu et al., “Video Anomaly Detection Based on Mixed Statistic Feature”. International Journal of Signal Processing Systems 2016.

Oral presentation | Organized Session | [Organized Session] OS-15

[1O2-OS-15a] [Organized Session] OS-15

Tue. Jun 5, 2018 3:20 PM - 5:00 PM Room O (2F Kaimon)

[1O2-OS-15a-01] Artificial Intelligence: Challenge to the Real World Problems

○Hideyuki Nakashima[1] （1. University of Tokyo）

3:20 PM - 3:40 PM

[1O2-OS-15a-02] Future Artificial Intelligence Technology: Real World Problems in Implementation

○Yoichi Motomura[1] （1. The National Institute of Advanced Industrial Science and Technology）

3:40 PM - 4:00 PM

[1O2-OS-15a-03] Utilization of Artificial Intelligence and its Human Resource Development in Kansai Area

○Joe Suzuki[1] （1. Osaka University）

4:00 PM - 4:20 PM

[1O2-OS-15a-04] How to Improve Manufactual Industrial Business with Design Thinking

○Nami Harada[1], Yoichi Motomura[1] （1. ADVANCED INDUSTRIAL SCIENCE AND TECHNOLOGY）

4:20 PM - 4:40 PM

[1O2-OS-15a-05] Optimization of Food supply chain by AI technology

○Tatsuhiro Matsuoka[1], Yoichi Motomura[2] （1. Sigmaxyz inc., 2. National Institute of Advanced Industrial Science and Technology）

4:40 PM - 5:00 PM

©The Japanese Society for Artificial Intelligence

3:20 PM - 3:40 PM (Tue. Jun 5, 2018 3:20 PM - 5:00 PM Room O)

[1O2-OS-15a-01] Artificial Intelligence: Challenge to the Real World Problems

○Hideyuki Nakashima[1] (1. University of Tokyo)

Keywords: AI applications

Invited talk about "Challenge to the real world problems in Artificial Intelligence"

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

次世代人工知能技術：社会実装の課題

～フレームと新たな評価指標の探索～

Future Artificial Intelligence Technology: Real World Problems in Implementation

本村 陽一
Yoichi Motomura

産業技術総合研究所 人工知能研究センター
Artificial Intelligence Research Center, The National Institute of Advanced Industrial Science and Technology

Currently, the practical application of artificial intelligence is dramatically advanced by machine learning using big data. Industrial structure reform and the smart society called Society 5.0 are also expected to be realized. In this paper, real world problems in implementation are discussed. In order to understand internal representation of learning result, Future artificial intelligence project is proceeded. The spiral of two difference tasks, optimization to evaluation function and searching the new evaluation function are introduced as a new challenging issue.

1. はじめに

機械学習に基づく人工知能技術の産業応用を進める上での課題が顕在化している．その一つは人工知能の学習結果が人にとって理解できない，ブラックボックスとなってしまうことへの懸念である．また人工知能におけるフレーム問題は数学的構造に起因するため，機械学習に基づく人工知能においても当然問題になる．社会実装を進める際には，何がフレームとなっているのかを明示的に扱うアプローチが重要である．そこで学習結果や前提としているフレームを説明可能，解釈可能，介入可能なものとする「人間と相互理解できる次世代人工知能技術」の研究開発プロジェクトが進められている[本村 2016a]．本発表では，プロジェクトの推進と，企業との概念実証(PoC)や調査研究を通じて明らかになった社会実装上の課題について議論する．

2. サイバーフィジカルシステム化のための AI

Internet of Things(IoT)が爆発的に進み，実空間における様々な現象がビッグデータとして記録され，それらが計算機空間でモデル化，シミュレーション可能になる Cyber Physical System(CPS)の概念がある．IoT デバイスの普及とそこから生成されるビッグデータを活用することで，社会の現象を計算モデルとして構築すると新たな現象が計算可能になる．確率的潜在意味解析(PLSA)とベイジアンネットを統合した手法(図 1)の応用事例が多数ある[本村 2016b][小西 2017]．従来難しかったビッグデータからのベイジアンネットの構造学習が，PLSA によって前処理(離散化)されることで，実空間の活動(5W1H)が時間、空間、人の情報とともにデータ化され、これが PLSA により情報量の高い潜在クラスに確率的に分類、すなわち確率ベクトルにコード化される。簡単のために所属確率が高いベクトルを 1 に、それ以外を 0 のように二値化されると考えると、実空間の現象の統計的な共起関係が PLSA の尤度極大化により、できるだけ情報量が高くなるようにディジタル化したことに相当する。さらにこのディジタル化された現象間の関係がベイジアンネットによって構造化されることで、時間や場所、人の特性、行動、対象物などがいわゆる「いつ」「どこで」「誰が」「何を」「どうした」という形で関係性や交互作用を確率的に表現できるように計算モデル化される。この計算モデルの入出力が実社会のサービスとして実行され、新たな実空間の現象を生じさせるならば、これは、計算モデルの空間(サイバー)上で、実空間(フィジカル)の現象が密に連携したサイバーフィジカルシステムの一つの実装方法となっている。サイバー空間で最適化された計算結果をスマホのアプリやサービスを通じて人々に提供し，意思決定や行動を支援することで，良い現象の発生確率を上げ，事故などの良くない現象の発生確率を下げるという意味での物理世界の制御，マネジメントが可能になる．

連絡先：本村陽一，産業技術総合研究所 y.motomura@aist.go.jp,http://staff.aist.go.jp/y.motomura/

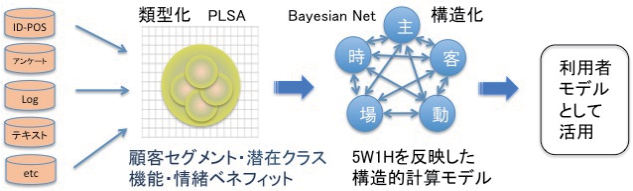


図 1 確率的潜在意味解析（PLSA）とベイジアンネット

3. 社会実装上の課題：フレーム問題と評価指標

産業の中で起こる様々な活動についてもビッグデータとして観測し，これを先に述べた方法でディジタル化，計算モデル化することで，サイバーフィジカルシステムを適切に構成することで制御，マネジメントに適用することができる．しかしここでいくつかの問題が顕在化する．一つは観測されたデータの背後にあるフレームが計算モデルには陽には反映されない問題である．また，制御，マネジメントのためには何らかの評価指標を導入することになるが，現状ではそれは学習データの教師信号として与える他なく，これがビッグデータとして観測されたものの中で一貫して存在しているとは限らない（実際には，多くの場合複数の暗黙的な評価指標が混在することもよくある）．こうした実社会における問題を回避する方法として，評価指標やフレームを画一化したコンテストやコンペティション、ゲームによるアプローチが人工知能技術の評価方法として存在する．しかしここで有用性が明らかになった技術を実際の社会の中で利用しようとすると、フレームの問題と評価指標の問題が大きな壁となる．

2017 年までに行われた人工知能技術の応用プロジェクトを調査したところ，活動が継続している事例では評価指標につい

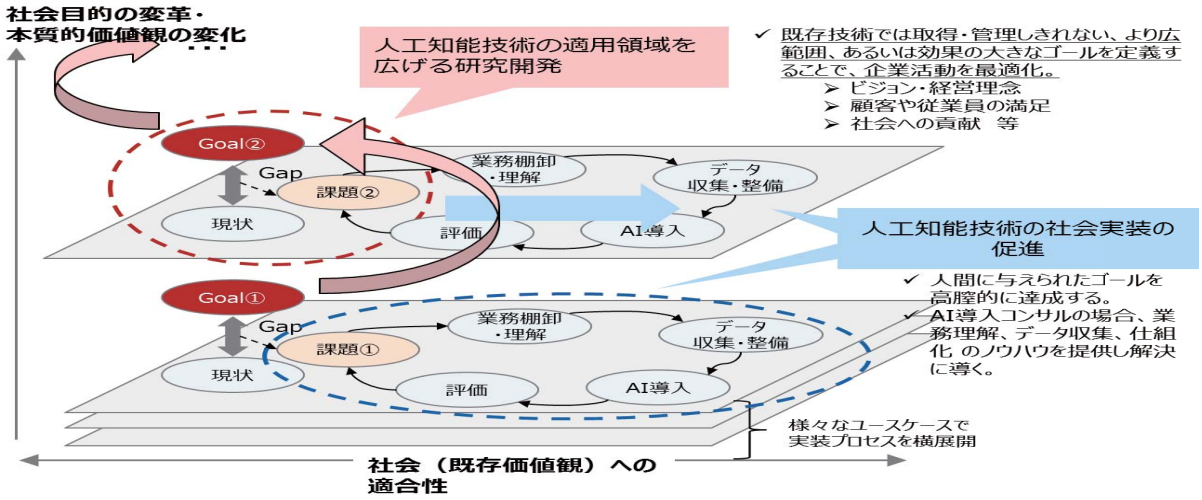


図 2 既存評価指標の最適化(横軸)と新たな指標の探索(縦軸)

て，初期の仮説からスタートし，これを少しずつ拡大していく，いわゆるアジャイル型のアプローチが見られた(図 2)．特定の評価指標に対する最適化(横軸)が従来の人工知能技術のタスクであるのにたいして，プロジェクトの実際の推進では新たな評価指標の探索(縦軸)をプロジェクト推進担当者が属人的に行っている．今後，この縦軸となる探索についてメタレベルの人工知能技術としての定式化，技術開発の重要性が明らかとなった．発表では調査事例と考察について報告する予定である．

4. おわりに

次世代人工知能技術により，サイバーフィジカルシステムを構築することで複雑な社会問題の解決や産業構造変革の推進している．実際に応用する場面において，状況依存性の高い説明変数を網羅的に収集するためには，データを観測する環境が日常的な利用環境とできるだけ合致するように統制しておく必要があるため，実サービスと調査・研究を一体化すべきであるとする「サービスとしての調査・研究(Research as a service)」という概念も提唱されている[本村 2009]．調査・計算モデル化の段階とその計算モデルを用いた応用を切り離すことなく，社会実装を進めながら，そこで得られるビッグデータを網羅的に収集する．このアジャイル型のサイクルを持続的に続ける中で，今後さらに背後に想定しているフレームと最適化のための評価指標についても探索対象とすることが重要である．これによってフレームの明示化と新たな評価指標の探索を人が望ましい形で管理できることが，人と相互理解する次世代人工知能の社会実装の鍵になる．問題の背後にあるフレームを機械学習におけるデータを補完する知識として扱うことで，データ・知識融合の手法として考えることができ，さらに評価指標の探索についても自動化を進めることが今後の課題である．

次世代人工知能技術を活用した情報システムと実サービスの開発・応用を通じて，多くの事例が生まれつつあるが，現在はこの事例の蓄積を組織的に分析し，共通の特性や有効なアプローチを抽出し，共通のフォーマットを開発することで，知識共有や再現性を高める活動が開始されている．こうしたビッグデータと人工知能技術による産業生産性向上と価値創出を目指した異業種連携を加速するための場づくりとして、産総研内に「人工知能技術コンソーシアム」が設立され、2017 年度 150 社以上の企業が 10 を越えるワーキンググループ，関西，東海，九州の地域支部により活動し、ユーザ参加型の社会実装，技術評価を進めている(図 3)．

人工知能技術を標準的産業基盤として確立し，社会の実サービスの中でビッグデータの収集と計算モデルの構築，活用を持続することでさらに多くの新たな AI 活用サービスの実現が容易になる．そのためには産業基盤のユーザとなるコミュニティの形成を支援する「場」が重要である．AI を活用したサービスシステムが共創的な価値創出を持続的に再現、発展できる仕組みがサイバーフィジカルシステムの社会実装であり，これによって社会や暮らしを今よりもよいものにするという方向性を強く打ち出すことが、人工知能技術により新たな産業や社会構造を変革するために有効であると考えられる。

謝辞

本研究は NEDO 委託事業「人間と相互理解できる 次世代人工知能技術の研究開発」の支援を受けて行われた。

参考文献

[小西 2017] 小西葉子，本村陽一，AI 技術の社会実装への取り組みと課題～産総研 AI プロジェクトから学ぶ，RIETI Policy Discussion Paper Series 17-P-012 (2017).

[本村 2009] 本村陽一，大規模データからの日常生活行動予測モデリング，シンセシオロジー vol.2, no.1, pp.1-11, (2009).

[本村 2016a], 本村陽一，次世代人工知能技術，情報処理学会誌，Vol.57 , no. 5 (2016) pp. 466-469.

[本村 2016b] 本村陽一，第 9 章「ベイジアンネットワークと確率的潜在意味解析による確率的行動モデリング」，確率的グラフィカルモデル，共立出版 (2016)，pp.231-244.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

関西における人工知能の活用、人材育成の事例

Utilization of Artificial Intelligence and its Human Resource Development in Kansai Area

鈴木譲[*1]
Joe Suzuki

[*1] 大阪大学基礎工学研究科
Osaka University #1

This talk will be discussed about utilization and human resource development of artificial intelligence in Kansai area.

1. はじめに

人工知能技術を産業界でいかに活用していくか、またそのための人材をどのようにして育成していくかは、人工知能の研究とは別の次元で重要な問題である。本稿では、人工知能の研究者という視点から、それらの事例を紹介する。何かの議論のきっかけになれば幸いである。以下、2.では AI ビジネス創出アイデアコンテストについて、3.ではおよび関西地区コンソーシアムについて概要を述べ、4 でまとめを行う。

2. AI ビジネス創出アイデアコンテスト

大阪商工会議所(会頭: 尾崎裕)、および産業技術総合研究所人工知能コンソーシアム(代表: 本村陽一氏)が主催した AI ビジネス創出アイデアコンテストには、22 件の応募があつまり、大阪商工会議所会頭賞（賞金100万円）には、ファッションポケット㈱重松路威氏の「人工知能を用いた女性向けアパレルトレンド発信とEコマース」が、人工知能技術コンソーシアム会長賞には、アイリス㈱沖山翔　氏の「咽頭画像の深層学習による診断機器開発」が選ばれた。

2017 年 11 月 17 日	募集開始
2017 年 11 月 29 日	応募説明会
2017 年 12 月 11, 18 日	事前相談(サロン)
2018 年 1 月 16 日	募集締切
2018 年 1 月 17-24 日	書類審査
2018 年 2 月 2 日	事前トレーニング
2018 年 2 月 16 日	公開プレゼンテーション (最終審査)



審査基準

実現性	既存ビジネスと差別化できており、明確かつ現実的な内容であること
収益性	将来的に収益の見込める内容であること
ユーザ視点	ユーザの価値創造が明確な内容であること
社会性	社会課題の解決に向けた内容であること

筆者は、コンテストの審査員という立場で参加した。コンテスト応募者に人工知能学会の専門家は皆無であったが、アイデアには工夫がなされていた。同じ人工知能でも、研究者であれば固有技術の改良をメインのテーマとするところを、応募者はビジネスという観点からサービスを提案していた。

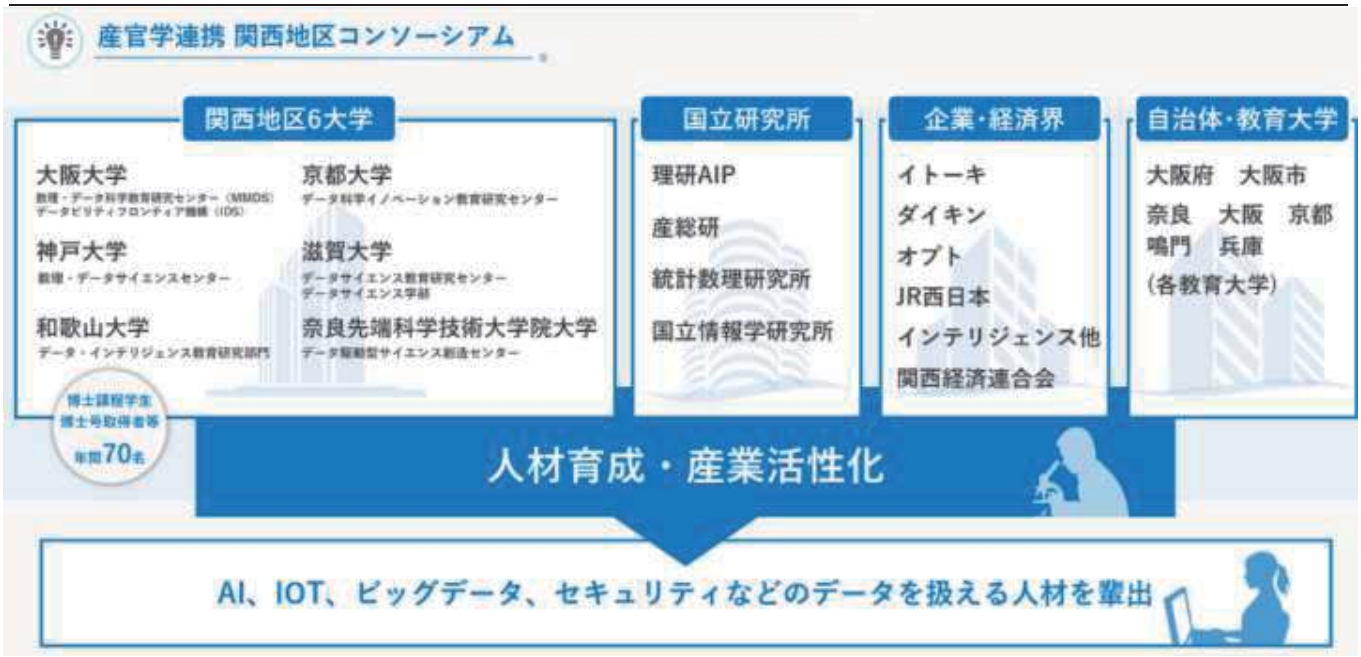
3. 産管学連携 関西地区コンソーシアム

データ関連人材の育成・確保のために文科省が開始したデータ関連人材育成プログラムの一環で、2017 年 10 月から大阪大学を幹事校(6 国立大学)として運営が行われている(写真は、キックオフミーティングのときのもの)。





連絡先 :鈴木譲 j-suzuki@sigmath.es.osaka-u.ac.jp



文科省の本プログラムは、関西地区コンソーシアムを含めて 4 拠点が採択されているが、いずれも以下の基本方針に基づいている。

- 博士課程学生・博士号取得者等の高度人材に対して、データサイエンス等のスキルを習得させる研修プログラムを実施することにより、我が国社会で求められるデータ関連人材を育成し、社会の多様な場での活躍を促進。
- 研修プログラムの開発・実施を行う育成機関が、データ関連人材の雇用を希望する企業、大学等とコンソーシアムを形成し、博士課程学生・博士号取得者等に対して、インターンシップ・PBL 等による研修プログラムを開発・実施することで、各々の専門性を有しながら、データサイエンス等のスキルを習得させるとともに、キャリア開発の支援を実施

関西地区コンソーシアムでは、A: データサイエンス「基礎コース」、B: データサイエンス「実践コース」、C: 医療データ「基礎実践コース」の 3 コースにわけてプロジェクトをすすめている。

筆者は、このうち A コースに参画していて、eラーニングコンテンツの開発(右上が e-ラーニング開発ソフト Camtasia Studio の画面)、セミナーの開催などを行っている(右上のポスターは、3 月 26 日-27 日のセミナーのもの。各日 200 名以上が参加を予定している)。

4. むすびにかえて

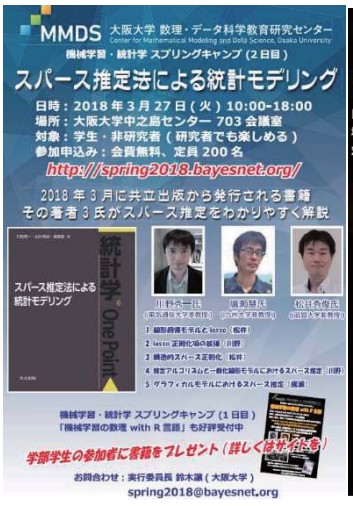
以上、ビジネス創出コンテスト、およびデータ関連人材育成関西地区コンソーシアムの概要を紹介した。

大学の教員は、普段は自分の大学の学生にしか教えていないが、いざ社会人や他大学・他専門の学生を教える段階になると、データサイエンスでは、特に社会人であらためて勉強したいというニーズが高い。セミナーだけでは対応できないので、e-ラーニングでクオリティの高いものを用意して、ある程度のレベルまで達するようにさせる必要があると思われる。

また、データサイエンスの業務経験はないが、数理能力などが卓越していて、再教育次第で活躍する可能性のある社会人も多くいるものと思われる。そのような意味で、データ関連人材育成の事業が成功し、大学の社会への貢献をアピールできたらと思い、意気込んでいる。

謝辞: 発表の機会をいただいた大阪大学数理・データ科学教育研究センター特任教授鈴木貴氏、産業技術総合研究所本村陽一氏に感謝します。







The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

デザインシンキングを用いたものづくりにおける業務の質向上のプロセス

How to Improve Manufactual Industrial Business with Design Thinking

原田奈弥　　本村陽一
Nami Harada　　Yoichi Motomura

産業技術総合研究所
ADVANCED INDUSTRIAL SCIENCE AND TECHNOLOGY

Japanese manufactual industry have made KAIZEN (improvement) for a long time and is assumed to be good quality and development. Artificial intelligence technology will help them their continuous improvement of their products' quality and service. To change our way to business or service to meet our customers' problems or necessity, it is important to create new ideas and evaluate them with process and skill of design thinking. Artificial intelligence technology is useful to estimate both quality of our business or service and idea. To apply artificial intelligence technology to manufactual industry for the first time, there can be some cost and risk to bother their consumers.We suggest how to investigate artificial intelligence application to current manufactual industry and their cost and risk. Then we will show a little example in our presentation.

1. 背景

1.1 ものづくり事業の特徴

日本の、ものづくり事業の一番の特徴は、ある程度以上の歴史や実績があることが挙げられる。ものづくりといわれて最もイメージされやすい製造業は高度成長期以降、日本の経済や技術開発力の象徴として、世界から認められる実績と信頼を築いてきた。広義のものづくりで考えると、農業や建築業、伝統工芸などはもっと歴史が長い。この歴史の中で、世界的な信頼やブランド力を築き上げながら事業を拡大してきた。そのなかで、他の産業と異なり、日本のものづくりがこれまで保有・維持してきたものとして、

- 現在も稼働している事業
- 顧客と顧客からの信用
- 生産や品質、顧客に関わる知識 (データ)
- 生産や品質を維持するためのノウハウ

が挙げられる。地道で愚直な PDCA サイクルに基づく業務の改善が仕事の質を向上させ、実績や信頼を築いてきた。ものづくりの事業や培ってきた技術、信頼は日本のものづくりの財産であり、今後もこれを維持向上していくことが日本のものづくり産業の至上命題である。

1.2 人工知能の活用による業務の質向上

ものづくりを始めとする産業における人工知能には 2 つのタイプが想定される。

- 人の作業を代替する人工知能 → 従来の改善を実施
- 人が能力的にできないことを行う → 創造や革新を実施

人工知能により、より合理的で効率的な業務の質向上のプロセスを図 1 に示す。人の事業やサービスなどを改善する PDCA サイクルで構成される Process と、全体的な方針である Viewing で構成される。Viewing で示される方針に合わせて、人の仕事やビジネスを、人工知能が評価し、改善施策に関する人の判断を助ける。つまり、人工知能の活用による業務の質向上は、これまでのものづくりにおける仕事の進め方を、人工知能によってより効率的に行うものである。

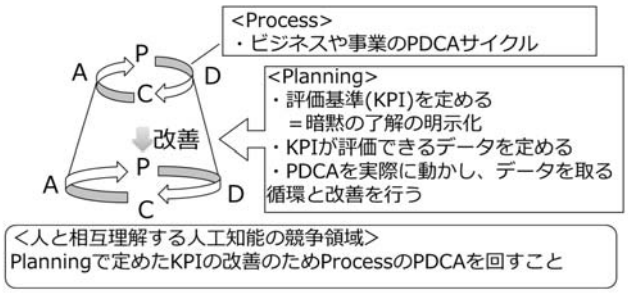


図 1: 業務の質向上のメタプロセス

先行研究や事例はサービス工学の分野で特に多くみられる。サービスにおいては、時間の経過とともに変化するお客様に合わせて事業内容を変えていく必要があり、図 1 と親和性が高い。[本村,2012] では、ベイジアンネットワークなどの数理モデリングを用いた、消費者行動の数理モデリングによる消費者の理解とサービス向上のプロセスを述べ、小売業でのポイントサービスや医療機関でのサービス向上の事例が紹介されている。小売業の分野では、ポイントカードを用いた ID-PoS データの収集によって、消費者個人の行動を継続的に詳細に知ることができる。[原田, 2016]、[山下, 2017] などが、顧客の購買履歴がデータになった ID-POS データを用いて、消費者が購買を行った時間や場所についての分析を行っている。

特に、少子高齢化に伴い、医療や介護の現場の業務の負荷が高くなることが見込まれることから、[Ide,2017] や [本村,2012] で述べられているような、高齢者の行動理解や、それによる医療や地域福祉などのサービス向上や業務の効率化に、人工知能のニーズが高まるということが考えられる。

更に、ビッグデータの観測、収集や人工知能の実装が行われる応用現場でのニーズが、人工知能技術の高度化の動機付けや

連絡先: 原田奈弥，産業技術総合研究所，135-0064 東京都江東区青海 2-4-7，03-3599-8224 ，nami.harada@aist.go.jp

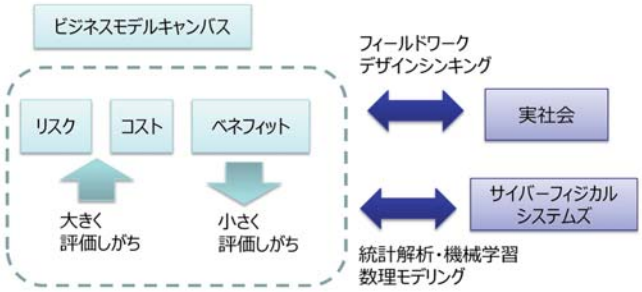


図 2: サイバーフィジカルシステムズが果たす役割

活性化につながり、理論研究の発展を促している。[石垣,2010] や [原田 2017] では、ID-PoS データから、より実用的で実践的、妥当な情報を引き出すためのデータ分析の方法論について述べられている。

このような、人工知能を用いた業務の質改善によって、ものづくりの事業のさらなる顧客価値の向上ができるのではないかと考えている。

2. 本研究のテーマ

本研究では、ものづくりの現在実際に機能している事業において、人と相互理解する人工知能を用いて、現在の顧客や信用を失うことなく、いかにして創造的で顧客価値の高い事業を行っていくか、実社会への人工知能技術の社会実装を念頭に置いてプロセスを提案する。技術の社会実装とは、技術の応用だけではなく、社会やビジネスの実課題の解決まで行うものと考えている。ビジネスの実課題をいかにして定義づけを行い、実装によるメリットだけでなく、コストやリスクも評価を行い、現実的なコストやリスクに抑えた中でいかにしてベネフィットを生み出していくのか、そのプロセスを、産総研 人工知能技術コンソーシアム ものづくり WG の中で検討してきた。本論文にて、その検討を通じて得られたプロセスを紹介する。

さらに、そのプロセスの現在進行中の事例として、人工知能技術コンソーシアム ものづくり WG の中でオープンイノベーションで進めているユースケースを示す。

3. 提案：人工知能のものづくりへの実装プロセス

本研究では、ものづくりにおいて、人と相互理解する人工知能の導入によってイノベーションを起こすには、図 2 のような、実社会とサイバーフィジカルシステムズとの中で、ビジネスモデルをブラッシュアップしていくことを提案する。

実社会で実際に存在するニーズや課題へのソリューションであることが必要である。そのためには、実際の顧客や現在の事業の現場を実際に見て回るフィールドワークや、新しい事業や仕組みを考えるためのデザインシンキングが必要となる。

一方で、開発のコスト低減や効率化のためには、機械学習や数理モデリングを用いたサイバー空間での検証が重要な役割を果たす。サイバーフィジカルシステム内でものづくりの条件などを検証できれば、現在の生産ラインや顧客へのストレスを抑えることもできる。サイバーフィジカルシステムズ内で検証を行うには、

- ニーズ
- データ

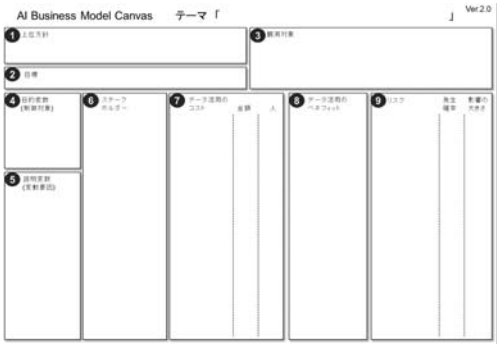


図 3: AI 版ビジネスモデルキャンバス

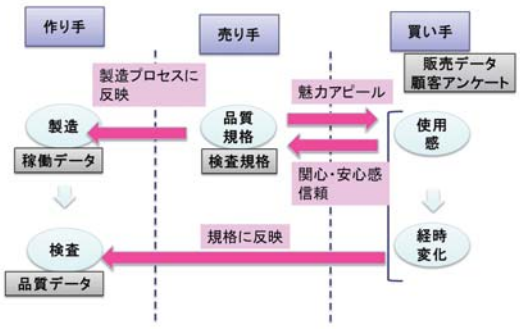


図 4: データバリューフローマップの例

- シーズ

が必要である。データが収集されている実際のビジネスの場が実社会での人工知能のフィールドであり、データの収集や活用に関しての関係者がステークホルダーになる。

ものづくり WG での活動を通じて考えられた、これらを組み合わせてものづくりにおいて人工知能でイノベーションを起こしていくプロセスは、

(1) ニーズや課題を決める

(2) デザインシンキングを通してデータの共有による新しい価値を考える

(3) 新しい価値創造のためのステークホルダーを洗い出す

(4) ステークホルダー毎のコスト、リスク、ベネフィットを洗い出し、事業の成立性や価値を検証する

となっている。この流れを促すツールとして、ものづくり WG の活動を通じて、

- データバリューフローマップ
- AI 版ビジネスモデルキャンバス
- データリスト標準フォーマット

を作り、ユースケースつくりを通じて引き続きこのツールの改善を行っている。当日の発表にて、こちらのツールも紹介する。

4. ユースケース

ものづくり WG の活動として、ユースケースの一つとして、PC などに入っているハードディスクの故障予知を目指してデータ活用を進めている。仕事や日々の生活の中でコンピュータに触れたり使ったりする機会が多い。

前述の人工知能導入のプロセスの中で、人工知能の導入に向けたニーズとしては、ハードディスクの故障による日々の生活や事業での不便さの発生防止とした。コンピュータがいつも使えるのが当たり前という前提の中で生活や事業を行っていることも多く、ハードディスクの故障によりコンピュータが使えなくなることは多くの不都合やトラブルとなることが考えらえる。

ステークホルダーは、コンピュータの利用者や管理者である。ステークホルダーそれぞれのコストやリスク、ベネフィットに関しても検討を行った。データ共有の際に多くあげられるリスクとして、機密情報などの対外的に流出してはいけないデータの流出があげられることが多い。コンピュータの利用者の日々の活用に関するデータは個人情報や機密情報を含むことが考えられる。しかし、この事例で用いたデータは、コンピュータが起動中のハードディスクの温度やファンの回転数などの稼働条件と、そのときのハードディスクが良品であるか、不良品であるかのアノテーションのデータであり、データがコンソーシアム内で共有されることに支障のないものになっている。

このデータから、ハードディスクの品質と稼働条件の関係を明らかにし、故障を未然に予測し予防保全を行うことで、コンピュータの利用者や管理者の利便性への貢献を目指して活動している。発表当日はこの現在の進捗も紹介する。

5. 今後の課題

前述のユースケースは現在進行中の事例なので今後も引き続きものづくり WG の活動の中でオープンイノベーションで行うことで、人工知能の社会実装のプロセスについて検討を行う。

人工知能のものづくりにおける実装やそのプロセスの課題は、3 つあると考えている。

一つは、数理モデリングや機械学習などのシーズの向上である。通常の量産工程では、学習データの不良品のアノテーションがつくデータが、良品に対して極めて少ないことが一般的である。その中でも不良品の発生メカニズムをデータから理解し、ものづくりの事業にフィードバックを行うには、サイバーフィジカルシステムズでの数理モデリングや機械学習による検証が必要である。

もう一つの問題は、社会実装を行う組織づくりである。図 2 の中でも示しているように、人工知能の社会実装には、そのフィールドの固有の技術や知識に加え、デザインシンキングや機械学習など、必要な要素技術が複数ある。それぞれの専門家の育成だけでなく、その専門知識や技術の融合によってイノベーションを生み出していくリーダーシップの養成についても今後の課題となるのではないか。

最後の課題は、人工知能やビッグデータの拡大・成長である。図 1 でも示したように、業務の質の改善により、より高度な課題に今後取り組んだり、ものづくりのサプライチェーン間でのデータを統合したりすることで、データや人工知能の知能が成長・拡大することが必要になるとかんがえられる。人工知能の拡大・成長のプロセスとして、すでにあるデータや人工知能のアウトプットから得られた知識から、

(1) データの収集

(2) データの可視化

(3) 現象の分類

(4) 現象が起こる原因の因果推論→行動変容の検討

のプロセスの中で、人工知能の導入時に（１)、（２）と、（２）の結果から、ステークホルダーに共通の問題認識を形成することが、人工知能の成長には重要である。共通の問題認識が、人工知能やデータ活用に対する意識の向上や組織の活性化を促し、これが（４）の行動変容の検討を助ける。これは、改善のための人工知能でも、創造や革新のための人工知能でも同様である。これらのことから、（１）～（４）のプロセスを円滑に進めるためにも、人工知能の導入時のテーマは、導入の時点で確実に成果が出せるものや、組織の中で常に賛成を得られるようなものとするのがよいのではないか。

6. 謝辞

本発表の内容は、産業技術総合研究所が運営する、人工知能技術コンソーシアムのものづく WG の活動の中で検討を行ってきました。特にハードディスクの事例は、株式会社アヤハエンジニアリング 谷昭宏様のデータ提供とリーダーシップの下でハードディスク予防保全部を結成し、活動方針などを議論してきました。有意義な議論の場を与えてくれるコンソーシアムと、有意義な議論に参加して下さった WG の皆様に心から感謝します。

参考文献

[Ide,2017] Ayae Ide,Kazuya Yamashita,Yoichi Motomura and Takao Terano,”Analyzing Regional Characteristics of LivingActivities of Elderly People from Large Survey Data with Probabilistic Latent Spatial Semantic Structure Modeling”, IEEE BigData2017 Workshop,(2017)

[Ishigaki,2010] Tsukasa Ishigaki, Takeshi Takenaka and Yoichi Motomura,”Category Mining by Heterogeneous Data Fushion Using PdLSI Model in a Retail Service”, 2010 IEEE International Conference on Data Mining pp.857-862 (2010)

[赤松 2012] 松幹之, 新井民夫, 内藤耕, 村上輝康, 吉本一穂:サービス工学-51 の技術と実践-, 朝倉書店 (2012)

[石垣,2010] 石垣司, 竹中毅，本村陽一: 百貨店 ID 付き POS データからのカテゴリ別状況依存的変数間関係の自動抽出法, オペレーションズ・リサーチ, 56, 2, (2010)

[石垣,2011] 石垣司, 竹中毅, 本村陽一: 潜在クラスモデルによる流通量販店舗の来店人数予測の精度改善の評価, 人工知能学会全国大会, (2011)

[井手 2016] 井手絢絵，本村陽一:高齢者の生活行動推論のための大規模アンケートデータを用いた確率的潜在意味構造モデル構築，人工知能学会「社会における AI」研究会第 27 回研究会,(2016)

[井手,2017] 井手 絢絵, 川本 達郎, 山下 和也, 本村 陽一:ミクロアグリゲーションを用いた匿名化による確率的潜在空間意味解析, 人工知能学会全国大会,(2017)

[近藤,2017] 近藤那央, 竹内理人, 山下和也, 櫻井瑛一, 本村陽一, 大規模イベントにおける人の行動履歴情報収集とそれを利用したインタラクティブシステムの開発に向けて, 人工知能学会全国大会,(2017)

[原田, 2016] 原田奈弥, 山下和也, 本村陽一: ID 付 POS データによる購買行動の季節変化の分析と視覚化, 人工知能学会 社会における AI 研究会 27 回研究会,(2016)

[原田 2017] 原田奈弥, 山下和也, 黄冬陽, 本村陽一:複雑な構造の経時データ解析におけるモデル選択についての考察, 人工知能学会全国大会 (2017)

[本村,2011] 本村陽一, 竹中毅, 石垣司: 条件付層別差分モデルによる需要予測の高精度化, 人工知能学会全国大会, (2011)

[本村,2012] 本村陽一, 竹中毅, 石垣司:サービス工学の技術 ビッグデータの活用と実践, 学校法人東京電機大学東京電機大学出版局 (2012)

[山下, 2017] 山下和也, 原田奈弥, 黄冬陽, 吉開朋弘, 本村陽一: ID-POS データによる来店行動・購買行動の潜在的時空間意味構造分析, 人工知能学会全国大会,(2017)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

人工知能技術による生産流通最適化

Optimization of Food supply chain by AI technology

松岡　竜大[*1]
Tatsuhiro Matsuoka

本村　陽一[*2]
Yoichi Motomura

[*1] 株式会社シグマクシス
Sigmaxyz inc

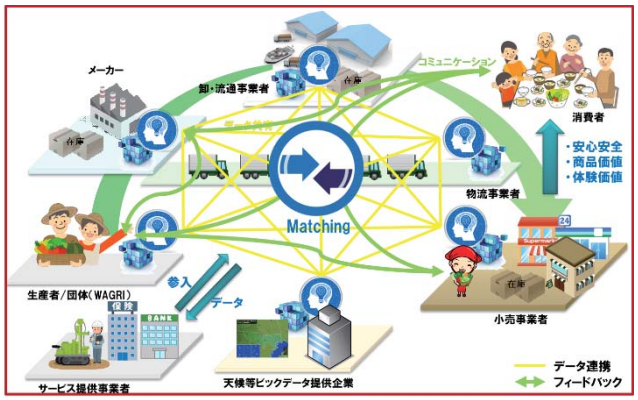
[*2] 産業技術総合研究所 人工知能研究センター
The National Institute of Advanced Industrial Science and Technology, Artificial Intelligence Research Center

Report on efforts to optimize the supply chain in fresh food as one of the use cases for solving social problems where the application of artificial intelligence technology is expected from AITC（Artificial intelligence technology consortium）.

1. はじめに

産業総合研究所　人工知能技術コンソーシアムから人工知能技術の応用が期待されている社会課題解決のユースケースの一つとして、生鮮食品におけるサプライチェーンの最適化の取り組みを報告する。気象データ等を活用した需要予測に、ビジネス条件を加味した商品自動発注 AI と生産予測 AI との協調によって、現在の市場外取引に代わるサイバーマーケットの構築を目指す。

本研究では、各事業体の AI 間での情報連携を担うバーチャルマーケットモデルを構築する。収集されたデータをオープン化し、サービス提供事業者へ提供するなどにより新規参入を促す。



生販間におけるフィードバックループに AI を用いることで参加者の負荷を低減し、参加障壁を減らすことで、参加者がより多くの品種を登録するモチベーション向上を目指す。

また、人工知能間の交渉・協調・連携による予測モデルについて、中小企業等での使用を念頭に説明変数の削減とモデル分類数の最適化を実現し、バーチャルマーケットへの参加を促す。蓄積データについては、ブロックチェーン型の分散処理を前提とし、I/F、ペイロード構造、認証方式等の要素技術を確立した上で、広く連携を促し、各 AI の精度を向上させる。

連絡先：松岡　竜大

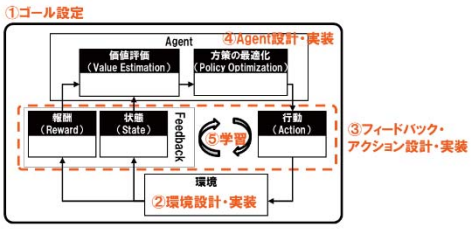
2. 需要予測と商品自動発注モデリング

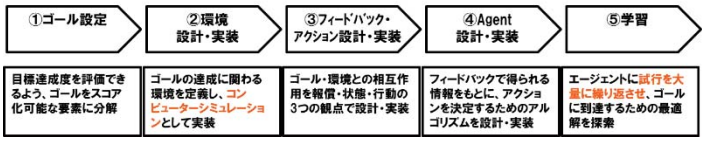
現状、小売業界等においては人手不足が顕在化するものの同時にコスト削減が必要であるなど、単純作業のみならず、習熟が必要とされる作業にまで知能技術に対するニーズが顕在化している。小売り現場において、商品発注に要する時間は、商品単位毎に数秒といわれており、店長等の経験豊富な人材が担っているケースが多い。これまで、人の作業を支援する需要予測を実装したケースはあるが、交渉を含めた自動化を実装可能な精度での実績がなく、モデリング精度の一層の向上と社会受容度の向上が必要である。

本研究では、天候データ、売り上げ実績等を用い、仮想的なユースケースを想定したシミュレーションにて、モデル間の精度比較と精度向上のための研究開発を実施する。計算時間が早くかつ一定水準以上の予測精度を有するモデル構築と予想と実績で乖離があった場合の対処方法の確立が目的となる。

次いで、セール情報やイベント情報等を含む、ビジネスの条件を加味した商品自動発注モデルの構築を実施する。

さらには、社会普及の加速を目指し、気象予報や来店や購買等観測される生活現象の認識・予測・制御・可視化に係る機能モジュールのプロトタイプ開発と現場での実証を行うとともに、モジュールの再利用、学習済みモデルに対して追加学習により個社に最適化されたモデルを構築するシミュレーション環境、データのオープン化に関するデータ規約等から構成される生鮮取引領域における次世代人工知能技術パッケージを開発する。





3. 品質モデリング

AI による受発注の協調・調整自動化実現のため、データ化された品質基準にたいして、多くの事業者が有効に活用できるデータセットを確立し、食品事業者間及び連携システムが効率的、かつオープンに活用可能な API の整理が必要である。

さらには多様化・変化する消費者・実需者ニーズに対応するためには、センサー等を活用による流通段階における品質“おいしさ”を可視化し、生産者・実儒者にフィートバックすることにより、ニーズに対応した生産・食品加工に繋げることが重要となる。

食品素材別の味覚、匂い、テクスチャー等、説明変数となりえるセンサーデータ仮説を構築し、官能検査専門家による評価（教師データ）を作成の上、嗜好性を目的変数にニューラルネットワーク解析等による相関性分析等により、“おいしさ”のモデル構築を行う。

品質基準に対して、食品会社・流通会社等へのヒアリング等により、有効可能性を評価する。それを踏まえ、データセットの定義を行い、及び想定される連携システムとの調整を実施の上、オープン化に向けた API を含む技術標準案に係る研究を行う。

4. 研究開発計画とロードマップ

本文多様なステークホルダーが、AI 技術を活用したサイバー・フィジカル・プラットフォームを構築し、コストとリスクを最小化、消費者も含めた全体の価値最大化を目指す。実証実験をスモールスタートし、MVP（Minimum Viable Product）あるいは要素技術開発を行いつつ、段階的社会実装を行う。

時期（目安）	2018年	2019年	2020年	2022年
実現事項	MVP稼働	PtoP稼働	マルチサイト実証	範囲拡張・民間主導
内容	シミュレーション環境下での実装	限定的な商取引（相対）における実証実験	複数事業者間の商取引における実証実験	業界全体への波及
研究開発項目	・需要予測AI開発 ・交渉AI開発 ・品質等の見える化 ・トレーサビリティ確保 ・プラットフォーム基本機能開発	・サービスプラットフォーム開発 ・データ共有プラットフォーム開発 ・参加企業側AI開発 ・データ連携等規約整備	・サービスインフラ開発 ・法令等整備 ・中小企業への社会実装	・国際展開

参考文献

本村陽一: 次世代人工知能技術, 情報処理, vol.57, no.5, 情報処理学会, 2016.

Oral presentation | Organized Session | [Organized Session] OS-15

[1O3-OS-15b] [Organized Session] OS-15

Tue. Jun 5, 2018 5:20 PM - 7:00 PM Room O (2F Kaimon)

[1O3-OS-15b-01] Development of service platform and eco system for sustainable data collection of AI

○Kota Takaoka[1], Yoichi Motomura[1] （1. Artificial Intelligence Research Center(AIST)）

5:20 PM - 5:40 PM

[1O3-OS-15b-02] User model about kansei using probabilistic methods and implementation trials of user model

○Eiichi Sakurai[1], Youichi Motomura[1] （1. National Institute of Advanced Industrial Science and Technology (AIST)）

5:40 PM - 6:00 PM

[1O3-OS-15b-03] Preliminary Investigation Toward Development System of Childcare Study Support Using AI

○Tetsuzi Yamada[1], Ryoma Hida[2], Masahiro Miyata[2], Takashi Omori[3] （1. Tamagawa University Brain Science Institute, 2. Tamagawa University Graduate School of Engineering, 3. Tamagawa University Faculty of Engineering）

6:00 PM - 6:20 PM

[1O3-OS-15b-04] Visitors' Migration Behavior Analysis at Large-scale Events

○Nao Kondo[1], Nami Harada[1], Kazuya Yamashita[1], Tomotaka Omae[1,2], Yoichi Motomura[1,2] （1. National Institute of Advanced Industrial Science and Technology, 2. Tokyo Institute of Technology）

6:20 PM - 6:40 PM

[1O3-OS-15b-05] Generation of learning data for everyday life behaviors in elderly care home using 3DCG

Koji Kitamura[1], Yoichi Motomura[1], Yoshifumi Nishida[1], ○Tomoya Iwasawa[2], Masanobu Eshima[2], Hideshi Hirose[3] （1. National Institute of Advanced Industrial Science and Technology, 2. IMAGICA Imageworks, Inc., 3. IMAGICA Corp.）

6:40 PM - 7:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

持続可能なデータ収集を可能にさせるサービスプラットフォームの構築

Development of service platform and eco system for sustainable data collection of AI

髙岡昂太[*1]
Takaoka, Kota

本村陽一[*1]
Motomura, Yoichi

[*1] 産業技術総合研究所 人工知能研究センター
National Institute of Advanced Industrial Science and Technology, Artificial Intelligence Research Center

Artificial intelligence (AI) has been making extraordinary progress. To keep developing the AI, reciprocal feedback-communication between AI and people in many use cases are important to collect sustainably data. Hence, this study aims to effectively build an AI platform from data collection to data analysis as well as the eco-systems in the field. The platform includes multiple applications for data collection, a cloud database to store data, probabilistic latent semantic analysis and Bayesian network as the AI by which people understand why predictions and recommendations are provided as a white-box. The platform can be easily customized and comfortably deployed for each use case depending on user needs. In the development trial phase, the platform has been deployed in several fields, such as vending machines in local communities.

1. はじめに

人工知能(AI)は、機械学習とビッグデータ、計算機の高速化により適用可能範囲が広がってきた。しかしながら、新たなデータが持続的に収集されないと AI 自体の性能は向上しない。つまり、多くデータが収集され続けるような環境やエコシステムを醸成する必要が生じる。そのためには価値あるユースケースで早期に AI の実装および活用がなされ、さらに多人数、多頻度、広範囲に展開する必要がある。

そのため本発表の目的は、AI 学習を進化させるために、サービスを提供することで、データを持続的に収集するサービスプラットフォームの必要性と、エコシステムの例を紹介する。

1.1 本発表の位置づけ

本発表の位置づけは、実社会問題へのチャレンジにおいて、AI を活用・応用するために必要不可欠なプラットフォームの提案、及びそれを活用するエコシステムに関する内容となる。そのため、本発表は、今後の人と AI が協調する一つの基盤モジュールとなる(図 1)。

2. AI サービスプラットフォームの構築

AI を発展させるには、データプラットフォームは重要である。しかしながら、業務の中で不必要なデータ入力や、フィードバックもなく不明瞭なデータ収集の継続は難しい(プロメテウスの岩問題)。 そのため、業務やサービスと連動し、データ収集からフィードバックまで一貫したサービスプラットフォームが必要不可欠となる。特にそのような AI を実社会に実装するには、透明性(transparency)・説明責任(accountability)・ 実社会へのポジティブなインパクトという 3 要因が重要と言われる(Cath et al. 17)。

2.1 現場のニーズに合わせたデータ収集

サービスプラットフォームとエコシステムの構築には、まず現場のニーズ把握が重要である。例えば、実生活場面において、AI 活用が、検知・評価・省力化・能力開発・マッチングなど、どの分野で期待されるかの把握である。また、本研究では個々人の文脈や状況にあったフレームを理解するため、ユーザーモデル、現象モデル、確率モデリングという3つのモデル化を行った(Motomura, 2009)。以下にその内容を示す(図 2 参照)。

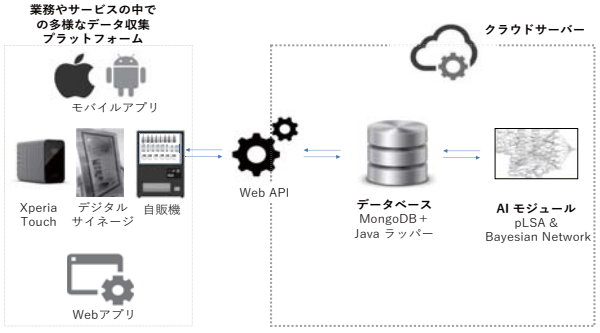


図1:サービスプラットフォーム概要

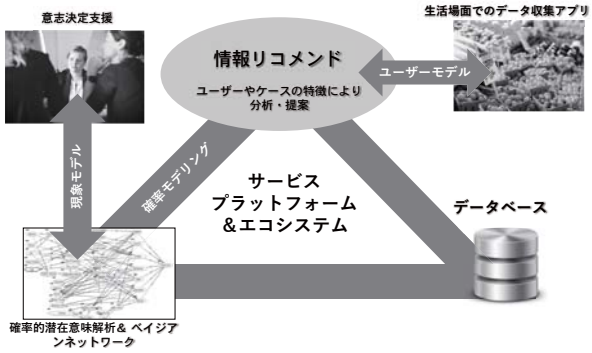


図 2. 場面ごとのモデリング

実生活場面において、ユーザーがどのような行動を取っているか、またその際にどのようなデータ収集がユーザーに負荷をかけずに可能になるかを検討した(ユーザーモデルの検討)。さらに、ユーザーがどのような場面で AI による意志決定支援をしてほしいのか、場面や文脈、実生活場面での制約といった、フレームに関する現象を検討した(ユーザーの意志決定支援を求める状況・現象モデルの検討)。そして、ユーザーモデル、現象モデルを事前情報として組み込み、リスク・コスト・ベネフィットを

連絡先:髙岡昂太, 産業技術総合研究所人工知能研究センター, 〒135-0064 東京都江東区青海 2-4-7, 03-3599-8920, kota.takaoka@aist.go.jp

最適化した確率モデリングを構築していった。確率モデリングについては、2.3 で述べる。

2.2 拡張性を想定したデータベース

実生活場面では、上記のユーザーモデル、現象モデル、確率モデリングを検討するために、解析目的上必要なデータ収集と実現可能なデータ収集、それぞれのニーズに応える柔軟なデータベースの拡張性が求められた。具体的には、取得される変数が増えることが想定される。データベースの一貫性を考慮することも重要であるが、サービスや現場実践と協働しながらデータ収集と解析を同時に行うサービスプラットフォームでは、現場のニーズに合わせて、柔軟に拡張できることに優先順位を置いた。その結果、サービスプラットフォームでは数値・テキスト・画像・動画などマルチモーダルなデータを収集するため、NoSQL 系データベースとして MongoDB を採用した。

2.3 ホワイトボックス化された AI 基盤

機械学習はデータから「予測」をすることが非常に強力である一方、実生活場面において、例えばビジネス場面で顧客への理由の説明や、公的場面での行政機関における説明責任など、「説明」が求められる場合は適さない場合がある（Executive Office of the President National Science and Technology Council Committee on Technology, 2016）。そのため、実生活場面のおける AI サービスプラットフォームと循環的に実生活にフィードバックしていくエコシステムでは、「説明」できることに重きを置いた。

また、サービスプラットフォームでは、データに基づき、ユーザーの行動をより良く変え、生活空間における質を高めることで、社会にポジティブな影響を与えることを目指している。そのため、ユーザーが主体的に AI を用いて判断するには、理解しやく共感できる根拠の提示が不可欠となった。なぜならば、根拠が明確で受け入れられやすければ、ユーザーは近い将来の見通しを立てられ、自発的に行動を変える動機付けとなるからである。だからこそ、理由が明確で、理解しやすく、また実生活場面における様々な不確実性を考慮に入れられる確率モデリングを、AI サービスプラットフォームは採用した。具体的にはアルゴリズムは、基本的に確率的潜在意味解析(pLSA)(Hofmann, 1999)とベイジアンネットワーク（Pearl, 1985）を採用している。

3. AI サービスプラットフォームとエコシステム例

同じユーザーでも、時間・場所・一緒にいる相手（フレーム）などにより、考え方や行動パターンは変化する。本発表において、単にシステムという呼び方ではなく、エコシステムとあえて呼んでいるのは、エコという血が通ったユーザーと AI との生態学的な関係性を重視しているからである。現在、ビジネス、地域活性化、社会問題にこの AI サービスプラットフォームの構築とエコシステムの醸成を同時に行っている（Takaoka, in press）。以下では、その一例として、開発した自動販売機でのサービスプラットフォームとエコシステムについて概要を説明する。

3.1 自販機サービスプラットフォームとエコシステム

自販機と一言でいえども、飲料、食品、書籍類、日用品、電化製品など扱う商品は多岐にわたる。また設置場所により、ターゲットとなるユーザーも異なる。しかしながら、重要な点は、それぞれ地域コミュニティの中で、自販機は販売から災害時の商品配布、デジタルサイネージとしての情報啓発まで自律的な機能を発揮できることにある。例えば、本サービスプラットフォームを自販機に活用し、公共交通系 NFC カードと連動することで、ユーザーの特性に基づく商品を継続的にリコメンドできる。また、設置場所などにおいても、購入商品が変わることが予想できる。例えば、“平日夕方頃”に“職場で一人で”お茶を買ってリフレッシュするユーザーは、“休日前”に“仕事上がりの夕方”に“同僚二人以上と一緒にいる”場面であれば、アルコールを購入する確率は高まる可能性がある。一方、同じユーザーでも、“平日 19 時頃”に“ジム”にいるとスポーツドリンクを買う確率が上がる可能性もあるだろう。そのような個人に紐付くデータを、フレームとして事前情報を確率モデリングに組み込むことができれば、フレーム問題に対応しながら、リコメンドの理由をユーザーに示し、ユーザー特性に合わせて商品をリコメンドすることができる。つまり、サービス提供とデータ収集が循環的に可能となる。

このように、サービスプラットフォームとエコシステムは、人の主体性を根拠を持って支えるパーソナルガイドとして、サービスを提供し、その反応をデータとして持続的に集めることが可能になると期待される。

謝辞：本調査の成果の一部は、国立研究開発法人新エネルギー・産業技術総合開発機構（NEDO）の委託業務の結果得られたものである。

参考文献

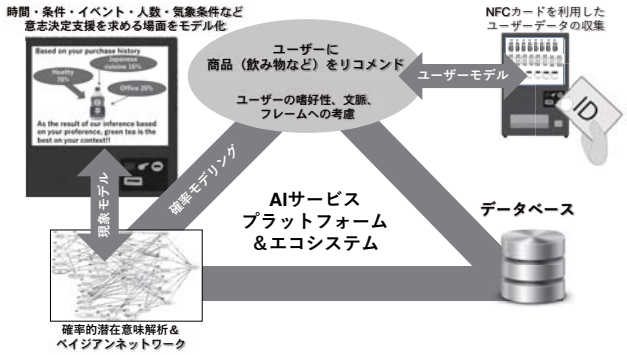


図 3. 自販機におけるサービスプラットフォーム

[Cath 2017] Cath, Corinne et al. 2017. “Artificial Intelligence and the ‘Good Society’: the US, EU, and UK Approach.” *Science and Engineering Ethics*: 1–24.

[Executive Office of the President National Science and Technology Council Committee on Technology 2016] Executive Office of the President National Science and Technology Council Committee on Technology: Preparing for the future of Artificial Intelligence, 10.1007/s00146-016-0685-0, 2016.

[Hofmann, 1999] T. Hofmann: Probabilistic latent semantic indexing, *Proc. 22nd Annu. Int. ACM SIGIR Conf. Res. Dev. Inf. Retr.*,.

[Motomura 2009] Y. Motomura: Predictive modeling of everyday behavior from large-scale data, Synthesiology English edition, National Institute of Advanced Industrial Science and Technology, 2009

[Pearl, 1985] J. Pearl: Bayesian networks: A model of self-activated memory for evidential reasoning, *Proc. 7th Conf. Cogn. Sci. Soc.*,

[Takaoka in press] Takaoka, K., Yamazaki, K., Sakurai, E., Yamashita, K., and Motomura, Y: Development of an Integrated AI Platform and an Ecosystem for Daily Life, Business and Social Problems, Applied Human Factors and Ergonomics (AHFE 2018),Springer, in press

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

感性に基づく確率的ユーザーモデリングと社会実装への取り組み

User model about kansei using probabilistic methods and implementation trials of user model

櫻井　瑛一 *1　　本村　陽一 *1
Eiichi Sakurai　　Youichi Motomura

*1産業技術総合研究所
National Institute of Advanced Industrial Science and Technology (AIST)

In this paper, we describe a methodology of user computational modeling and our activity to use this model in the real-world situations. One promising approach to user modeling is the concept of a persona, which is a fictional image of user that contains not only his/her demographic information, but also deep information regarding his/her daily lifestyle, concerns, and other related factors. A persona is explained in a narrative story style, so it is not easy for computers to automatically construct a meaningful persona. In this paper, we show the data driven persona model which is made by combining probabilistic clustering method with Bayesian network. We also show implementation trials to use this user model.

1. はじめに

我々は，人の行動がその人自身の感性や性格，その人周囲の状況によって変化することをモデル化し，このモデルを計算可能な形で記述できないか，ということを研究してきた．そのために，人の行動のモデルとしてユーザーモデルという概念を提唱し，文部科学省「精神的価値が成長する感性イノベーション拠点」プロジェクト (以降，COI プロジェクトと略す) 内でモデル化の試みを進めてきた [櫻井 16, 櫻井 17].

このようなモデル化は，多種多様な消費者に適応するために，製品設計の場において使用されている．その代表的な方法としては，定性調査に基づき仮想的なユーザーを推定し，定量調査によってその裏付けをするペルソナ法がある [Pruitt 03]. もともとは，UI/UX のために開発されたが，いまや製品設計の上で想定される仮想的なユーザー作成の代表的な方法となっている．

ユーザーのモデル化は，製品設計だけでなくブランド戦略にも重要になっている．製品単体での性能競争のみでは商品の競争力を生まない現状から，企業は製品に付帯するサービスや製品間のネットワークを重視する戦略を取っている．この目的を達成するために，企業は自身のブランドに共感するファンを作り出す戦略やマーケティングを行うなど，製品からサービスを重視した施策を実施されその理論（たとえば，[Vargo 04]）も研究されている．このような理論では人の異質性に着目するため，ユーザーをいかにモデル化するかは非常に重要となる．

ペルソナ法ではモデル化を定性的な記述により作成することで，人にとって理解しやすい形をとっている．このモデルをサービスの中へ組み込むためには，モデルを人が理解したうえでそれをロジックにおとし実装する必要がある．しかし，現在人の考え方は多様となり，その変化も比較的大きくなっているため，それを頻繁に変更可能な仕組みとする必要がある．効率的なシステム実装のためには，ユーザーモデルは機械的かつ計算可能なモデルとして記述されている必要がある．

我々は，COI プロジェクトの目標である感性の解明の一環として，製品の価値設計に適用可能なユーザーモデルの作成とそれによる感性構造の解明，そして計算可能なモデルとしての記述・活用に取り組んできた．本論文では，それを作成するために我々が行ってきた，ユーザーモデルの作成と国立研究開発法人新エネルギー・産業技術総合開発機構プロジェクト「人間と相互理解できる次世代人工知能技術の研究開発」(以降，NEDO プロジェクトと略す) を用いて行うユーザーモデルの社会実装に向けた活動について述べる．

連絡先: 櫻井瑛一，国立研究開発法人産業技術総合研究所 人工知能研究センター，東京都江東区青海 2-4-7, e.sakurai@aist.go.jp

2. ユーザーモデルの作成

我々は，COI プロジェクト内で感性に対するユーザーモデルの作成に向け活動を行ってきた．ユーザーモデルの対象は，車の購入する人であった．我々は，定性的な調査による車に対して生じる感性情報の収集と車の販売現場からの感性データ収集を通じて，ユーザーに対する仮説を作成してきた [櫻井 16]. この調査活動を通じて車の販売店にて車の購入に影響する要素を洗い出し，インターネットによる定量調査に必要な調査項目を設計とデータ収集を行い，得られたデータからユーザーの典型例を，PLSA とベイジアンネットワークを利用することで，計算可能なユーザーモデルの作成を行った [櫻井 17].

本節では，後者について簡単な内容説明を行う．

2.1 アンケートデータのクラスタリングによるユーザーの類型化

アンケートデータに対して，文書分類の文脈にて提案された PLSA[Hofmann 99] を用いてクラスタリングを行った．PLSA は単語の出現頻度と共起によるクラスタリングを行うが，アンケートデータに対してこの手法を適用した場合，アンケート設問で選択された選択肢・設問の共起関係による分類が得られることになる．したがって，PLSA の適用により，アンケートの回答から，回答者のクラスタリングを行うことができることになる．

今回対象としたデータは車を対象としたインターネット調査アンケートであり，その項目として，車に対する重視点や回答者の感性的な側面，家族などのデモグラフィック情報が含まれる．このデータに対して，PLSA を適用し AIC によりクラスタリングする数を決定した結果，7 つのクラスタに分類された．

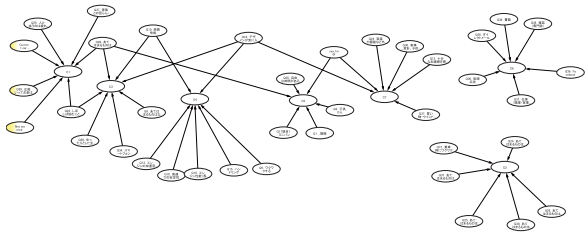


図 1: クラスタ結果に対するベイジアンネットワークによる説明モデル

2.2 クラスタ結果に対するベイジアンネットワークによる説明モデル

PLSA により得られたクラスタに対して，どのような選択肢が影響力を持つかを検証するために，ベイジアンネットを用いて各クラスタに対する説明モデルを作成した．具体的には，各アンケート解答者を PLSA により得られたクラスタ所属確率が最も高いクラスタに割り付けたデータを用いて，セグメントを説明する設問内の選択肢をベイジアンネットワークにより探索した．この探索には Bayonet を用いた [本村 03]．図 1 がその結果である．

この結果から，各セグメントの特色が明らかとなり，例えば，いわゆる走る車が好きな層 (C4) や，既婚者で家族用にミニバン系統を購入する層 (C5) などが現れることが分かった．また，今回の設問では社会的な状況を問う設問を入れクラスタリングを行っているため，多くの設問で「あてはまるものはない」と答える消極的な層 (C2) や非婚かつ所得が厳しい層 (C1) など社会の断面を見ることもできる．

今回の結果はベイジアンネットワークにより構成されているため，計算可能なモデルとなっているが，アンケートから端的に出た特徴であるため，そのクラスタの意味やそれが生じる要因を考える必要がある．したがって，ペルソナのような人に理解しやすいモデルであるか，という意味ではもう一段解釈が必要な結果であるともいえる．

3. 社会実装にむけて

前節の例におけるクラスタリングと説明モデルによる回答者の類型化は分析としては非常に有用であり，ベイジアンネットワークにより作成されているため，計算可能なモデルでシステムへの導入が可能となっている．しかし，社会においてモデルを更新して行くためには，このモデルを活用したサービスを作成し，データを収集していく必要がある．我々は継続的なデータ収集に向けた試みを我々は二通り行っている．その取り組みについて記す．

3.1 小規模なデータ収集の試み

アンケートの分析から比較的少数の設問があればよいことがわかってきた．そこで，アンケート項目を絞って行えば，継続的なデータ収集ができるのではないかと考えた．COI プロジェクトでは，アンケートデータの感性項目作成のために自動車販売店にて協力していただきデータ収集を行っていた．継続的なデータ収集が行えるかの試行として，タブレットを使用したアンケートシステムを利用した販売店にとって必要なデータ (来店動機など) の継続的なデータ収集を試みている．タブレットを用いることで，紙ベースでの調査に比べ敷居が高くなるという意見もあったが，紙のアンケートを PC に入れる手間を考えれば，問題が少ないという結果であった．ただ，課題としてはタブレットをだれが客に勧めるのかという構造的な問題はあり，それを解決する手段が必要であることが分かっている．



図 2: 接客カタログにアンケートと情報提示サービスを組み込んだ例

3.2 業務に埋め込まれた情報収集システム

上記のアンケートシステムはアンケートを為すために作成されているためそれを行うという意思や意味づけが必須であった．そのような動機付けなしに自然と情報を提供してもらう一つの解決手段としては，サービスや日常業務内にアンケート等の仕組みを埋め込むことである．そのようなシステムを NEDO プロジェクト内で開発中である．図 2 がそのプログラムの例である．ここでは，接客用カタログシステムに，アンケートを組み込み，その人の好み (カタログ内で気に入ったものを選択) と価値観のアンケートを行うことで，その人に合った情報を提供する仕組みとなっている．これにより，接客業務に生かせると同時に来店顧客の好み情報や購入に至ったのかなどの情報を取ることができる仕組みとなっている．このような仕組みが実際の現場で稼働可能かを今後は検証していく予定である．

4. おわりに

本論文では，ベイジアンネットワークを活用したデータに基づくユーザーモデルの紹介と，それを利用し社会実装していくための我々の取り組みについて述べた．社会実装に関しては，まだ試みの半ばの段階であり，それを継続して進めていきたい．

謝辞

本研究（の一部）は国立研究開発法人新エネルギー・産業技術総合開発機構（NEDO）委託事業「人間と相互理解できる次世代人工知能技術の研究開発」の支援および国立研究開発法人科学技術振興機構（JST）の研究成果展開事業「センター・オブ・イノベーション（ＣＯＩ）プログラム」の支援を受けて行った．

参考文献

[Pruitt 03] J. Pruitt and J. Grudin. Personas: Practice and theory. In Proceedings of the 2003 Conference on Designing for User Experiences, 2003.

[Vargo 04] S. L. Vargo, R. F. Lusch, R. H. Smith, S. Hunt, G. Laczniak, A. Malter, and F. Morgan. Evolving to a new dominant logic for marketing. Journal of Marketing, pp. 1–17, 2004.

[櫻井 16] 櫻井, 本村, 安松, 坂本, 道田. 感性ユーザーモデルの構築のためのデータ収集方法. 行動計量学会全国大会, 2016.

[櫻井 17] 櫻井, 本村, 安松, 坂本, 道田. 感性に基づく確率的ユーザーモデルの構築. 行動計量学会全国大会, 2017.

[Hofmann 99] T. Hofmann and J. Puzicha. Latent class models for collaborative filtering, In Proceedings of 16th international joint conference on Artificial intelligence, 1999

[本村 03] 本村. ベイジアンネットソフトウェア BayoNet. 計測と制御 42.8 ,pp. 693-694, 2003.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

AIによる保育研究支援システム開発に向けた予備的調査
- 子どもの関心推定を目指して-
Preliminary Study Toward Development of Childcare Support System Using AI
- Aiming at Estimating Children's Interests -

山田徹志[*1] 肥田竜馬[*2] 宮田真宏[*2] 大森隆司[*3]
Tetsuji Yamada Ryoma Hida Masahiro Miyata Takashi Omori

[*1] 玉川大学脳科学研究所 [*2] 玉川大学大学院工学研究科
Tamagawa University Brain Science Institute#1 Tamagawa University Graduate School of Engineering #2

[*3] 玉川大学工学部
Tamagawa University Faculty of Engineering #3

In this study, we tried to estimate child's interest as a preliminary investigation towards introduction of AI technology to childcare. The research method focused attention on the child's interest that the childcare professional would estimate in nursery practice. In addition, we conducted annotations by teachers on child's interests by sensing daily childcare scenes. As a result, the interest of 18 children was described. Then, it was suggested that the physical activity state of the child is involved in the estimation of the child's interest. From these results, usefulness of measuring physical activity was recognized for estimating children's interests. We also showed that automatic estimation of child's interest using AI technology could be realized through measurement of physical activity state.

1．はじめに

昨今,保育(就学前教育・養育以下, 保育)について社会的投資効果の重要性が確認され[Heckman 2013,OECD 2017], OECD 諸国では就学前教育制度の整備が進んでいる. これを受け保育所の無償化をはじめとした政策が実施されようとしている. 同時に, 待機児童問題が深刻な社会問題として認識されており, 保育者(幼稚園教諭, 保育士以下, 保育者)の職務采配権限の拡大や保育施設・機能の設置規制緩和を含めた量的拡大が行われている. 一方, 課題となるのが多様化する保育の経営形態の中で子どもに対して効果的な保育サービスを維持・継続していくことである. それは保育の効果, すなわち保育の質の保証の問題である.

保育の質について ECCERS,Sics[A UK 2018, Ziko 2018]など諸外国における保育の質評価スケールを相互補完的に活用し，保育の質の向上を計る研究[秋田 2016]が国内ですすめられている．これらの評価では，日々の保育場面の事例やエピソードの記述より保育の質を評価する手法が採られ，その内容には保育者や研究者の記述項目も少なくない.

「保育の質」の評価が事例記述等の手作業により行われる理由は，「保育の質」が「遊び」や「生活」へ向かう子どもの姿を基に評価されるところにある．そして，この作業は，保育有識者（保育者，研究者）が保育職務における子どもとの関わりの中で，見て感じたことを実践的事実として継続的に保育記録として記述し蓄積することで実現されている．すなわち，保育研究では，フィールド研究で得られた事例における子どもの育ちを保育有識者（人）が感覚的に読み取ることにより行われる．さらに，事例記述等の作業には膨大な時間を要し，研究者や保育者の大きな負担となる．つまり，現行の保育の質評価指標は子どもの育ちを議論する上で有用ではあるが，その方法を保育研究の現場にて実施するには労力と時間という制約がある．また，子どもの姿の読み取りは，保育者・研究者の主観的解釈にて行われる為，定量的記述の妥当性・信頼性の保証は容易ではない.

これらの問題に対し最近の AI の画像認識に関しては，人と同等以上の能力を発揮する場合も多い．そして，子どもの姿の読み取りは人でも非専門家には難しい面も多く，AI を用いても保育領域への実装は難しいと予想される．
では，如何なる方法なら AI の実装は可能になるのか．そこで，本研究では，保育研究において子どもの育ちを客観化して推定・評価する新たな研究手法として，AI の新たな社会実装の可能性を子どもの関心推定より検討する.

連絡先:山田徹志 玉川大学脳科学研究所
194-8610 東京都 町田市 玉川学園 6-1-1
E-mail:tetsuzi@lab.tamagawa.ac.jp

2. 方法

2.1 何を測るべきか ： 保育が目指す子どもの「学び」

子どもの育ちを評価する為の要素は多岐にわたる．その中のどこに AI が寄与できるか，ということはいまだ確定していない．そこで我々は，保育の目的に注目した.

保育とは，教育と養護を一体的に捉えた概念である. 義務教育でも教科教育でもない保育は，子どもの「遊び」や「生活」を通した心情，意欲，態度の基礎的育成を「学び」として捉えるとされている．ここで言う「学び」とは事象（「ひと」や「もの」とで構成される環境）に対して子どもが自ら関心や好奇心をもち，事象に主体的に関わる姿としている[内閣府 2015]．つまり保育の「目的」は，日々の「遊び」「生活」の中での子ども一人ひとりの心的状態（こころ持ち）をよりポジティブな状態へと誘導し，人間性を形成していくことにある．これより，子どもの育ちの評価は，子どもの事象への主体的な関わりに伴う心の

状態を推定することでなされると考える．以上より本研究では，「子どもの環境への主体的な関わりの場面における心的状態が子どもの育ちの評価に関連する」との仮説をおき，子どもの心的状態の推定と定量的な評価を試みる．

2.2 子どもの「関心」が環境への主体的な関わりを生む

子どもの主体的な環境へ関わりは，まず日々の保育における多様な環境を知覚し、その環境への子どもの積極的な心的状態に誘発された実際の活動（行動）として表出する．そして，この積極的な心的状態は知覚し認識した対象へ「関心」を向けることで事象との関わりを生む．すなわち，子どもの「関心」は子どもの主体的な思考の現れであると考えられ，その推定が子どもの「育ち」の評価の重要な要因となろう．これより，子どもが環境（ひと・もの・こと）へと主体的にかかわる時をとらえるなら、その活動の種類と特徴から子どもの育ちの評価につながる特徴量が得られると期待する．

2.3 「関心」の読み取りが子ども理解につながる

保育者は，子どもとの関わりの中で「子ども理解」を計りながら保育を行っている[Reddy.V 2015]．そして「子ども理解」は子どもの関心の認識に直結し，子どもをポジティブな心的状態へと誘導する為の環境を整備・選択する際の根拠となる．子どもの成長はその環境に誘発される部分が大きく，環境整備は子どもの育ちを形成する主要な要因の一つとされることから，「子ども理解」は保育の質の評価における中心的課題である．

ここで我々が注目したのは，「子ども理解」の主要な手段の一つが子どもの「関心」の推定であるということである．関心は子どもの心的状態の現れであり，しかも関心を示すという行動は第三者が見れば認識可能である．すなわち，物理的に観察可能な視覚情報の中に関心の推定に必要な情報は含まれており，さらにそれが「子ども理解」につながる，と考える．これより，保育者が子どもの関心を読み取る際の判断指標を子どもの行動に関する物理量と結び付けて計測することは，保育における子どもの育ちを推定し評価する為の指標の抽出につながろう．

2.4 AI での学習に向けての子どもの関心推定の試行

以上の仮説を基に現在，一定の保育場面における保育活動の記録を継続（2016 年 4 月~現在）している．本研究では記録映像の一部分について、人手（保育者）による子どもの関心のアノテーションを実施し予備的に評価した．計測環境及び調査対象は以下の通りである．

計測環境

保育室に Kinect v2 センサ，ビデオ，指向性マイクを設置し計測に使用．Kinect v2 センサは4台を多方向から設置し，カラー情報（RGB）と深度（D）情報を取得した．

調査対象

玉川大学附属幼稚園 英語教育（BLES-K）の活動へ参加した 4 歳児 18 名（男児 10 名，女児 8 名）．

倫理的配慮事項

本調査は，玉川大学倫理審査及び，幼稚部保護者の承認（調査実施説明会の実施と承諾書の提出）のもと実施した．

収集したデータを以下の 2 段階の手順で分析し，子どもの関心を評価した．第 1 段階では，保育評価手法 Sics[Ziko 2018] を参考に 2016 年 9 月 29 日の保育観察記録 18 分 53 秒より無作為に 2 分間（120 秒）を選んだ．なお，本場面は「集団で輪になり保育者とクラスの子どもが歌を歌う」という保育活動であった．そして，この 2 分間について保育者 3 名が協力し，繰り返し映像を見ながら 1 秒ごとに子どもの関心についてのアノテーションを実施した（120 秒×18 名 2,160 ラベル）．子どもの関心を記述した複数のアノテーションラベルの内，保育活動内容において，子どもたちが関心をもち関わりをもつことが予想される対象を分析に用いた．ラベルの作成は保育経験 5 年を有する保育者 3 名と保育学研究者 1 名，認知科学研究者 1 名により行った．ラベルの内容は，分析映像内，保育活動の中で，子どもが関心を向けて関わりを持っている対象を参考に作成した．次の 1~6 である．

1.「保育者との関わり」2.「友だちとの関わり」3.「全体（集団活動）との関わり」4.「保育活動とは関連しない人との関わり」5.「ものとの関わり」6.「飽きる」．これらの記述結果を集計し，統計的手法（ナイーブ・ベイズ法）により定量的な分析を行った．

その後，アノテーションの安定性を確認する為、別の保育者 3 名により同場面（2 分間）において最も特徴的な行動量を示した幼児 1 名について，再度，同 1~6 ラベルのアノテーションを実施し，記述の比較を行った．

第 2 段階では，子どもの物理的な活動量と関心評価ラベルとの関係を検討した．アノテーションの記述の一つとして，記録環境下（保育室）の地図をコンピュータ画面に作図し，いくつかの特徴的な場面について，子どもの物理量として個々人の位置(座標)と向き(角度)を記述した．そして，この物理量から保育者が記述した関心を推定できる可能性を検討した．

3. 結果・考察

3.1 関心対象の分布と尤度距離

無作為に抽出した 2 分間（120 秒）の映像箇所についてアノテーションによる関心を定量化し評価した結果が Fig.1, Fig.2 である．Fig1 は，子ども 18 名の 120 秒間における関心推定ラベル1～6 の分布である．Fig2 は，Fig.1 の個々の子どものラベル分布を確率分布とみなし，それらの全体平均の確率分布からの尤度距離（-Log Lc）を計算したものである．これを見ると，全体平均が示していると想定される集団の活動に対し，個々の子どもの関心がどれだけ一致しているかという一つの定量化がなさ

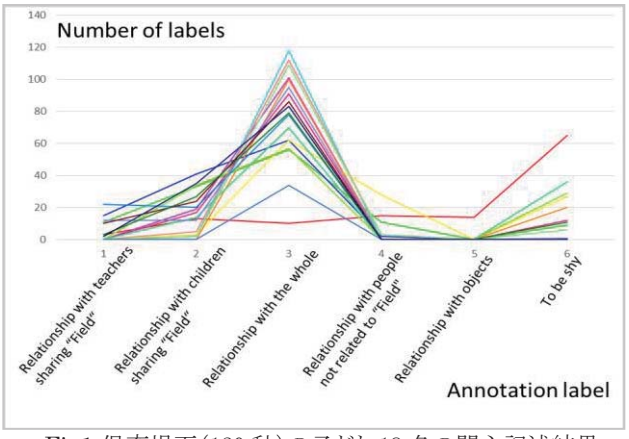
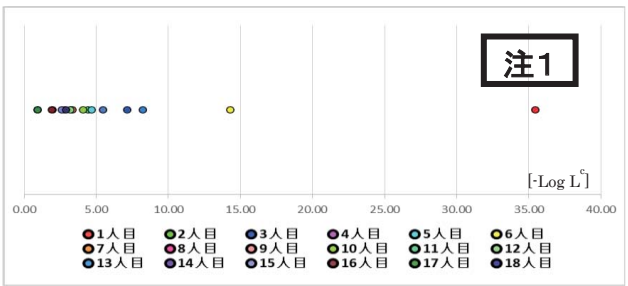


Fig1 保育場面（120 秒）の子ども 18 名の関心記述結果



$$\mathbf{Eq.}\ -\mathrm{Log}\ L^c = \sum_k \left(-\left(\frac{(x_k^c - mk)^2}{\sigma_k{}^2}\right)\right)$$

Fig2 保育場面（120 秒）の子ども 18 名の尤度距離

れたように見える．多くの子どもは全体平均への距離が近いことから集団活動に対し関心を向け活動へと参与していると推定できるが，一部の子どもは集団活動とは別の対象に関心を向け関わっていると推察される．つまり，集団活動という複数人の関心が集中している状況下への個人の関心傾向が活動への参与の程度に対する距離として現れている．ただ，この数値はあくまでも一つの計算的な指標にすぎず，この尤度距離がどれだけ保育者の子どもの姿を読み取る上での直観・認識と一致するかは，今後の検討が必要である．

次に，Fig2 において最も尤度距離の大きかった幼児 1 名（以下，A児）について，再度別の保育者 3 名によりアノテーションを実施した結果が Fig3 である．

その結果，120 ラベル（秒）で 87.5%（120 ラベル中 105 ラベル）の一致を示した．そして，保育者間の関心推定における差異(Fig3 黄色枠箇所)の原因は，子どもの向き（視線）情報と位置（場所）情報の判断基準の迷いであった．これより，判断基準をより明確化することで，少なくとも保育者による関心の推定に関しては高い安定性が確保できるものと考えられる．

Fig1～Fig.3 の関心推定の結果を物理量から予測する可能性について検討する為，子ども 18 名の向きと位置を可視化した（Fig4）．

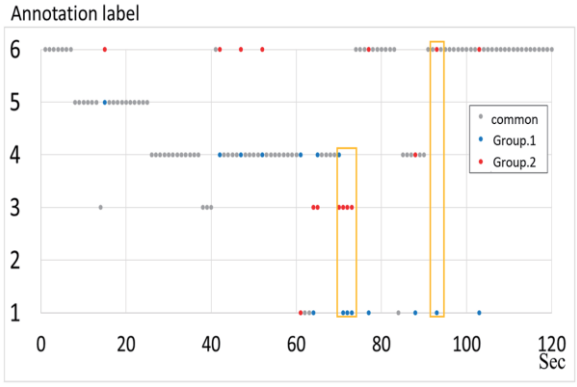


Fig3 アノテーター間のA児の関心推定結果の比較結果

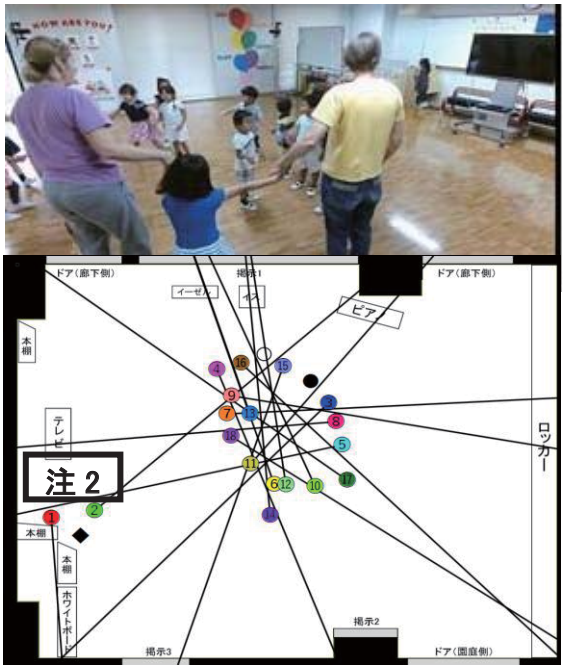


Fig4 A児が最も尤度距離示した時間の子どもの位置と向き

Fig4 は，A児が最も尤度距離を示した場面における子どもの物理的な活動量（位置・向き）を可視化したものである．上部が実際の保育活動場面であり，その瞬間の保育活動へ参与していた子ども 18 名の位置と向きを地図上に記述したものが下部の図である．下部の地図上にある 1~18 の番号が付記された 18 色の○は，子どもの場所（位置），各○より引かれた黒色の直線は子どもの視線の向きを示している．

この瞬間，ほとんどの幼児は保育者と共に輪になり歌う為，一個所に集まる中，A児（赤色①，図中の注 2）は，他の子ども達より離れた位置におり，視線は絵本棚に向いていた．本場面だけでは判断は難しいが，物理量から推定されるA児の活動への参与の程度は，Fig.2 で示した尤度距離と相関があることが示唆される．なお，このデータは本研究で行ったアノテーションの一部であり，現状では対象とした活動の全体について全ての子どもの位置と向きの情報が一秒ごとに記述されている．

3. 2　関心対象の分類にみる個々の特徴分布

子どもの関心推定の結果より，一定の保育場面で子ども 18 名の関心が定量化できた．このためには，まず子どもの関心状態が生じる関心対象となる事物の記述が重要である．すなわち，子どもが「遊び」，「生活」において環境に対し積極的に関わろうとする時には，明確な対象が存在するであろう．そして，その対象は，子どもが保育環境下において知覚可能な「ひと」，「もの」だけに限定されず，複数の「ひと」「もの」の関係として形成される「こと」（事柄）も含めて認識することで，集団の関心状態の検出・記述が可能になると考える．例えば，「クラスで先生の絵本を見る時」や「輪になり一緒に歌を歌うとき」など全体がその場の状況，雰囲気を感じ関心対象を共有していることが見受けられる．このことは Fig1 の記述ラベルの集計結果で「こと」（ラベル 3）が多くみられることからも言えよう．

このことから，関心対象「こと」に対する個々の子どもの関心ラベルの分布について，全体の平均分布からの尤度距離を算出するならば，個人の関心は集団の関心傾向に依存しつつも，子どもが関心という心的状態を発生させる個々の心的な特性に応じた特徴が表れると予想される．つまり，個人の関心傾向と全体（他の子ども）の関心傾向とを比較・計算することが関心推定には有用だと考えられる．また，A児のように特徴的な分布を示す場合が典型ではあるが，他にも例えば子どもが保育活動の中で何らかの不安や活動に参与することへの困難などを抱く場合などには，特徴分布の明確な違いが表れるであろう．

一方，保育環境下で子どもの関心対象となりうる事物を事前にセンシングすることは物体認識技術によりいずれ可能となろうが，対象の種類は膨大である．この問題に対して，子どもの個々の関心から生まれる行動特徴を基に映像データから関心対象を判定することも，関心対象の推定における今後の技術開発の一つの方向性であろう．

3.3　子どもの物理的活動量と関心発生にみる「場」

Fig3 のA児の部分的アノテーション結果では，関心の推定結果が保育者間で 87.5%と高い一致率（安定性）を示した．これは，保育者が感覚的に行っている子どもの関心の読み取り（推定）は，保育者間で共通性が高いことを示唆している．そして，保育者間の関心推定結果のゆらぎから，関心の推定には子どもの「位置」「向き」といった物理的な量が影響することが示唆された．これより，子どもの「位置」「向き」を定量化することは，子どもの関心を機械的な方法で推定することへ寄与すると考える．「位置」「向き」といった物理的行動特徴は画像情報から比較的容易に計測可能であり，機械による子どもの関心推定のために必須の計測項目であろう．そして，先の関心対象の推定におけ

る技術開発を行う上でも重要な活動量だと言えよう.

関心推定に伴う子どもの物理的活動量について他にも注目すべき点がある. それは, 関心という心的状態が発生する際に特徴的な活動量(位置・向き)のパターンを示すことである. Fig4 下部の地図では, 多くの子どもたちの位置は円形となり, 向きは, 保育活動(輪になって歌を歌う)という「こと」(ことがら)に関連する対象(保育者及び「こと」に参加する友だち)へ向いている. これは,「こと」によって子どもたちの関心に強いバイアスが生じ, 複数人の関心が特定の関心対象へ収束された状況であると推察される. つまり, 人間が知覚可能な環境下で複数の心的状態(関心)が一定の対象より誘発されている状況である.

一方, Fig4 でのA児は, 全体で歌を歌うという活動の中で絵本棚の本へと関心を向けている. この時, 個人(A児)の心的状態(関心)が一定の対象による誘発される状況であると推察される. すなわち, 関心推定に関与すると思われる物理的活動量(位置・向き)は, その瞬間に一定の関心対象と複数人もしくは個人との間に形成される関心発生の状況を同時に描き出している. これらが示す心的状態の発生に伴う事象との関わり(状況)を我々は,「場」と解釈している.

これらの議論から個人の心的状態(関心)の特性検出は, 時間とともに変化する保育活動の中での個人及び集団と関心対象の間に形成される「場」の推定に依存すると予想される. そして, 関心とは個々の子どもが有する知識・好み・成熟の結果として感じる特定対象への価値の認識であり, それがその対象に向けての関心を示す物理的な行動として現れたものと推察される. これより, 子どもの関心状態の推定は, ただ, 保育活動に子どもが参与しているか否かをみるものではなく, 個性に関わる行動特徴の検出を通して, 子どもの育ちを記述し評価する為の情報源として活用できるであろう.

以上より, 本研究の主眼である保育研究領域へのAI導入のためには, まず子どもの物理的な状態の自動認識を通しての関心推定の自動化が求められよう. そして, このような背景のもとで我々は, 人の心的状態を読み取る上で必要な物理量としての「位置」「向き」を計測するシステムを開発し, それを使っての子どもの関心推定の自動化へ向けた技術開発を進めている.

3.4 子どもの育ちと関心分布の関係

本研究の一連の結果は, 集団の中での個々の子どもの関心推定の可能性を示唆している. しかし, 現状の分析手法で得られる結果と保育の質 (子どもの育ちの評価) との間には, いまだ溝が残る. 例えば, A児の行動の分析結果について我々は, A児が所属する園の保育者と保育カンファレンスを複数回実施し, 情報共有を試みてきた. その過程で, 保育者はA児の日々の保育活動において, 集団活動への参加についての困難感を抱いていたことが判明した. そこに, 本分析により得られたA児の関心状態を報告し議論した結果, 視覚的にメッセージ性の強い「もの」 (絵本, 紙芝居) や特定の「ひと」 (ある特定の保育者及び友だち) に対し関心を持ち関わっていたことが明らかとなった. そして対応として, A児が関心を向けやすい対象と関わりを集団の保育活動の環境の中に置くことで, A児は集団活動場面にも参与するようになったと報告されている.

これより, 子どもの育ちと関心の関連は事例としては認められる. 一方, 科学的に子どもの育ちを論じるには, 機械的なセンシングで子どもを長期間追跡し, 子どもの行動特徴の長期的な変容を捉えることが必要である.

4. 課題・展望

4.1 課題 : AI 技術による関心推定の試み

本研究の課題は, より多様な保育場面での縦断的な子どもの関心推定の継続である. それには, 専門職者による多くのアノテーションが必要であるが, その作業には膨大な時間と労力を要する. この課題に対して我々は AI 技術を用いた分析システムによる半自動の子どもの心的状態の推定を試みている[肥田 2017,山田 2017].

4.2 展望 : 保育・教育分野における AI の社会実装

本研究では, 子どもの活動の物理的な計測から関心推定が可能であることが示唆された. これは, 保育の質の維持に必要な子どもの育ちの客観的な推定・評価システムの開発に繋がる. 例えば, 特徴的な行動を示す子どもの検出や, 保育者間での関心の読み取りの共通性は, 保育現場において子どもの育ちの振り返りへの活用や援助方策の議論の上で必要となる客観的事実である.

そして, 本推定法の実現は, これまで人による専門的技能と考えらてれて来た子どもの育ちの記述を支援して画期的な作業軽減を生むことで, 新たなビジネスを生み出すことを期待する. しかし, 現状の保育研究領域はIT技術の導入文化が成熟しておらず, 保育側のニーズを AI 側が把握することが求められる.

また, 心的状態の推定という技術は, 極めて幅広い応用場面が予想される. 保育・教育以外にマーケティング, 介護, 医療にも多くの活用場面が想像できる. この為, 本研究が, 保育. 教育分野に依存することなく多様な社会領域へと実装されその有用性が認知されることで, 今まで AI 導入が難かった保育・教育の領域の門戸が開かれることを期待している. そして, 未来に向けて投資すべき子ども達により質の高い保育・教育を提供する為に, 保育を科学的に議論し質を維持・継続していく為のシステム構築を目指したい.

参 考 文 献

[Heckman 2013] Heckman, James J. and Tim Kautz 2013 "Fostering and Measuring Skills: Interventions that Improve Character and Cognition" NBER Working Paper Series 19656

[OECD 2017] Starting Strong 2017 Key OECD Indicators on Early Childhood Education and Care OECD

[A UK 2018] A UK ECERS Network Resource: http://www.ecersuk.org/index.html 2018.2.2

[Ziko 2018] Sics(Ziko)PDF:http://www.kindengezin.be/img/SiCs-ziko-manual.pdf 2018.2.2

[秋田 2016] 秋田喜代美 淀川裕美(訳)2016 『「保育プロセスの質」評価スケール』明石書店

[内閣府 2015] 内閣府 2015 『幼保連携型認定子ども園教育・保育要領』

[Reddy 2015] Reddy.V(著),佐伯胖(訳)2015 『驚くべき乳幼児の心の世界ー「二人称的アプローチ」から見えてくることー』ミネルヴァ書房

[肥田 2017] Hida, R., Yamada, T., at.al 2017 Development of Interest Estimation Tool for Effective HAI Proceedings of the 5th International Conference on Human Agent Interaction 483-486

[山田 2017] Yamada, T., Omori, T., at.al 2017 Verification of a Quantitative Evaluation Method for Quality of Child Care Process : Aiming at an AI-Supported Child Behavior Analysis 18th Annual Conference of PECERA O3TEC03

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

大規模イベントにおける来場者回遊行動分析

Visitors' Migration Behavior Analysis at Large-scale Events

近藤那央[*1] 原田奈弥[*1] 山下和也[*1] 大前智嵩[*1 *2] 本村陽一[*1*2]
Nao Kondo Nami Harada Kazuya Yamashita Tomotaka Omae Yoichi Motomura

[*1] 産業技術総合研究所
National Institute of Advanced Industrial Science and Technology

[*2] 東京工業大学
Tokyo Institute of Technology

There are many big-scale events all around to encourage learning sciences, recruiting or advertising. Though these events' hosts want these events to be more meaningful and interesting to both visitors and exhibitors, it is difficult to correct data to improve the management of these events for their short period or rent space. We show how to correct visitors' data easily and use these data and artificial intelligence technology to improve these events.

1. はじめに

複数の独立した展示ブースが集合し，来場者が自由に回遊することのできる大規模イベントは，様々なテーマで頻繁に開催されている．こうしたイベントの例としては，科学技術イベント，就活イベント，商業展示会などがある．こうしたイベントの主催者は，イベントがよりスムーズに行え，出展者と来場者の両方が満足できるようにブースの配置や講演会スケジュールなどを設計する．しかし，大規模かつ短期間，貸し会議場での開催などの条件により，来場者の回遊データを取得する事が困難である．そのため，多くの現場では，経験則によってイベントが設計されている．

我々は，2016 年度より科学技術イベントであるサイエンスアゴラにて，”みえちゃう！タッチラリー”と称した来場者回遊データ収集システムの開発・運用実験を行ってきた[近藤 16]．収集したデータより，来場者属性や場所による訪問者数の差分が大きいことなどが分かった．そこで，2017 年度のサイエンスアゴラでは運用方法の改良として来場者のシステムへの登録を必須化することで，データ数の増加を狙った．また，システムへの参加ブースも前年度より増加した．本論文では，サイエンスアゴラ 2017 の 3 日目で得られた来場者回遊データの中で，特に時間に着目し解析を行なった結果について示す．

2. サイエンスアゴラ 2017 での来場者データ収集・分析

サイエンスアゴラ 2017 にて，来場者回遊データ収集システム”みえちゃう！タッチラリー”を用いてデータ収集を行なった．以下にイベントとシステムの概要を紹介する．

2.1 イベント概要

サイエンスアゴラは，国立研究開発法人 科学技術振興機構が 2006 年より毎年お台場エリアで開催している，社会と科学をつなぐ日本最大級のオープンフォーラムで，セッションや体験型ブースで構成される．2017 年度は，11 月 24 日から 26 日までの 3 日間，テレコムセンタービル 1 階、3～5 階、8 階、20 階を使って開催され，開場時間は午前 10 時から午後 4 時までであった．

連絡先：近藤那央，産業技術総合研究所，東京都江東区青海 2-3-26 9，n.kondou@aist.go.jp

出展企画は学校や研究機関，企業など多岐に渡り，来場者も未就学児から 70 歳以上まで幅広い年齢層が訪れた．2017 年度の総参加者は[サイエンスアゴラ 2017 開催結果]によると，来場者 3256 人，企画提供者 1767 人，その他ゲスト，プレスを合わせて 5095 人であった．また，出展ブースおよびセッションは 149 であった．

2.2 来場者データ収集システム”みえちゃう！タッチラリー”

我々は今まで RFID シールつきカードと ID 認証端末を用いて，ID に紐付けたデータ収集が低コストで実現できるシステムを開発・運用してきた[本村 15]．このシステムを展示会型の大規模イベント向けに改良したものが”みえちゃう！タッチラリー”である．本システムは，参加者が持つ ID カードと，参加ブースに設置してある ID 認証端末，ID 認証機能つき自動販売機を用いる．参加者はまず個人属性をシステムへ登録し，ID カードの ID と紐づける．カードを持ち，スタンプラリーのようにブースにある ID 認証端末にタッチすることで，個人属性と紐づけられたブース番号とタイムスタンプが取得できる．そして，退場前に ID 認証機能付き自動販売機にタッチし，当日の自分の回遊行動を見る”ふりかえり”を行う．システムの概略図を[図 1]に示す．

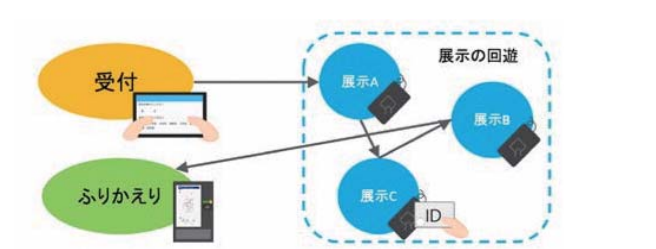


図 1 システム概略図

システムに能動的に参加してもらう工夫として，来場者向けにはブースを訪問するごとにポイントを取得し，”ふりかえり”時にポイントに応じて飲料を得られるようにした．ブース出展者向けにはタッチした人数やタッチ時に取得した満足度評価をリアルタイムで閲覧できるようにした．システムは3日間運用したが，システムトラブルにより後日解析可能なデータは最終日の 11 月 26 日のみであった．

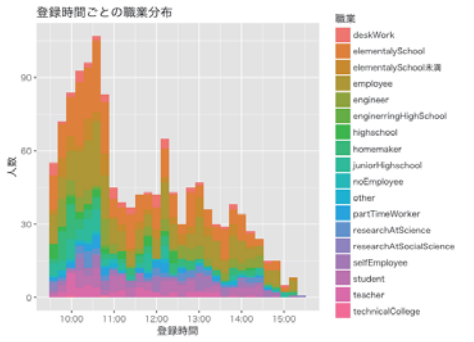


図 2 登録時間毎の人数と職業分布

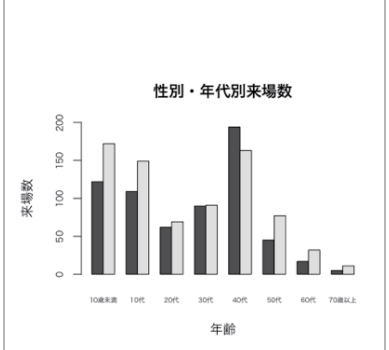


図 3 世代・年代別来場数

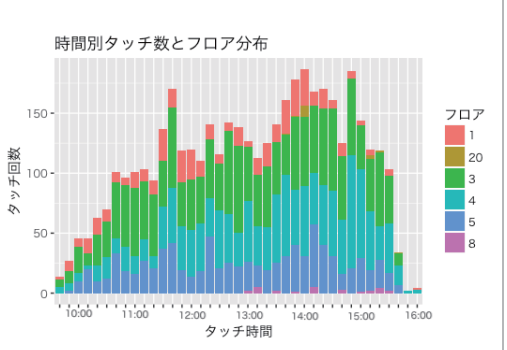


図 4 時間別タッチ回数とフロア分布

2.3 来場者属性

本システムで取得できる個人属性は，”年代”，”性別”，”居住地域”，”所属”，”職業”，”システム登録時刻”である．11 月 26 日のシステム登録者は 2236 人で，その内データ解析に同意した来場者は 1411 人であった．更に，1箇所以上のブースでカードをタッチしてシステムを利用した来場者は 659 人であった．登録時間と人数のヒストグラムに職業で色分けしたグラフを[図 2]に示す．

サイエンスアゴラに来場する人は未就学児または小学生が多く，小学生から大学生までの”学生”が大多数を占める．次に，性別・年代別来場者数を[図 3]に示す．[図 3]の通り，10 歳未満と 10 代の来場者が多い．また，それらの親世代である 40 代の来場者が最も多かった．更に性別に着目すると，全体的に男性の来場者が多いが，40 代までの来場者に関しては男女に大きな差は無かった．また，40 代に関しては女性が多く，ここから未就学児，小学生を連れて来場する母親が多いと推定できる．この傾向は 2016 年度の解析結果でも示されており，年度にかかわらずサイエンスアゴラというイベントの傾向であると言える．

3. 来場者の回遊傾向

1 日を通した会場全体の来場者の回遊傾向を調べるために，時間別のタッチ回数をフロアで色分けしたグラフを[図 4]に示す．まず，タッチ回数に着目する．初めてタッチされた時刻は 9 時 40 分で，最後にタッチされた時刻は 16 時だった．2.3 で述べたように，開場から 10 時 50 分までは登録回数が集中していた．その間，タッチ回数は 1 日の中で最も少なかった．フロアの数字はビルの階であり，2 階では展示が行われていない．また，8 階と 20 階は講演会である．開場から 20 分間は 5 階に訪れた人はいなかった．1 日を通して最もタッチ回数が多いフロアは 3 階で，最も少ないフロアは1階であった．

4. 考察

4.1 受付における問題

サイエンスアゴラではこれまで来場受付と出口アンケートでその都度属性を取得しており，タッチラリーでも属性を取ることは，参加者にとって何度も同じ質問を繰り返すことになり煩雑と思われる可能性があった．そこで，2017 年はサイエンスアゴラの来場者登録とタッチラリーの受付を同時に行い，属性情報を共有することとした．しかし，従来の入場者一人ずつの登録は時間がかかるため，入場時の混雑が予想されていた．図 2 は当日の登録時間毎の登録者数である．当日は入場開始より列ができていた．入場開始の 9:30 より，10:50 までの約 1 時間 20 分の間に来場者が集中した．10:50 を境に入場が激減しており，この時間帯に過集中した事が分かる．9:30 より急激な右肩上がりになっている理由として，登録待ちの列が長くなったため，急遽受付の人数と端末の数を増やした事が挙げられる．ここから，当日行った朝の受付に対する事前対策が不十分であり，混雑する会場から 1 時間半の間は受付端末を通常時より大幅に増やすか，登録方法を変更する必要があると言える．

4.2 来場者のフロア間回遊行動

来場者の入場ピーク時間が終了してからは，1 日を通して継続的にシステムが利用されていた．1 階への訪問者が少ない理由について，1 階の展示が少ないこともあるが，多くの来場者が 1 階の展示を素通りして他のフロアの展示を見に行っていたとも考えられる．最もタッチ数が多い3階は会場の構造上,1階からアクセス良いためであると推定できる．展示ブースがあるフロアとしては最上階である5階は3階に対して訪問者が極めて少なく，フロアによる訪問者数の差は大きいと言える．5 階のうち，タッチ回数が多い時間帯は特別な企画が行われていた可能性が読み取れる．

5. まとめと今後

サイエンスアゴラ 2017 において，来場者の回遊行動データを収集した．訪問時間を中心として解析を行う事で，来場者全体の会場内の回遊を推定することができた．今後訪問時間や訪問ブースなどで来場者をセグメント化することができれば，セグメント毎の回遊行動を推定できる．将来の大規模イベントにおいて，データに基づくブース配置や当日の誘導などの設計ができる可能性が示された．

本研究は NEDO 委託事業「人間と相互理解できる 次世代人工知能技術の研究開発」の支援による．

国立研究開発法人科学技術振興機構の主催するサイエンスアゴラ 2017 において，公式イベントとして実験を実施した．次世代自動販売機より来場者に提供した飲料は，キリン株式会社 から 提供を受けた．

参考文献

[近藤 16] 近藤那央, 竹内理人, 櫻井瑛一, 本村陽一. ID カード と AI 対話システムを用いたイベント空間における行動データの収集と行動支援技術. 人工知能学会合同研究会. 2016.

[サイエンスアゴラ 2017 開催結果] http://www.jst.go.jp/csc/scienceagora/reports/2017/

[本村 15] 本村陽一, 櫻井瑛一, 廣川典昭, 村山敬佑, 川島謙佑, 安松健. コミュニティの行動計量技術~IC カードとタブ レットによるビッグデータ収集と確率的潜在構造分析. 行 動計量学会全国大会, 2015.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

3DCG を用いた介護施設における生活行動学習用データの生成

～技術の社会実装として、介護問題にフォーカスし、AI 技術の社会実装に向けた研究～

北村光司[*1]　本村陽一[*1]　西田佳史[*1]　岩澤朋也[*2]　江島正将[*2]　廣瀬英志[*3]
Koji Kitamura　Yoichi Motomura　Yoshifumi Nishida　Tomoya Iwasawa　Masanobu Eshima　Hideshi Hirose

[*1] 産業技術総合研究所 AIST
[*2] IMAGICA イメージワークス IMAGICA Imageworks, Inc.
[*3] IMAGICA IMAGICA Corp.

1. 緒論

近年，深層学習を筆頭に人工知能技術を実問題に適用する研究が活発になっている．最近では，実問題に適用可能な人工知能技術を作るには，データが最も重要で，質の高いデータをいかに整備できるかが課題であると言われている．つまり，質の高いデータを整備しにくい対象には人工知能技術を適用しにくい．そのような AI 技術が適用しにくい対象の1つに，介護現場での傷害予防や介護支援がある．介護記録のようにデータが存在するものについては，AI 技術を適用して，ケアプランの作成を支援する試みなどがあるが，現場で事故が起きたことを検出したり，身体や認知機能の変化を検出したり，といった現場の環境を見守って介護を支援するような試みはあまり行われていない．その理由は，介護現場の環境やそこにいる高齢者は多様であり，様々な状況に対応可能なほど十分なデータを収集することが困難なためである．特に，事故は日々頻発するわけではないため，データの収集が難しい．また，状況のデータ取得方法としては最も情報量が高い画像データは，プライバシーの問題があり，容易にデータを整備できるものではない．

本研究では，この問題を解決するためのアプローチとして，介護現場やそこで起きる動作や事故を，CG で再現し，その映像を機械学習に用いる，アプローチを提案する．本稿では，試みについて述べる．

2. 3DCG を活用した学習用データの生成

本研究では，機械学習に十分な量のデータを実際には取得しにくいデータに関して，3DCG を活用して作成するアプローチを提案する．CG を活用して学習用データを生成する試みは，物体認識などを対象として研究が行われているが，まだ動作や状況の認識を対象とした試みは少ない．それは，介護施設のように環境も含めてそこで起きる現象の理解が進んでいない対象の場合，何をどのように再現するのかが困難であるためであると考えられる．著者らは，今までに RGBD カメラを実際に介護施設に設置して，高齢者の動作や危険な状況のデータを収集しており[Murata 2017]，これらをベースにすることで，現実との乖離が少ない再現が可能となる．

3DCG を用いて現場の環境や状況を再現することの利点は，あらゆる視点から映像データを生成可能である点，明るさや物の配置といった環境や時間による変化を再現したデータを生成可能である点，1 人の時系列的な動作の組み合わせや複数人の動作の組み合わせを変化させたデータを生成可能である点，実際には取得が難しく，人による再現も難しい事故状況を再現したデータを生成可能である点，生成した画像データはプライバシーの問題がないため，広く公開可能で現場を対象とした研究の活性化への貢献などが考えられる．

学習用データの生成ワークフローは，以下の手順である．

① **対象とする環境や状況の選定：**再現したい環境や状況を，実際の現場へのヒアリングや少数でも存在する実際のデータを元に決定する．

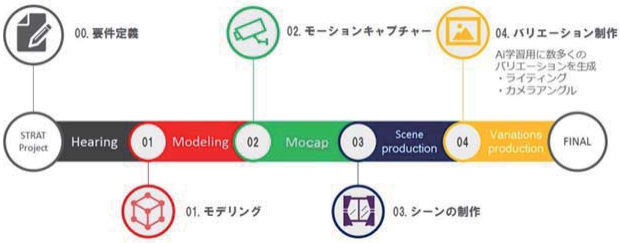
② **選定内容に基づく環境・キャラクタ・道具等 CG モデルデータの制作：**最終的な再現映像に必要な CG モデルを制作する．

③ **現場を模擬した環境で，状況を再現したモーションキャプチャの収録：**動作に関連する場面を切り出し，その動作の再現に必要な模擬環境を構築し，モーションキャプチャで人の動きを収録する．

④ **モーションデータのクリーンナップと，CG シーンの制作：**収録したモーションデータを 3DCG アニメーションで利用可能なようにノイズ除去などの処理を行い，キャラクタの CG モデルに適用し，CG で制作した環境と合わせてシーンを制作する．シーンは，3DCG ソフトやゲームエンジン(3DCG max, maya, UNITY, UE など)で制作・保存することで，様々なバリエーションを制作可能とし，活用可能なようにする．

⑤ **機械学習用にバリエーションの選定と制作：**CG で制作したシーンをベースに，対象とする現場であり得る状況の変化を可能な限りデータに基づいて検討し，映像のバリエーションを選定し，3DCG シーンを制作する．

⑥ **機械学習用データの生成：**制作した 3DCG シーンを元にレンダリングを行い，動画データもしくは連番の静止画データとして生成する．いずれも，FPS は自由に設定可能である．また，教師データとして，フレーム単位もしくは画像単位で，状況や動作，環境や物体などの情報を付与する．



3. 介護現場の再現への適用

本研究では，3DCG を活用した機械学習用データの制作の具体例として介護現場の再現と映像制作を行ったので，その具体的な内容について述べる．

3.1 介護現場での対象の検討と選定

映像を元にした AI 技術が貢献可能な介護現場の課題として，現場のスタッフだけでは常時高齢者を見ることができないことによる，動作や行動の小さな変化の把握や事故などの危険な状況の検出が考えられる．今回は，著者らが既に取得済みの実際の介護現場での映像を元に，介護現場で典型的な動作や状況，事故に関連する動作や状況を整理し，対象を選定した．今回は，「高齢者の健康状態を把握するのに重要な歩行シーン」，「利用者の多い介護支援機

連絡先：北村光司，産業技術総合研究所，k.kitamura@aist.go.jp

器を用いたシーン」，「転倒などの危険性が高い移乗シーン」を中心に選定した．以下に示す 6 種類の状況を再現することとした．

① 手すりに掴まりながら杖を用いて歩く
② 介助されながら椅子から立ち上がる
③ 介助されながら車椅子からベッドへの移乗
④ ベッドからの立ち上がりと歩行器を使った歩行
⑤ 前，後ろより介助されながら歩行器を使って歩行
⑥ 歩行器使用時にバランスを崩して転倒（前及び後ろに転倒）

3.2 行動の再現と 3DCG での映像化

選定した行動を再現し，モーションキャプチャを用いて，人体の動作を関節ごとの動きとして捉え，動画像として 3D データキャプチャを行う．今回モーションキャプチャの収録は，IMAGICA 品川プロダクションセンター内の MIRA-ST で行った．このスタジオで利用した環境やシステム（Fig. 1）は以下の通りである．

・ システム：光学反射式モーションキャプチャーシステム
・ カメラ台数：VICON T1 60 x 22 台（解像度 1600 万画素）
・ ソフトウェア：Blade/Motion Builder
・ フロア寸法：20m(L)X12m(W)X6.6m(H: バトン下) 80 坪

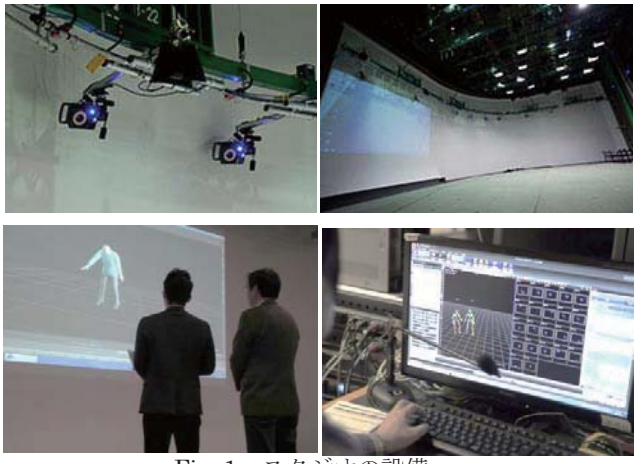


Fig. 1　スタジオの設備

このスタジオでは，複数名での同時収録が可能であり，収録しながらリアルタイムでキャラクタモデルにモーションを流し込んだプレビュを表示しながらチェックが可能になっており，収録しながら最終的な CG 映像をイメージ可能な映像で確認できる．

今回は，実際の介護現場での映像を参照しながら，モーションキャプチャのアクタに動作の再現を行ってもらい，モーションデータを収録した．収録時の様子を，Fig. 2 に示す．



Fig. 2　車椅子への移乗と歩行器で移動の様子

3.3 バリエーションの作成とアノテーション付学習データの作成

CG でシーンを再現することで，キャラクタ，アングル，環境(背景，物体，明るさなど)，時間帯等を容易に変更可能となる．このような CG の特性を活かすことで，実際にあり得る状況を網羅した機械学習用データを生成することが可能である．Fig. 3 に明るさを変えた場合の例と，アングルを変更した場合の例を示す．

最終的に，生成した CG 映像とモーションキャプチャ撮影時の実写の映像の例を Fig. 4 に示す．このような映像を複数生成し，深層学習用プログラム Chainer で取り込み，実際に学習に使用できることを確認した．このように，3DCG を活用することで，学習データを整備することが難しい介護現場での状況を再現可能で，そのバリエーションを整備可能であることが確認された．

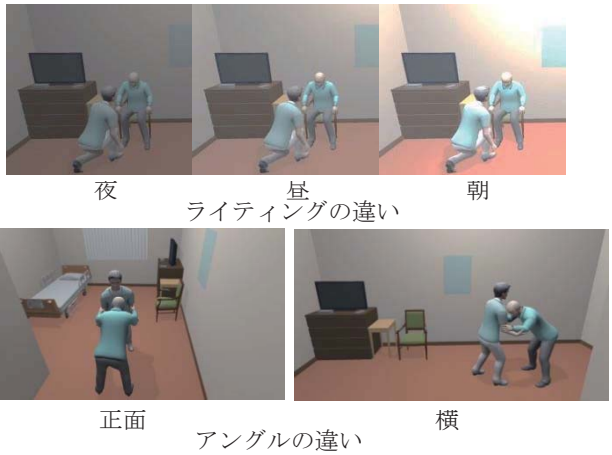


Fig. 3　映像のバリエーションの例



Fig. 4　実写と CG での再現の例

謝辞
本研究は NEDO 委託事業「人間と相互理解できる 次世代人工知能技術の研究開発」の支援を受けて行いました．

参考文献

[Murata 2017] Erisa Murata, Koji Kitamura, Mikiko Oono, Yoshihisa Shirato, Yoshihumi Nishida: "Behavior Monitoring with Non-wearable Sensors for Precision Nursing," Proceedings of the 6th International Conference on Applied Human Factors and Ergonomics(AHFE 2017), pp. 384-392, July 2017.

[1P1] [General Session] 3. Data Mining

座長:成松 宏美（NTT）

Tue. Jun 5, 2018 1:20 PM - 3:00 PM Room P (4F Emerald Lobby)

[1P1-01] A Sampling Method based on Generalized Relative Square Error to Emphasize Low Probability Events

Hiroshi Hasegawa[1], ○Tomomi Nakamura[1], Takashi Washio[2] （1. Dept. Math and Sciences, Ibaraki University, 2. ISIR, University of Osaka）

1:20 PM - 1:40 PM

[1P1-02] Adaptive questionnaire system based on Bayesian network

○Shu Tamura[1], Eiichi Sakurai[1], Youichi Motomura[1] （1. National Institute of Advanced Industrial Science and Technology (AIST)）

1:40 PM - 2:00 PM

[1P1-03] Applying Ordinal logit model to Self-Attentive-LSTM

○Hiroyuki Mitsugi[1], Michiharu Kitano[1], Hiroaki Watabe[1] （1. Daiwa Institute of Research Ltd.）

2:00 PM - 2:20 PM

[1P1-04] Creation of Causal Relation Network using Semantic Similarity

○kohei nishimura[1], Hiroki Sakaji[2], Kiyoshi Izumi[2] （1. Department of Systems Innovation, Faculty of Engineering, The University of Tokyo, 2. Graduate School of Engineering, The University of Tokyo）

2:20 PM - 2:40 PM

[1P1-05] Analysis of the relation between leaders and revitalization of community activities

○Kosuke Hamajima[1], Atsuko Mutoh[1], Koichi Moriyama[1], Nobuhiro Inuzuka[1] （1. Nagoya Institute of Technology）

2:40 PM - 3:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

一般化相対二乗誤差に基づく低確率事象強調サンプル法

A Sampling Method based on Generalized Relative Square Error to Emphasize Low Probability Events

中村文美 *1　長谷川博 *1　鷲尾隆 *2
Tomomi Nakamura　Hiroshi Hasegawa　Takashi Washio

*1茨城大学大学院理工学研究科
Graduate School of Science and Engineering, Ibaraki University

*2大阪大学産業科学研究所
The Institute of Scientific and Industrial Research, University of Osaka

A method of data sampling from a huge data set is discussed. We introduce a generalized relative square error to emphasize low probability events and figure out the best sampling weight to reduce the error. Our arguments are based on the large deviation theory. Large reduction in the generalized relative square error was numerically confirmed for the best sampling weight. We also propose to use Wang-Landau algorithm in data sampling. This algorithm is not only efficient to estimate a distribution of the original data, but also useful in data sampling to suppress the statistical errors.

1. 背景

近年、ネット社会の発達に伴い、カードや携帯電話が普及し、時々刻々の個人レベルの情報が収集されている。また気象などの解析のための大規模シミュレーションなどによっても、膨大なデータが生み出されている。この状況から、ペタ（エクサ）というスケールの大規模データから有益な情報を導かなければならない状況になりつつある。

しばしば、このような大規模データの全てを用いて解析することは、効率的ではないので、サンプル・データを用いて解析することが考えられる。しかしながら、ただ一様にサンプリングすれば、頻出事象のデータは取り込めても、低確率事象のデータは捨てられてしまう可能性が高い。頻出事象と低確率事象が同程度の重要性を持つ場合は、一様サンプリングで良いが、大規模事故や大規模災害のように、滅多に起きない事象の方が重要な場合がある。このような場合、ハインリッヒの法則を考慮すれば、頻出事象から低確率事象まで、切れ目なくサンプリングする必要がある。この論文では、低確率事象を考慮したサンプリング法を提案する。

最初、低確率事象の重要性を考慮して一般化した相対二乗誤差を導入する。次に大偏差理論 [Ellis 06] を基礎に、一般化相対二乗誤差最小を実現するサンプル分布を特定する。そして、特定したサンプル分布に対して、一般化相対二乗誤差が実際小さくなることを数値実験により確認した結果を報告する。最後に、Wang–Landau 法 [Wang–Landau 01] を適用して、データ分布が不明のデータからデータ分布を推定しつつ、サンプリングを行う場合の一般化相対二乗誤差の減少について議論する。

2. 一般化相対二乗誤差最小分布

実数 x は定義域 $[x_{\min}, x_{\max})$ に含まれるとし、大規模データが従う確率分布を $f(x)$ とする。確率分布 $f(x)$ から生成された大数 N_L のデータ集合を $X = \{x_n | n = 1, \cdots, N_L\}$ とする。定義域を $i_{\max}$ 個の区間 $I_i = [x_{i-1}, x_i)$ $(i = 1, \cdots, i_{\max}, x_{\min} = x_0, x_{\max} = x_{i_{\max}})$ に分割し、i 番目の区間 I_i に含まれる確率を f_i とする *1。データ集合 X からデータ $x \in I_i$ をランダムにサンプルした時、重み π_i で選択するとする。この重み π_i を低確率事象に配慮して設計する。

区間 I_i にデータがサンプルされる確率は $p_i = \pi_i f_i$ で与えられる。しかし統計ゆらぎのため、実際に区間 I_i にデータがサンプルされる数 n_i は、一般には np_i からずれる。ここで n は全サンプル数とする。今、確率 $q_i = n_i/n$ と定義するとき、確率分布 p, q を、各々 $p = \{p_i | i = 1, \cdots, i_{\max}\}, q = \{q_i | i = 1, \cdots, i_{\max}\}$ とする。このとき、期待されるサンプル分布 p に対して、サンプルでの実現分布 q の出現確率は、大偏差理論 [Ellis 06] より、以下のように与えられる。

$$P(q|p) \approx \exp[-nD_{\mathrm{KL}}(q:p)] \tag{1}$$

ここで、カルバック・ライブラー（KL）ダイバージェンス $D_{\mathrm{KL}}(q:p) = \sum_i q_i \log(q_i/p_i)$ は q と p の情報的距離を与える。q と p が等しい時のみ $D_{\mathrm{KL}}(q:p) = 0$ となる。

期待されるサンプル分布 p が与えられたときの、誤差の期待値を以下のように定義する。ここで低確率事象を考慮して一般化した相対二乗誤差を用いる。

$$E_\nu(p) = \int \sum_{i=1}^{i_{\max}} |\frac{f_i - \hat{f}_i(q|p)}{f_i^\nu}|^2 P(q|p)\delta(\sum_{j=1}^{i_{\max}} q_j - 1) dq_1 dq_2 ... dq_{i_{\max}} \tag{2}$$

ここで $\hat{f}_i(q|p) = f_i q_i/p_i = q_i/\pi_i$、$\delta$ 関数は確率の規格化のために導入してある。ν は低確率事象を考慮して選択する実数とする。$\nu = 0$ のとき、$E_\nu(p)$ は通常の二乗誤差、$\nu = 1$ のとき、$E_\nu(p)$ は通常の相対二乗誤差を与える。例えば事故データにおいては、大事故の確率は小さくとも、甚大な被害を与える。被害額を考慮して確率の小さい大事故をより優先させるサンプリングでは、$\nu > 1$ が選択される。

一般化相対二乗誤差 $E_\nu(p)$ を最小にするサンプル分布 p を導出する。まず $P(q|p) \approx \exp[-nD_{\mathrm{KL}}(q:p)]$ を見積もる。n

連絡先: *1 e-mail: 16nm110t@vc.ibaraki.ac.jp,
hiroshi.hasegawa.sci@vc.ibaraki.ac.jp
2 e-mail: washio@ar.sanken.osaka-u.ac.jp

*1　区間選択としては、簡単な均等分割でも良いが、区間幅に重みをつけた区間選択も可能である。

が十分に大きいとき、$D_{\mathrm{KL}}(q:p) \approx 0$、すなわち $q \approx p$ の近傍のみが積分に寄与できる。そこで $q_i = p_i + \Delta q_i$ として、Δq_i の 2 次まで見積もると、$D_{\mathrm{KL}}(q:p) \approx \sum_i \Delta q_i^2/(2p_i)$ となり、一般化相対二乗誤差 $E_\nu(p)$ は以下のように書き換えられる。

$$E_\nu(p) \approx C \int \sum_{i=1}^{i_{\max}} \frac{f_i^{2(1-\nu)} \Delta q_i^2}{p_i^2} \exp[-n \sum_{j=1}^{i_{\max}} \frac{\Delta q_j^2}{2p_j}] \times \delta(\sum_{j=1}^{i_{\max}} \Delta q_j) d\Delta q_1 d\Delta q_2 ... d\Delta q_{i_{\max}} \quad (3)$$

ここで C は規格化定数である。更に、δ 関数の積分表示、$\delta(x) = \int_{-\infty}^{\infty} \exp[-\mathrm{i}kx] dk/(2\pi)$ を上の一般化相対二乗誤差 $E_\nu(p)$ の式に代入して、鞍点法で Δq_i^2 までガウス積分で見積もると、

$$E_\nu(p) \approx \frac{1}{n} \sum_{i=1}^{i_{\max}} f_i^{2(1-\nu)} (\frac{1}{p_i} - 1) \quad (4)$$

となる。ガウス積分であるが、実際の計算はかなり面倒である。

次に、一般化相対二乗誤差 $E_\nu(p)$ を最小にするサンプル分布 $p^{(\nu)}$ を導出する。$p^{(\nu)}$ は規格化条件 $\sum_i p_i = 1$ の下での一般化相対二乗誤差 $E_\nu(p)$ 最小化の式の解として求めることができ、

$$p_i^{(\nu)} = \frac{f_i^{1-\nu}}{\sum_j f_j^{1-\nu}} \quad (5)$$

となる。$E_\nu(p)$ が通常の二乗誤差（$\nu = 0$）のときは、$p_i^{(0)} = f_i$ すなわち $\pi_i = 1$ となって、単純サンプリングが二乗誤差最小のサンプリング法になる。$E_\nu(p)$ が通常の相対二乗誤差（$\nu = 1$）のときは、サンプル分布が一様分布 $p_i^{(1)} = 1/i_{\max}$（$\pi_i = 1/(i_{\max} f_i)$）となって、全ての事象を一様にサンプルすることが相対二乗誤差を最小にする。

最後に、この後の数値実験の準備として、サンプル分布 $p^{(\eta)}$ に対する一般化相対二乗誤差 $E_\nu(p^{(\eta)})$ を導出しておく。

$$E_\nu(p^{(\eta)}) \approx \frac{1}{n} \{ \sum_i f_i^{1-2\nu+\eta} \sum_j f_j^{1-\eta} - \sum_i f_i^{2(1-\nu)} \} \quad (6)$$

3. 数値実験

人工データからサンプリングを行って、サンプル分布 $p^{(\eta)}$（$\eta = 0, 1/2, 1, 2$）を生成し、一般化相対二乗誤差 $E_\nu(p^{(\eta)})$（$\nu, \eta = 0, 1/2, 1, 2$）を計算し、理論の結果と比較した。またサンプル分布 $p^{(\nu)}$ に対する $E_\nu(p^{(\nu)})$ が、他のサンプル分布に対する $E_\nu(p^{(\eta)})$（$\eta \neq \nu$）に比較して小さくなることを、数値実験により確認した。具体的には、以下の数値実験を行った。

1. Box-Muller 法で 200 万個の標準正規乱数を生成して、元データとした。
2. $[-3, 3)$ を定義域として、均等幅の 100 個の区間でヒストグラムを作成し、データ分布 f_i $(i = 1, 2, \cdots, 100)$ を導出した。
3. 導出したデータ分布 f_i から、理論値 $E_\nu(p^{(\eta)})$（$\nu, \eta = 0, 1/2, 1, 2$）を計算した。
4. $\eta = 0, 1/2, 1, 2$ のサンプル分布 $p^{(\eta)}$ は、元データから重み $\pi_i \propto f_i^{-\eta}$ で選択して生成した。サンプル分布のデータ数は 1000 個として、一般化相対二乗誤差 $E_\nu(p^{(\eta)})$（$\nu = 0, 1/2, 1, 2$）を計算した。統計サンプル数は 1 万とした。

数値実験の結果を表 1 に示す。理論と数値実験が良い精度で完全に一致した。特に一般化相対二乗誤差 $E_\nu(p^{(\eta)})$ に対しては、期待通り $\nu = \eta$ の場合に誤差が最小となった。例えば、相対二乗誤差について、重み無しでサンプルした場合と最小を実現する一様分布になるようにサンプルした場合と比較すると、相対二乗誤差は約 1/5 に減少した。

表 1．サンプル分布 $p^{(\eta)}$ に対する一般化相対二乗誤差 $E_\nu(p^{(\eta)})$

$E_\nu(p^{(\eta)})$	$\eta = 0$	$\eta = 1/2$	$\eta = 1$	$\eta = 2$
$\nu = 0$ 実験	9.86E-4	1.10E-3	1.68E-3	1.65E-3
$\nu = 0$ 理論	9.86E-4	1.10E-3	1.68E-3	1.65E-3
$\nu = 1/2$ 実験	0.0993	0.0772	0.0987	0.844
$\nu = 1/2$ 理論	0.0990	0.0772	0.0990	0.843
$\nu = 1$ 実験	50.5	15.5	9.90	49.6
$\nu = 1$ 理論	49.6	15.4	9.90	49.6
$\nu = 2$ 実験	2.25E8	3.80E7	8.65E6	2.38E6
$\nu = 2$ 理論	2.16E8	3.72E7	8.56E6	2.56E6

実用においては、元のデータ分布が不明の場合が想定される。その場合に備えて、Wang–Landau 法 [Wang–Landau 01] を適用して、データ分布を効率的に推定すると同時にサンプリングを行うことを試みた。今回、Wang–Landau 法は、元データのデータ分布の効率的推定に有用であるだけでなく、サンプリングの統計誤差の抑制にも効果があることが明らかになった。簡単のために、目標サンプル分布が一様の $p^{(1)}$ 場合に、Wang–Landau 法を用いてサンプリングを行ったところ、相対二乗誤差 $E_1(p^{(1)})$ は更に 1/5 以下に減少した。

4. 結論

この論文で、我々は、大規模実データからの低確率事象強調サンプリングに、一般化相対二乗誤差最小を実現するサンプル分布を用いることと同時に、元データのデータ分布の推定とサンプリングに、Wang–Landau 法を用いることを提案した。我々は、低確率事象を強調して扱うために、相対二乗誤差をより一般化した一般化相対二乗誤差を導入し、誤差最小を実現するサンプル分布を推定した。この結果は、数値実験により、良い精度で確認された。更に Wang–Landau 法は、実用において必要な元データ分布の効率的推定に有用であるだけでなく、サンプリングにおいても、統計ゆらぎの抑制効果があることを数値実験で確認した。

この論文の基礎となる着想は、マルチカノニカルマルコフ連鎖モンテカルロ法から得ている [Berg–Neuhaus 92]。そこでは低確率事象を強調するために、サンプルヒストグラムのフラット化、すなわちすべての事象を一様にサンプルするために、状態密度の逆数の重みでサンプリングを行う。これは我々の相対二乗誤差最小の一様サンプル分布に対応する。また状態密度の効率的な計算法として開発されたのが、Wang–Landau 法である。

参考文献

[Ellis 06] Ellis, R. S.: Entropy, Large Deviations and Statistical Mechanics, Springer Publication (2006).

[Wang–Landau 01] Wang, F. and Landau, D. P.: Phys. Rev. Lett. **86** 2050–2053 (2001).

[Berg–Neuhaus 92] Berg, B. and Neuhaus, T.: Phys. Rev. Lett. **68** 9–12 (1992).

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

Bayesian Networkを用いた動的アンケートシステムの提案

Adaptive questionnaire system based on Bayesian network

田村　脩 *1　　櫻井　瑛一 *2　　本村　陽一 *3
Shu Tamura　　Eiichi Sakurai　　Youichi Motomura

*1*2*3産業技術総合研究所
National Institute of Advanced Industrial Science and Technology (AIST)

In this study, we aim to find effective and personalized questions from a questionnaire that enable answerers clustering. We propose a question selection method based on a Bayesian network model that is constructed from probabilistic clustering results. We show that the gap between the accuracies of estimating cluster index of our method and the upper bound of them is very small.

1. はじめに

ユーザのモデル化を図り商品のマーケティングや新商品の設計に生かすことは広く行われてきた．昨今では，大量のデータの収集が可能となったことで，客観的なデータからユーザーモデルを作成することが試みられている．その一例としては，購買履歴などの人の行動データから行動の類型化を行い，行動の典型的な例を作成することがある．例えば，[石垣 10] では，顧客の購買行動を Probabilistic Latent Semantic Analysis[Hofmann 99](以降 PLSA と略す) を拡張したモデルで人の類型化を行い，得られた顧客行動のセグメント情報と顧客に対して行ったアンケートデータに基づいたベイジアンネットワークを作成することで得られた顧客行動セグメントの構造を明らかにしている．この論文では，セグメントを数億のログデータから作成しているが，その本質は購買商品頻度と顧客という二次元のデータから，確率的手法によりセグメントを得ることにある．したがって同様の形式のデータであれば，形式的に適用することでセグメントとその関係を明らかにすることが可能となる．そのような例として，アンケートデータそのものに PLSA にてクラスタリングを行い，得られたセグメントの特徴をセグメントに対するベイジアンネットワークから見出した研究も存在する [井手 17]．このように分析として，クラスタリング手法とベイジアンネットワークを組み合わせたセグメント説明モデルにより，データに基づいたクラスタリング結果の解釈が可能となることがわかる．

上記の例は分析を目的としていたが，アンケートデータを拡充するためには，サービス (ゲーミフィケーションなどの形をふくめ) として，データを蓄積する仕組みが必要である．しかし，次々と未知の人が来るときにその人がどのクラスであるかを推定する問題の下で，ベイジアンネットワークを使用してユーザーモデルを推定する場合，新規の人にアンケートをすべて回答してもらう必要がある．多くの場合，アンケートは多くの設問から構成され，設問内に多くの選択肢を含むため，すべてを回答してもらうコストは非常に大きくデータを蓄積する当初の目論見を損なう恐れが大きい．

そこで，本論文では，ベイジアンネットワークによるセグメント説明モデルを用いてアンケート項目を逐次に提示することで，ユーザーセグメントの推定をどれだけ可能となるかを検証することとした．

連絡先: 田村脩，国立研究開発法人産業技術総合研究所 人工知能研究センター，東京都江東区青海 2-4-7，0465-35-7815，shu.tamura@aist.go.jp

2. 提案手法

先に，提案手法で使用する方法を紹介し，提案手法について述べる．

2.1 PLSA

PLSA(Probabilistic Latent Semantic Analysis) は文書分類のために考案されたモデルである [Hofmann 99].

このモデルは，文書に出現する単語 w は話題 k によって変化し，各文書 d は話題 k の混合によって出来上がっていると考える．この話題 k がいわゆる潜在クラスである．このモデルでは文章，単語，潜在クラスの同時確率を次のように定義する:

$$P(w,d,k) = \sum_k P(w|k)P(d|k)P(k).$$

この同時確率から文章データセット $\mathcal{D}$ に対する尤度を計算し，EM 法を用いて尤度最大化されるように，$P(w|k), P(d|k), P(k)$ を推定をする．

2.2 Bayesian Network

ベイジアンネットとは，条件付き確率により，データ間の潜在的な依存構造をモデル化する手法である．例えば，X_1, X_2, X_3, X_4 の 4 個の変数が存在したときに，その同時確率を

$$P(X_1, X_2, X_3, X_4) = P(X_1)P(X_2|X_1)P(X_3|X_1, X_4)P(X_4)$$

と表現できたとすると，その関係はグラフとして図 1 のように表現される．このような条件付き確率に基づいたモデルの手段をベイジアンネットワークという．データからこのネットワークを推定する場合，各変数が条件付き確率としてもっとも結びつきが強いものから選択され，全体の構造の複雑さとのトレードオフによりグラフ構造が推定されることになる．

今回の分析では，各変数 X_i がアンケートの設問となる．そして，アンケート回答結果のデータから，この条件付確率による関係をベイジアンネットワークにより推定し，アンケートの設問とセグメント間の関係性を導き出した．

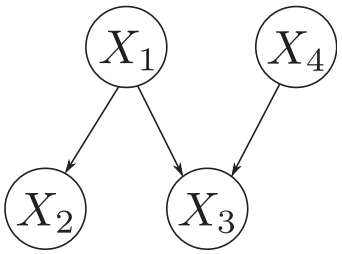


図 1: ベイジアンネットワークの例

2.3 提案手法

本研究では，まずアンケートデータそのものに対して PLSA を用いてクラスタリングを行い，得られたセグメント及びそれを説明する設問に関するベイジアンネットワークを構築する．その後，セグメントにエビデンスを与えた際の各設問の確率値の変化量をもとに，次の設問を逐次的に選定するシステムを提案する．

本項では，まず確率値の変化量を算出する際に用いる KL ダイバージェンスについて紹介したのち，逐次的設問選定システムの詳細について述べる．

2.3.1 KL ダイバージェンス

KL ダイバージェンスとは，ある二種類の確率分布がどれだけ似ているかを表す指標である．同じ確率分布では値が 0 になるため，便宜的に確率分布間の距離として扱われる．α, β を離散確率分布とした際の KL ダイバージェンスは，以下の式であらわされる．

$$D_{KL}(\alpha, \beta) = \sum_{k}^{K} \alpha_k * \log \frac{\alpha_k}{\beta_k} \tag{1}$$

2.3.2 エビデンス付与による設問の確率値の変化量

セグメントの集合 $C = \{c_1, ..., c_x, ..., c_X\}$ を，設問の集合 $Q = \{Q_1, ..., Q_y, ..., Q_Y\}$ が説明する構造のベイジアンネットワークを考える．設問の集合 Q における y 番目の設問 Q_y が，選択肢の集合 $Q_y = \{q_1, ..., q_k, ..., q_{n_y}\}$ を持つとしたとき，新たなエビデンスを付与した際の設問 Q_y の確率値の変化量 $ProbChange(Q_y)$ を以下の式で定義する．

$$ProbChange(Q_y) = \sum_{q \in Q_y} d(q) \tag{2}$$

$$d(q) = \sum_{c \in C} \sum_{x=0}^{1} D_{KL}(new\_p(q, c = x), old\_p(q)) \tag{3}$$

ここで，$old\_p(q)$ は，既に回答された設問の回答をエビデンスとして与えた際に推測される，選択肢 q の選択確率分布である．そして，$new\_p(q, c = x)$ は，既に回答された設問の回答及び，セグメント c に x(0 または 1) のエビデンスを与えた際に推測される，選択肢 q の選択確率分布である．なお，$c = 0$ は，クラスタ c には属さないという意味であり，$c = 1$ は，クラスタ c に属するという意味である．この 2 つの分布の KL ダイバージェンスをとることで，確率値の変化量とした．

2.3.3 逐次的設問選定の方法

各セグメントの所属確率の変化に敏感に反応する選択確率を持つ選択肢が，優先して選定するべき重要な選択肢であると考えられる．そこで，既に回答された設問のエビデンスを所与として，各セグメントにバイナリでエビデンスを与えた際に，各選択肢の選択確率値の変化の合計値 ($ProbChange$) が最も大きい設問を，次の設問として採用する．この方法によって，セグメントへの影響が大きい設問を優先的に採用できると考えられる．以下に具体的な式を示す．

既に回答された設問集合を $preQ$ とすると，アンケートシステムで次に質問する設問 $nextQ$ は，以下の式によって決定される．

$$nextQ = Q_{nextqid} \tag{4}$$

$$nextqid = \underset{y|1 \leq y \leq Y, y \notin preQ}{\arg\max} ProbChange(Q_y) \tag{5}$$

つまり，まだ質問の終了していない設問群のうち，$ProbChange$ の値が最も大きい設問を採用する．

3. 使用したデータセット

アンケート対象として 18 歳以上で車を所有し，車購入の決定権者でかつ 5 年以内の購入者の中で，車に対して安さのみを求めない人を対象者にインターネット調査を行った結果のデータを今回は使用した．設問の内容は，回答者のデモグラフィック属性と，車の購入に対する重視点，車に対するわくわく感などの感性的な質問である．このデータでは，総数として 4164 名のデータがあり，その中でも，回答に対する誠実さを問う設問に正確に答えた 3373 名のデータを使用した．

4. 実験

今回の実験では，提案手法である逐次的設問選定を行った場合と，すべての設問に回答した場合とを比較し，提案手法の有意性について検討する．

4.1 準備

実験を行うにあたり，3373 名の全回答について，PLSA により 7 つのセグメントに分類した．続いて，各セグメントを各設問が説明するようにベイジアンネットワークを作成した．ベイジアンネットモデルの構築には，ベイジアンネットワーク構築ソフトウェア Bayonet[本村 03] を用いた．

4.2 実験概要

本実験の概要について述べる．本実験では，未知のユーザーのセグメント推定を目的としているため，PLSA によって得たセグメントについて，提案手法及び比較手法を用いて推薦結果を出力し，実際の回答結果と比較した．

また，ユーザーのセグメントに限らず，一人のユーザーが複数の回答を行う設問についても推論が可能であるため，重要な情報であると考えられる「車の購入に対する重視点」を示す設問についても予測を行うこととした．

データセットとしては，PLSA 及びベイジアンネットワークを作成した際と同様のデータを使用した．

まず，提案手法については，回答する設問数を 5 つとした．評価の際には，動的に採用した 5 つの設問をエビデンスとして，ベイジアンネットワークで予測を行い，確率の高い上位 1 件または 3 件を推薦結果として出力した．

また，比較手法として，以下の二種類の実験も行った．

・全 30 問の設問の回答結果をエビデンスとし，ベイジアンネットワークで予測

・全 30 問の設問の回答結果及び，PLSA によって得られたセグメントをエビデンスとし，ベイジアンネットワークで予測 (車の購入に対する重視点の予測時のみ)

4.3 評価

本実験の評価として，以下の 2 種類の評価指標を用いた．
・$matching\_rate$: ユーザー単位での実際の回答と推薦結果の一致率を算出し，全ユーザーについて平均をとった指標．
・hit_rate: 推薦結果と実際の回答で一致するものが 1 つ以上存在すれば成功であるという考えによる指標．
以下に詳細を説明する．

4.3.1 $matching\_rate$

1 つ目の指標 (以後 $matching\_rate$ とする) について説明する．$matching\_rate$ は以下の式で表される．

$$matching\_rate = \frac{\sum_d \frac{matching(d)}{\min(label(d), recommend)}}{D} \tag{6}$$

ここで，D はユーザー数を，$matching(d)$ はユーザー d において推薦結果と実際の回答が一致した個数を，$label(d)$ はユーザー d の実際の回答結果の個数を，$recommend$ は本実験での推薦個数 (1 または 3) を表す．実際の回答が推薦数よりも多い場合に，全ての回答をマッチングさせることができないことを考慮した評価指標である．

4.3.2 hit_rate

続いて，2 つ目の指標 (以後 hit_rate とする) について説明する．hit_rate は以下の式で表される．

$$hit\_rate = \frac{\sum_d step(matching(d))}{D} \tag{7}$$

$$step(x) = \begin{cases} 1 : x > 0 \\ 0 : x \leqq 0 \end{cases} \tag{8}$$

各ユーザーの推薦結果が，実際の回答と一つ以上一致していれば hit とし，その率をとった指標である．実際の利用シーンを想定した際に，最も優先度が高く，なおかつ高水準であるべき指標であると考えられる．なお，$recommend = 1$ の場合は，$matching\_rate$ と同義であるため，$recommend = 3$ の場合について評価する．また，セグメントの予測においては，各ユーザーは一つのセグメントにのみ所属しているので，$recommend = 3$ の場合についても $matching\_rate$ と同義であるため，hit_rate の評価は行わない．

5. 結果・考察

本項では，まず評価指標を用いて各手法の比較を行い，次に動的設問選択によってどのように設問が選ばれたのかを把握する．

5.1 各手法の比較

5.1.1 PLSA を用いたユーザーセグメントについての評価

PLSA を用いたユーザーセグメントについて，各手法の比較を行う．

表 1 に，各手法における評価指標の一覧を示す．なお，表 1 の評価指標の前に表示されている”1”や”3”は，各ユーザーに対する推薦個数である $recommend$ の値を表している．

表 1: セグメントについての評価比較

	1_matching_rate	3_matching_rate
提案手法	51.11%	87.99%
全設問	68.78%	94.49%

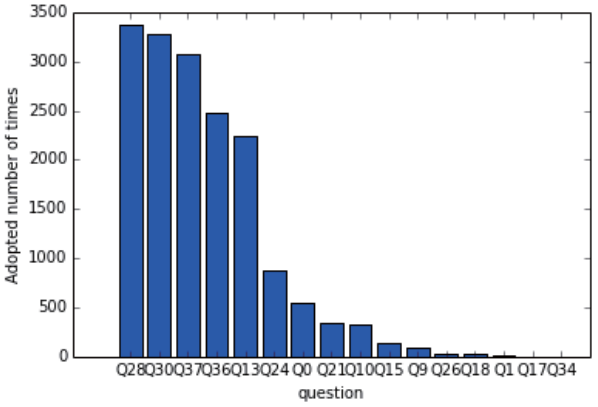


図 2: 採用された設問の採用頻度

表 1 より，推薦数が 1 つの場合における $matching\_rate$ については，提案手法と最高評価の手法の間で，約 18 ポイントの差にとどまっていることがわかる．同様に，推薦数が 3 つの場合の $matching\_rate$ についても約 7 ポイントの差となっている．

5.1.2 車の購入に対する重視点についての評価

車の購入に対する重視点について，各手法の比較を行う．
表 2 に，各手法における評価指標の一覧を示す．

表 2: 車の購入に対する重視点についての評価比較

	1_matching_rate	3_matching_rate	3_hit_rate
提案手法	64.57%	57.94%	85.98%
全設問	71.75%	67.16%	90.78%
全設問及びセグメント	72.49%	67.46%	90.84%

表 2 より，推薦数が 1 つの場合における $matching\_rate$ については，提案手法と最高評価の手法の間で，約 8 ポイントの差にとどまっていることがわかる．同様に，推薦数が 3 つの場合の $matching\_rate$ については約 10 ポイント，hit_rate については約 5 ポイントの差となっている．

5.2 動的設問選択による設問リスト

動的な設問選択によって，扱われる設問の幅がどれ程広がったか，確認を行う．図 2 に，提案手法におけるセグメント予測について，採用された設問と，その採用頻度について示す．

図 2 より，5 つの設問に答える提案手法であるにも関わらず，16 もの幅広い設問から回答を得ていることが読み取れる．これは，前に回答された設問によって，次の設問が変化していることの裏付けであるといえる．

6. まとめ

今回の実験により，動的設問選択を用いた少数設問による予測は，全設問の回答を用いた場合と比較してもそれほど劣っていないといえる．今後は，設問選択における選択基準について，より深く考察をすべきである．

謝辞

本研究（の一部）は国立研究開発法人科学技術振興機構（JST）の研究成果展開事業「センター・オブ・イノベーション（ＣＯＩ）プログラム」の支援によって行われた．また，本研究は，国立研究開発法人新エネルギー・産業技術総合開発機構（NEDO）の委託事業「人間と相互理解できる次世代人工知能技術の研究開発」の支援を受けて行った．

参考文献

[石垣 10] 石垣, 竹中, 本村. 日常購買行動に関する大規模データを融合したベイジアンネットユーザモデル. 人工知能学会全国大会 3J1-NFC1a-2, 2010.

[井手 17] 井手, 川本, 山下, 本村. ミクロアグリゲーションを用いた匿名化による確率的潜在空間意味解析. 人工知能学会全国大会 1K2-2, 2017.

[Hofmann 99] T. Hofmann and J. Puzicha, “Latent class models for collaborative filtering”, Proc. 16th international joint conference on Artificial intelligence, 1999

[櫻井 16] 櫻井, 本村, 安松, 坂本, 道田. 感性ユーザーモデルの構築のためのデータ収集方法. 日本行動計量学会第 44 回大会予稿集, 2016

[本村 03] 本村陽一. ベイジアンネットソフトウェア BayoNet. 計測と制御 42.8 (2003): 693-694.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

Self-Attentive-LSTM への順序ロジットモデル適用

Applying Ordinal logit model to Self-Attentive-LSTM

参木 裕之[*1] Hiroyuki Mitsugi
北野 道春[*1] Michiharu Kitano
渡部 裕晃[*1] Hiroaki Watabe

[*1] 株式会社 大和総研
Daiwa Institute of Research Ltd.

In this research, we propose a method incorporating structure of ordered logit model into output layer of Self-Attentive-LSTM. This helps to predict ordinal variables. Model with using this method learns relationships among classes since the order of classes are assumed in advance. We show this model is useful when the objective variable is ordinal by applying to "The economic watcher", data surveyed by the Japanese Cabinet Office. When predicting the Economic assessment index, this proposed method improved F-measures of both sides of the ordinal indices compared to Self-Attentive-LSTM.

1. はじめに

機械学習において，教師あり学習でも目的変数の種類によって扱う問題が異なる．目的変数が有限離散集合であれば分類問題となるが，目的変数が実数集合であれば回帰問題となる．また，目的変数が順序変量の場合，ランキング学習や順序回帰問題となる．特に，順序ロジットモデル[McCullagh 1980]は，判別関数の係数を各クラスで共有し，切片のみが各クラスで異なるため，クラス分類と回帰の両方に位置する手法である．機械学習の応用の観点としては，近年，深層学習の研究が日々発展し，テキストマイニングにおいて，翻訳や文書生成などのタスクで精度を向上させている．しかし，目的変数が順序変量を扱った問題は筆者の知るところでは無い．例えば，説明変数がテキストを分割した形態素の系列，目的変数が順序変量の場合，LSTM(Long-Short-Term-Memory) [Hochreiter 1997] で目的変数を予測すると，精度が良くならない場合がある．

本研究では，Self-Attentive-LSTM(Long-Short-Term-Memory) [Zhouhan 2017]の出力層に順序ロジットの構造を取り入れることで，順序変量の予測に役立つ手法を提案する．LSTM は RNN(Recurrent Neural-Network)の拡張であり，テキスト等の長文の学習に優れている．LSTM に Self-Attentive の構造を取り入れることで，予測に寄与した形態素の寄与度を算出することが可能になる．通常の判別モデルであれば，各クラスの関係性は独立であるが，順序ロジットを取り入れる利点として，各クラスの順序性が仮定されるため，クラス間の関係性をモデルが学習できるところである．目的変数が順序変数の場合に本手法の有用性を，内閣府が調査・公表している景気ウォッチャー調査[wat]を使用して示す．景気ウォッチャー調査は景気判断理由のテキストと 5 段階の景気判断値が対応しているデータセットであり，2000 年に調査を開始してから，約 20 万件のアンケート情報が確保されている良質なデータである．提案モデルでテキストから景気判断値の予測をしたところ，Self-Attentive-LSTM に比べて景気判断値の両側（景気が良い，悪い）の F-measure の精度が向上した．

2. 関連研究

本研究に関連がある順序ロジットモデルと LSTM を用いた研究を紹介する．

Jianlin らは，ニューラルネットワークの出力層に順序ロジットの構造を適用することで，多くのデータセットに対して，通常のニューラルネットワークより精度が良いことを示している[Jianlin 2008]．目的変数の与え方を one-hot 表現から工夫することで，順序ロジットの構造を取り入れている．しかし，数値データの検証のみでテキストデータの検証には触れられていない．

深層学習を景気ウォッチャー調査に適用した研究として，[山本 2016]では，5 段階の景気判断値（1~5）の中央の値を除いて、1 と 2 を「ポジティブ」、4 と 5 を「ネガティブ」と扱い、2 値判別問題として LSTM で景気ウォッチャーデータを学習し，景気判断が「ポジティブ」か「ネガティブ」を予測している．しかし，目的変数に順序性があることはモデルに考慮されていない．

上記の問題点を踏まえて，本研究では，目的変数の順序性を考慮し，Self-Attentive-LSTM に順序ロジットモデルを適用することで，景気ウォッチャー調査の景気判断値の両側（景気が良い，悪い）の F-measure を既存モデルより精度良く予測した点に新規性があると考えている．

連絡先：参木 裕之，大和総研 フロンティアテクノロジー部，hiroyuki.mitsugi@dir.co.jp

3. OL-ALSTM モデルの提案

提案モデルを OL-ALSTM(Ordinal Logit Self-Attentive LSTM)と呼ぶことにする．ベースモデルとなる Self-Attentive-LSTM を紹介した後に，OL-ALSTM モデルを説明する．

3.1 Self-Attentive-LSTM

予測に寄与した単語を算出する方法として Attention 構造がある．Attention には，翻訳等の seq2seq で使われる Global Attention[Bahdanau 2015]や Local Attention[Luong 2015]があるが，本節では，Self-Attention [Zhouhan 2017]のみを解説する．

Self-Attentive-LSTM とは，LSTM に Attention 構造を入れたモデルである．$X = (x_1, x_2, \cdots, x_n)$を入力の系列（系列の長さは$n$とする）とし，$x_t$を$t$時点の入力ベクトル，$\overrightarrow{h_{t-1}}$を$t-1$時点の順方向の隠れ層のベクトル，$\overleftarrow{h_{t+1}}$は$t+1$時点の逆方向の隠れ層のベクトルとおくと，Bidirectional LSTM の出力は次のように表せる．

$$\overrightarrow{h_t} = \overrightarrow{LSTM}\left(x_t\ ,\ \overrightarrow{h_{t-1}}\right)$$
$$\overleftarrow{h_t} = \overleftarrow{LSTM}\left(x_t\ ,\ \overleftarrow{h_{t+1}}\right)$$

$\overrightarrow{h_t}$と$\overleftarrow{h_t}$を結合したh_tを隠れ層のt時点のベクトルとする．unidirectional LSTM の隠れ層ベクトルの次元をu，系列の長さをnとすると，隠れ層の系列行列Hは次のように表せ，$n \times 2u$の次元となる．

$$H = (h_1, h_2, \cdots, h_n)^T$$

Attention 行列は次のように求めることができる.

$$A = softmax(W_2 \tanh(W_1 H^T))$$

W_1は$d_a \times 2u$の重み行列であり, d_aはハイパーパラメータである. また, W_2は$r \times d_a$の重み行列であり, rはハイパーパラメータである. Aは$r \times n$の次元になり, $softmax$は行方向に計算し, 行方向に和をとると1になることを意味する. 入力HとHから計算されるAを用いると, 文章の埋め込み行列Mは次のように表せる.

$$M = AH$$

埋め込み行列Mを用いて, 最終的に出力層から目的変数を予測する. また, 各形態素の寄与度の算出方法の 1 つとして, Aに対してrの平均(列方向に平均)をとることで寄与度を求めることができる.

3.2 OL-ALSTM モデル

上記の Self-Attentive-LSTM の出力層に順序ロジットの構造を適用することを考える. 目的変数ベクトルをyとする(K個のカテゴリーをもつ)と, 順序性を考慮しなければ, one-hot 表現とするが, 順序性を考慮する場合は, $y \leq k$であれば, ベクトルの先頭からk個を1とし, $y = (1, 1, \ldots, 1, 0, 0)$のように表す[Jianlin 2008]. 出力層のk番目の出力が, 目的変数がk以下になる確率を意味する. 出力層のベクトルを

$$o = (o_1, o_2, \ldots, o_k, \ldots, o_K)$$

とすると, $o_i(i \leq k)$が1, $o_i(i \geq k)$が0に近づくように学習し, 重み行列を逆誤差伝播法で更新する. 活性化関数はシグモイド関数とし, 損失関数はクロスエントロピー関数とする.

$P(y_i \leq i) - P(y_i \leq i+1) = P(y_i = i)$であるため, クラス分類を行う場合は, $o_i - o_{i+1} := \tilde{o_i}$と定義すると, 各クラスの予測確率は, 以下のように表せ,

$$\tilde{o} = (\widetilde{o_1}, \widetilde{o_2}, \cdots, \widetilde{o_k}, \cdots, \widetilde{o_K})$$

最終的な予測クラスは次のように求めることができる.

$$\hat{y_i} := argmax_i \widetilde{o_i}$$

4. 実験

OL-ALSTM モデルの精度を検証するため, Self-Attentive-LSTM と比較する.

(1) 前処理

形態素は wikipedia のダンプ[wik]から学習した Word2Vec モデルによって分散表現ベクトル化した(Word2Vec の次元は 150 次元とした)[Mikolov 2013]. 学習済分散表現ベクトルを重み行列として, OL-ALSTM モデルの Embedding 層に初期値として入力し, End-to-End で学習を行った. また, 未知語と padding に対応するため, それぞれ未知語用のベクトルと padding 用のベクトルを用意し, Embedding 層の重み行列に結合した.

(2) モデルのパラメータ

$u = 300$, $d_a = 350$, $r = 30$とし, Mで特徴抽出が完了した後に 2000 次元の層と 200 次元の層を追加し, 出力層と結合する. 系列の長さは最長の系列にあわせ, バッチサイズは 32, ドロップアウトは 0.2, 学習率は 0.001, 最適化は Adam で行った.

(3) 景気ウォッチャーデータ

景気ウォッチャー調査はタクシーの運転手やスーパーの店主等の景気に敏感な方々を対象としたアンケート調査であり, 景気判断理由のテキストと 5 段階の景気判断値からなる. データは PDF および CSV 形式で毎月公開され, 景気の現状判断と先行き判断の 2 種類存在するが, 今回は現状判断にて検証を行う.

表 1:現状判断の全回答数割合

悪い:1	0. 093
やや悪い:2	0. 253
変わらない:3	0. 435
やや良い:4	0. 201
良い:5	0. 018

(4) 学習方法

2000 年から 2016 年までのデータを 1:1 の割合で学習データと検証データに分け, 検証データの Accuracy で評価する. なお, ベイズ最適化等のハイパーパラメータの最適化は行っていない.

(5) 実験結果

混同行列から集計すると, OL-ALSTM は景気判断値の「1」や「5」の F-measure が大きく, 回答数割合が少ない景気判断値の両側(景気が良い, 悪い)を当てるのが得意と考えられる. 不均衡データであるため、「2」と「3」と「4」の F-measure が高くなる傾向がある中で, モデルとしては, 「1」や「5」の景気の良い局面や悪い局面の F-measure の精度が向上したことに意味がある. また、Precision の観点から, 「1」や「2」と予測したデータのうち, 正解が「5」であった予測誤りの割合が減少し, Recall の観点からは, 正解が「4」や「5」のデータのうち、「2」と予測された再現誤りの割合が減少していたことが確認できた. このことから, 順序ロジットの構造をモデルに取り入れることで, 「1」を「5」と誤判別する誤差と「1」を「2」と誤判別する誤差が異なるので, クラス間の順序性を考慮した学習と予測ができていると考えられる.

表 2:OL-ALSTM の予測結果

OL-ALSTM		Precision	Recall	F-measure
景気判断値	1	0.458	**0.221**	**0.298**
	2	0.504	0.571	0.536
	3	**0.658**	0.694	0.676
	4	0.701	**0.746**	0.726
	5	0.440	**0.027**	**0.051**

表 3: Self-Attentive-LSTM の予測結果

Self-Attentive-LSTM		Precision	Recall	F-measure
景気判断値	1	0.526	0.166	0.252
	2	0.508	0.596	0.549
	3	0.654	0.713	0.682
	4	0.720	0.735	0.728
	5	0.800	0.002	0.005

5. まとめ

本稿では Self-Attentive-LSTM の出力層に順序ロジットの構造を取り入れることで, OL-ALSTM を提案し, クラス間の関係性を順序関係に着目して学習を行った. また, 目的変数が順序変量である景気ウォッチャー調査を用いてモデルの検証を行い, 景気判断値の両側(景気が良い, 悪い)の F-measure の精度が向上したことを確認できた. しかし, 今回検証した景気ウォッチャーデータは景気判断値の両側(景気が良い, 悪い)が反転している教師データは少ないため, OL-ALSTM モデルと Self-Attentive-LSTM モデルで予測精度においては大きな差は見受けられなかった. 今後は, 株価データのようにリスクとリターンの

相関が高いデータ(上昇と下落の反転があり得る)で同様の検証を行い，提案モデルが優位となる局面を考察する予定である.

参考文献

[Bahdanau 2015] Bahdanau, D. et al: Neural machine translation by jointly learning to align and translate, arXiv:1409.0473, 2014.

[Hochreiter 1997] Hochreiter, S. and Schmidhuber, J.: Long short-term memory, Neural computation, Vol. 9, No. 8, pp. 1735-1780 , 1997.

[Jianlin 2008] Jianlin, C. et al: A neural network approach to ordinal regression, IJCNN , 2008.

[Luong 2015] Luong, M. et al: Effective approaches to Attention-based Neural machine transaction, proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing, pages 1412-1421, 2015.

[McCullagh 1980] McCullagh, P.: Regression models for ordinal data, Journal of the Royal Statistical Society B, 42, 109-142, 1980.

[Mikolov 2013] Mikolov, T. et al: Distributed Representations of Phrases and their Compositionality, In Proceedings of the 26th Neural Information Processing Systems, NIPS 2013, pp.3111-3119, 2013.

[wat] 景気ウォッチャー調査, 内閣府, http://www5.cao.go.jp/keizai3/watcher/watcher_menu.html

[wik] ウィキペディアの日本語版のダンプ, ウィキメディア, https://dumps.wikimedia.org/jawiki/

[Zhouhan 2017] Zhouhan, L. et al: A Structured Self-attentive Sentence Embedding, arXiv:1703.03130, 2017.

[山本 2016] 山本裕樹, 松尾豊, 景気ウォッチャー調査の深層学習を用いた金融レポートの指数化, 第 20 回人工知能学会, 2016

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

表現類似度を用いた因果ネットワークの構築

Creation of Causal Relation Network using Semantic Similarity

西村弘平 *1　坂地泰紀 *2　和泉潔 *2
Kohei Nishimura　Hiroki Sakaji　Kiyoshi Izumi

*1東京大学工学部システム創成学科システムデザイン&マネジメントコース
Department of Systems Innovation, Faculty of Engineering, The University of Tokyo

*2東京大学大学院工学系研究科
Graduate School of Engineering, The University of Tokyo

Visualizing chains of Economic events and Financial matters including background events from text data is useful for investors and manager to understand Economic events and Financial matters properly. However, extracting chains of Economic events and Financial matters manually takes a lot of time. Therefore, we treat chains of Economic events and Financial matters as chains of causal relations (we call them Causal Network) and propose the procedure creating causal network using vectors similarity which represent semantic similarities between expressions of Economic events and Financial matters.

1. はじめに

近年, 人工知能分野の手法や技術の金融市場の様々な場面への応用が期待されており, 膨大な金融情報を分析して投資・経営判断を支援する技術が注目されている. 特に, 投資家・経営者は経営・金融事象の情報を把握し, 各事象を正しく理解して投資や経営の判断をする必要がある. 経済・金融事象の理解の支援の 1 つに事象の結果だけではなく, 経済・金融事象に至った背景・原因まで可視化することがあげられる. すなわち, 複数のテキストデータから抽出した因果関係を用いて因果関係の連鎖 (以下, 因果ネットワーク) を構築し, 事象を背景知識とともに可視化する技術は有用である. 本論文では上記の背景を踏まえ, テキストデータから抽出した因果関係ノード間の原因表現と結果表現の表現類似度を測ることによってテキストデータから因果ネットワークを構築する手法を提案する.

2. 先行研究

本章では, 提案手法に関連する因果関係抽出・因果ネットワーク構築の先行研究について述べる.

2.1 因果関係抽出

Khoo et al.[Khoo 2000], 乾ら [乾 2004] は接続関係や格フレームを用いて因果関係を抽出する手法を提案している. これらの手法は単文もしくは複文・重文からしか因果関係を抽出できないという問題点がある. 坂地ら [坂地 2015] は文書中にある因果関係を, 手がかり表現を用いて抽出する手法を提案している. 坂地らの手法は因果関係が存在する構文パターンを列挙し, 手がかり表現を用いることによって単文, 複文・重文関係なく因果関係にある表現を抽出することができる. 本提案手法では坂地らの手法を利用して, 因果関係を抽出する. また, 本論文での因果関係の定義を坂地らと同様に, 「原因若しくは, 理由と結果を示し, 手がかり表現を伴って 1 文中, もしくは隣り合う 2 文中に表層的に出現するもの」とする.

連絡先: 西村弘平, 東京大学工学部システム創成学科システムデザイン&マネジメントコース, 〒 113 ー 8656 東京都文京区本郷 7 ー 3 ー 1 工学部 8 号館 530 室, b2017knishimura@socsim.org

2.2 因果ネットワーク構築

Ishii et al.[Ishii 2012] は SVO の構造と WordNet を用いてニュース記事から因果ネットワークを構築する手法を提案している. Ishii et al. は SVO 構造を利用することで注目する単語を決め, WordNet を用いた単語のマッチングによって概念的な単語の類似度を計算している. 津川ら [津川 2015], [津川 2016] は WebAPI を用いて要因結果検索を用いて, 事象間の共起度を測定し因果ネットワークを構築している. 津川らの WebAPI を用いる手法は検索エンジンのアルゴリズムによって影響を受けるため, 手法の再現性が低いと考えて, 比較手法には Ishii et al. の手法を用いた.

3. 提案手法

本章では, テキストデータから因果ネットワークを構築する手法について述べる. 3.1 節から 3.4 節までで因果ネットワーク構築の概要を述べ, 3.5 節で因果ネットワーク構築に用いる因果ノード間類似度計算手法について述べる. 手法の概要は図 1 の通りである.

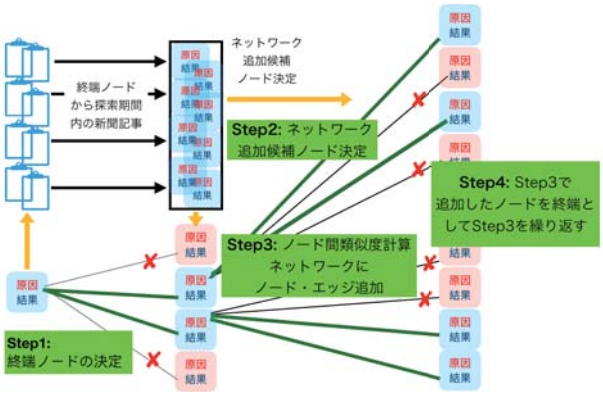


図 1: 因果ネットワーク構築手法の概略

3.1 因果ネットワークの終端ノードの決定

決算短信のテキストから坂地ら [坂地 2015] の手法を用いて因果関係表現を抽出する. 抽出した因果関係ノードの中から市場の情勢や企業の業績を記した因果関係ノードを手動で選択し, 因果ネットワークの終端ノードとする.

3.2 探索対象の因果関係ノードの探索

3.1 節で定めた終端ノードを終端とする因果ネットワークの追加候補の因果関係ノードを日本経済新聞のテキストから抽出する.

因果関係抽出は 3.1 節と同じく坂地ら [坂地 2015] の手法を用いる. 3.1 節で定めた終端ノードよりも過去のもので、終端ノードから探索期間 S 以内の因果関係を因果ネットワークの追加候補とする. さらに坂地らの手法で抽出した因果関係ノードのうち, 原因・結果表現の名詞・形容詞・動詞の単語数の合計がともに閾値 β 以上である因果関係ノードのみを因果ネットワークの追加候補とした.

3.3 因果ネットワークへのエッジ・ノードの追加

3.2 節で抽出した因果ネットワークへの追加候補の全ての因果関係ノードと終端ノードの組み合わせについて因果関係ノード間の類似度を計算する. 因果関係ノード間の類似度が閾値 α 以上であるときにノードを追加して因果ネットワークを拡張する.

3.4 因果ネットワークの更新

3.2 節で抽出した因果関係ノードを因果ネットワークへの追加候補ノード, 3.3 節で因果ネットワークに追加したノードを終端ノードとして 3.2 節, 3.3 節の処理を $n-1$ 回繰り返す. ここで, n はあらかじめ定めた因果ネットワークの更新回数である.

3.5 因果関係ノード間の表現類似度計算手法

本節では, 提案手法で用いている因果関係ノード間の計算方法について述べる. 計算手法の概要は図 2 の通りである. 因果関係ノード間の類似度は 2 種類の類似度を足し合わせることによって計算する. 1 つは IDF 値を用いて作成したベクトル間のコサイン類似度で, もう 1 つは Bojanowski et al.[Bojanowski 2016] の FastText から求めた単語分散表現を用いた類似度である. IDF 値を用いたベクトル表現を用いることによって, 因果関係が含まれている領域やドメインなどのトピック情報の類似度を計算し, FastText から得た分散表現からなるベクトル表現を用いることで比較する因果関係の原因・結果表現間の表層的な類似度を計算する. ベクトル間類似度はコサイン類似度を 0 から 1 の値取るように正規化したものとした.

$$cosine\_similarity = cos(\theta) = \frac{A \cdot B}{\|A\|\|B\|} \tag{1}$$

$$vector\_similarity = \frac{(cosine\_similarity + 1)}{2} \tag{2}$$

IDF 値を用いた類似度は, 因果ネットワークへの追加対象のノードの結果表現と終端ノードの原因表現から IDF 値上位 3 つの単語を抽出し, IDF 値を用いてベクトルを作成しベクトル間の類似度を計算する. IDF 値は 1998 年から 2016 年までの全ての原因・結果表現から抽出した. FastText を用いた類似度は, 因果ネットワークへの追加対象ノードの結果表現と終端ノードの原因表現内にある名詞・動詞・形容詞の分散表現を足し合わせてベクトルを作成し, ベクトル間類似度を計算する. FastText の類似度は cbow と skip-gram の 2 つのアルゴリズムに対して計算した. IDF, FastText の合計 3 つのベクトル類似度の平均を取ることによってノード間の類似度とした.

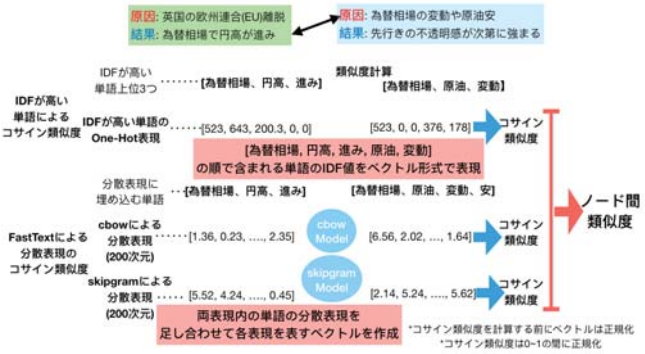


図 2: 因果関係ノード間類似度の計算方法

4. 実験

実験には 1982 年から 2016 年までの 54206 件の決算短信テキストと 1998 年から 2016 年までの 6921 日分の日本経済新聞の記事テキストを用いた.

FastText のモデルの学習には決算短信テキストと日本経済新聞テキストを用いた. また, IDF の計算は日本経済新聞から抽出した因果関係ノードに対して行なった.

決算短信テキストから抽出した因果関係の中から 5 つの終端ノードを手動で選び, 日本経済新聞テキストから因果ネットワークへの追加候補ノードを抽出して因果ネットワークを構築する実験を行なった. 比較手法に Ishii et al.[Ishii 2012] の WordNet を用いたノード間類似度を計算する手法を用いた. 終端ノードは図 5, 実験のパラメータは図 3 の通りである. 比較手法はノード間類似度の値が 0, 0.33, 0.66, 1 のいずれかなので 0.65 のみ実験を行なった.

S, 因果ネットワークへの追加候補ノード探索期間: 52 週間

n, 因果ネットワークの更新回数: 4

α, 因果ネットワークにマージするときのノード間類似度の閾値: 0.65, 0.70, 0.75

β, 因果ネットワークへの追加候補ノードの原因・結果表現の単語数についての閾値: 5

図 3: 因果ネットワーク構築に用いたパラメータ

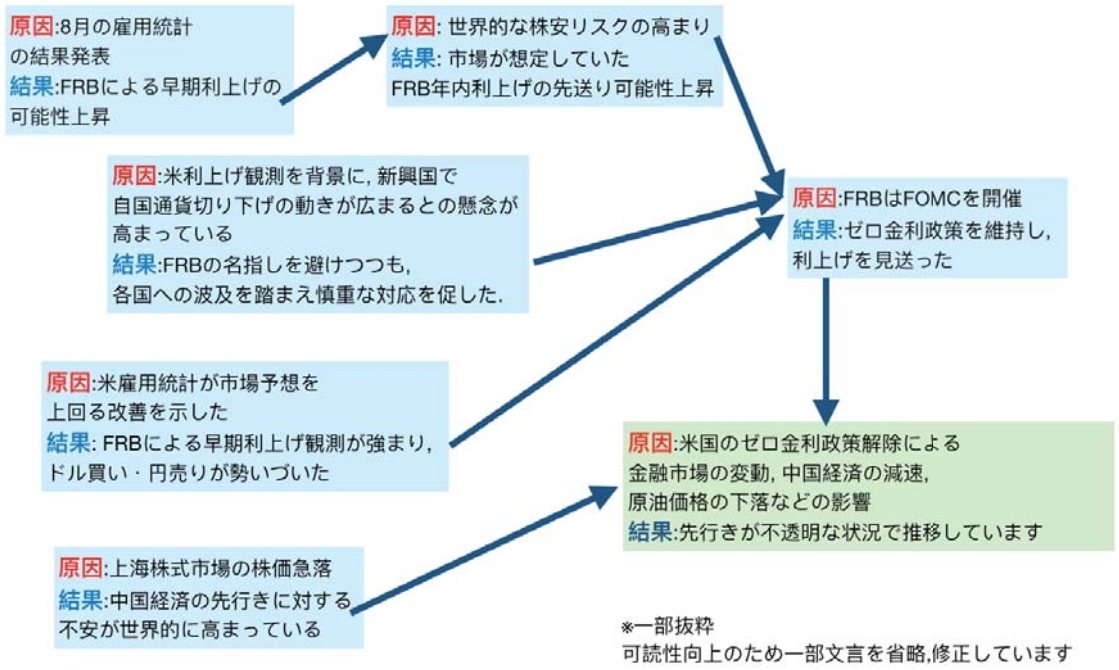


図 4: 構築した因果ネットワークの例

ID1: [原因] 為替相場の変動や原油安 [結果] 先行きの不透明感が次第に強まる, 中央魚類株式会社, 2016-11-2

ID2: [原因] 海外経済の減速懸念や個人消費の低迷, 資源価格安の長期化, [結果] 景気の先行きに不透明感が出てまいりました, 矢作建築工業株式会社, 2016-5-9

ID3: [原因]3 中国や韓国を中心に全世界で鉄鋼生産能力増強が進行し, 過剰な生産設備による供給過剰問題が顕在化する, [結果] 世界的な鉄鋼需給バランスが大きく崩れた, 合同製鐵株式会社, 2016-4-28

ID4: [原因] 米国のゼロ金利政策解除による金融市場の変動, 中国経済の減速, 原油価格の下落などの影響, [結果] 先行きが不透明な状況で推移しました, クエスト株式会社, 2016-4-1

ID5: [原因]EU 情勢不安や中国経済減速の影響, [結果] 売り上げが減少しています, 石塚硝子株式会社, 2016-4-25

図 5: 終端ノードに用いた因果関係ノード

5. 実験結果と考察

手法の評価指標には Precision(精度) とノード数を用いた. 1 日の新聞テキストから約 300 件の因果関係ノードが抽出されるため、数が多く正解データを作成できず再現率の代わりにノード数を評価指標に加えた.

Precision の計算方法は, 構築した因果ネットワークに対してランダムに 100 個のノードを抽出し, ノード間関係が「経済・金融事象を背景知識まで理解するために適切なつながりであれば正しい, そうでなければ誤り」という定義に従って, 因果関係の連鎖として適切か手動で判断し評価を行なった. 各ノード間関係の評価は著者 1 人のみが行なった.

Precision(精度), ノード数をそれぞれ表 1, 表 2 に記す. 手法名は比較手法, 提案手法をそれぞれ比較, 提案と記している.

精度, ノード数がともに高い手法がよりノード間の類似度をより正確に計算できていると言える. 提案手法では, 比較手法に比べて精度では全てのノードについて, ノード数にもおいても 3 つの終端ノードに対して比較手法よりも多くノード数を抽出できており, 提案手法が比較手法よりも精度高くノード間の類似度を計算できていると言える.

表 1: 各実験における精度の差

手法 (α)	ID1	ID2	ID3	ID4	ID5
比較 (0.65)	0.00	0.02	0.03	0.00	0.00
提案 (0.65)	**0.12**	**0.08**	**0.10**	**0.11**	**0.05**
提案 (0.70)	0.39	0.44	0.39	0.46	0.30
提案 (0.75)	1.00	0.48	0.83	0.56	0.60

表 2: 各実験におけるノード数の差

手法 (α)	ID1	ID2	ID3	ID4	ID5
比較 (0.65)	**82392**	24779	**1970587**	56027	11073
提案 (0.65)	80323	**97814**	90978	**100273**	**46429**
提案 (0.70)	44	424	41	288	115
提案 (0.75)	2	26	6	70	10

終端ノードを ID5 としたときの具体的な因果ネットワークの構築事例から抜粋したものを図 4 に示す.

構築した因果関係では,「米国のゼロ金利政策解除による金融市場の変動, 中国経済の減速, 原油価格の下落」という経済事象の原因となったアメリカの金利政策の流れ, 上海市場の動向を因果ネットワークとして取得できていることがわかる.

6. まとめ

本研究では, ベクトル表現の類似度を用いて決算短信と日本経済新聞のテキストから因果ネットワークの構築手法を提案した. また, 5 つの終端ノードについて因果ネットワーク構築の実験を行い, 提案手法が WordNet を用いた既存手法よりも精度高く因果関係間の類似度を計算できることを実験で確認した. 提案手法は WordNet といった事前知識を必要としないため, 新たな単語を含むテキストからでも因果ネットワークを構築することができ有用である.

提案手法には問題点に以下の 2 つの問題点がある. まず 1 つめに因果表現のみだと経済・金融事象の情報量が少ないという問題点がある. 因果表現のみでは経済・金融事象を理解するための情報量が不足している事例を表 3 に記す.

表 3: 抽出した因果表現の情報量が不足している例

原因表現	結果表現	不足情報
同国経済は１５年にマイナス成長に陥ったもよう	通貨安が進んだ影響が大きい。	国名, 地域名
見通しが低い方から８人の平均は０・３６％減	２期連続のマイナス成長を予想する人が増えた。	企業名, 地域名

表 3 に記した不足情報を補うことがより経済・金融事象を表す因果ネットワークの構築に役立つと考えられる. 新聞記事の見出しや因果表現の周辺テキストから因果表現が含まれる分野・領域の情報をメタ情報として抽出することが今後の課題の１つであると考えられる.

もう 1 つの問題点として, 因果関係・類似関係以外の関係にある因果ノードの関係を区別できていないという問題点がある. 提案手法では因果関係と類似関係を用いて因果ネットワークを構築した. しかし, 経済・金融事象を背景知識まで理解するための適切なつながりである因果ネットワークにおいてはノード間の関係に包含・例示・時系列推移などの類似以外の事象間関係もある. 類似関係ではないノード間の関係の事例を表 4 に記す. 包含・例示・時系列推移などの関係を全て区別して因果ネットワークを構築する手法を開発することは経済・金融事象の理解に向けて背景にある事象まで理解できるように可視化するという目的を果たすために有用であると考えられる.

例示や包含の関係については, 上位下位概念の辞書を用いることによって例示・包含関係を求めることができるが辞書は単語数に限りがあるため, 辞書のエントリにない単語を含む場合にはノード間の関係を特定できないという問題点がある.

時系列推移の関係については, Cheng ら [Cheng 2017] の研究を参考に教師あり学習を用いることで因果関係ノード間が時間推移の関係あるかを判定する手法が考えられる.

表 4: 因果関係ノード間の関係の例

ノード間の関係	ノード A の結果表現	ノード B の原因表現
例示	ドイツの株価指数ＤＡＸは年初から１割以上の大幅な下落となっている。	年初からの資源価格の急落や資本・金融市場の混乱の影響
包含	中国経済の減速を背景にアジア全域で鋼材価格が下落。	米国のゼロ金利政策解除による金融市場の変動、中国経済の減速、原油価格の下落などの影響
時系列推移	英国の欧州連合（ＥＵ）離脱問題で金融不安が高まっている。	英国の欧州連合（ＥＵ）離脱決定

参考文献

[Khoo 2000] C. S. Kho o, S. Chan, and Y. Niu, Extracting causal knowledge from a medical database using graphical patterns.” in Proceedings of the 38th Annual Meeting on Association for Computational Linguistics, pp. 336343, Asso ciation for Computational Linguistics, 2000

[乾 2004] 乾孝司, 乾健太郎, 松本裕治, et al.,“接続標識「ため」に基づく文書集合からの因果関係知識の自動獲得,”情報処理 学会論文誌, vol. 45, no. 3, pp. 919933, 2004.

[坂地 2015] 坂地泰紀, 酒井浩之, and 増山繁,“決算短信 pdf からの原因・結果表現の抽出,”電子情報通信学会論文誌 D, vol. 98, no. 5, pp. 811822, 2015.

[Ishii 2012] H. Ishii, Q. Ma, and M. Yoshikawa,“Incremental construction of causal network from news articles,” Journal of information processing, vol. 20, no. 1, pp. 207215, 2012.

[津川 2015] 津川敦朗, 新妻弘崇, and 太田学,“交絡事象の発見による 因果関係ネットワークの改良.”DEIM Forum, E2-3, 2015.

[津川 2016] 津川敦朗, 新妻弘崇, and 太田学,“共起関係に着目した因 果関係ネットワークの拡張.”DEIM Forum, F3-2, 2016.

[Bojanowski 2016] P. Bojanowski, E. Grave, A. Joulin, and T. Mikolov,“Enriching word vectors with subword information,”arXiv preprint arXiv:1607.04606, 2016.

[Cheng 2017] F. Cheng and Y. Miyao,“Classifying temporal relations by bidirectional lstm over dependency paths.”in Proceedings of the 55th Annual Meeting of the Associ- ation for Computational Linguistics (Volume 2: Short Papers), vol. 2, pp. 16, 2017.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

コミュニティ活動におけるリーダー間の関係が活動の活性化に与える影響

Analysis of the relation between leaders and revitalization of community activities

浜島康佑 Kosuke Hamajima　武藤敦子 Atsuko Mutoh　森山甲一 Koichi Moriyama　犬塚信博 Nobuhiro Inuzuka

名古屋工業大学 大学院工学研究科情報工学専攻
Dept. of Computer Science and Engineering, Graduate School of Engineering, Nagoya Institute of Technology

Revitalization of community activities plays an important role in solving regional and national problems. In communities such as neighborhood associations, community activities sometimes carry out to enrich lives of members and improve their environment. Participation in community activities is supported by members having rights and responsibilities. However, there are few people who actually participate. That's because nonparticipants can obtain the same benefit with participants. Therefore, nomination of leaders who always participates in the activities and encourages the norm consciousness of the surrounding people is important to revitalize activities.

In this research, we analyze the relationship between leaders who revitalize activities using an agent-based model.

1. はじめに

自治会・町内会のような**コミュニティ**では、生活を豊かにしたり環境を改善するためにコミュニティ活動を行うことがある [清水 69]。コミュニティ活動の重要性は多くの人が認識しているにもかかわらず、実際に活動に参加する人は少ない。これは、コミュニティ活動に参加せずとも参加者と同等の公益を得ることができる上、コミュニティ活動に参加するには労力や時間が必要なため個人単位では参加行動が起きにくいためである。このことから、コミュニティ活動は自発的な形成や拡大が容易ではないといえる。

今村らは、個人のコミュニティ活動への参加は自身の周囲の人間の参加行動が関係していると指摘した [今村 10]。この指摘から、コミュニティ活動の活性化を考えるうえで、コミュニティの中での人間関係を分析することは必要であると考えられる。

また、コミュニティ活動の中には一定以上の活動結果を見込むために、活動に必ず参加し地域住民を先導するリーダーを指名する場合がある。このリーダーが中心となってコミュニティ活動の活性化を促すため、適切なリーダーを指名することは重要である。このことと今村らの指摘を踏まえると、適切なリーダーを指名するにはそのリーダーが持つ人間関係を考慮する必要があるといえる。

本研究ではコミュニティ活動のシミュレーションを行い、コミュニティ活動を活性化させるリーダーの持つ人間関係について調査を行う。調査の結果より、複数人のリーダー間の関係がコミュニティ活動の活性化にどのように影響しているかを考察する。

2. 従来研究

今村らは実際のコミュニティ活動（長野県の保健補導員活動など）を調査し、個人がコミュニティ活動に参加する動機は周囲の目を気にすることから生起する、と指摘した [今村 10]。長野県の保健補導員活動では保健補導員の役は持ち回り制であり、役が回ってきた人は初めは活動に積極的ではなかったが、規範的影響を受け、それまで他の人がやってきたからという消極的な理由で参加した。そして活動を通じて活動へのやりがいを感じるようになり、積極的に参加するようになった。

山田らは今村らの指摘した周囲への意識（**規範意識**）と活動に参加して感じたやりがい (**自己効力感**）から個人がコミュニティ活動への参加・不参加を決める数理的なエージェント・ベース・モデルを提案した [山田 15]。このモデルでは、参加した個人がその隣人に影響を与え、その隣人がさらに隣人に影響を与えるという参加行動の伝播を表している。

甲村らは山田らの提案したエージェント・ベース・モデルにネットワーク構造を導入し、より複雑な友人関係を表現できるようにモデルを拡張した [甲村 16]。そして数理的なネットワーク生成モデルを用い、そのパラメータを変更する実験から、ネットワーク全体の指標とコミュニティ活動の活性度の関係を調べた。またネットワーク中心性の高い上位 3 人をリーダーとしたときの実験を行い、コミュニティのネットワーク構造と、参加人数が最も多くなるネットワーク中心性の種類について考察した。

賀川らは甲村らの提案したモデルを利用してシミュレーションを行い、個人のリーダーとしての影響力を調査した [賀川 17]。この調査では活動活性化貢献度という指標を設け、個人が持つリーダーとしての影響力を示した。また、その指標がネットワーク中心性の観点からどのように表されるかを調べ、活動を活性化させるリーダーのして必要な要素を提示した。

従来の研究では、コミュニティ内の人間関係と個人の持つリーダーとしての影響力に注目していたが、現実のコミュニティ活動ではリーダーを複数人設ける場合がある。これまでの研究では複数人のリーダーの相互の関係と、リーダー達がコミュニティ活動に与える影響力の関係については考察がされていなかった。そこで本研究ではリーダーを選ぶ組み合わせに注目し、リーダーの相互の関係がコミュニティ活動の活性化にどのように影響を与えるかについて調査を行う。

3. コミュニティ活動形成モデル

本研究ではコミュニティ活動のシミュレーションのために甲村らのコミュニティ活動モデル [甲村 16] を使用する。このモデルはエージェント・ベース・モデルであり、コミュニティ内

連絡先: 連絡先: 浜島康佑，名古屋工業大学，愛知県名古屋市昭和区御器所町，k.hamajima.701@nitech.jp

の各メンバーはエージェントとして表される。各エージェントは**態度 (A)**、**自己効力感 (E)**、**規範意識 (N)** の 3 つの動機変数を持つ。この変数はコミュニティ活動が行われるごとに更新し、その値によって活動への参加・不参加を決定する。

態度は活動に対してどの程度積極的であるかを示しており、コミュニティ活動で自分が得られた利益に基づいて更新される。自己効力感は自分が参加した活動が成功したかどうかによって更新される、自信の程度を表す。規範意識は自分の周囲の人から受ける影響のことであり、周囲の人の参加率により更新される。

コミュニティ活動の結果は、活動の参加割合によって決まる費用 (C) と公益 (B) の和で表される。費用とは活動に参加するために必要な時間や労力のことであり、参加割合によって一人当たりの費用が増減する。一方公益は、コミュニティ活動によってコミュニティ全体にもたらされる利益のことである。この利益は活動への参加・不参加に関係なく得られる。コミュニティ活動にある程度の参加があった時に初めて活動が成功し、活動が成功すると公益が発生する。活動の参加割合と費用・公益・経験の関係を表 1 に示す。

表 1: 活動への参加割合と費用・公益・経験の関係

参加割合 X	参加者 C	参加者 B	参加者 経験	不参加者 C	不参加者 B
$0 \leq X < 1/9$	-9	0	$failure$	0	0
$1/9 \leq X < 2/9$	-8	0	$failure$	0	0
$2/9 \leq X < 3/9$	-7	0	$failure$	0	0
$3/9 \leq X < 4/9$	-6	4	$success$	0	4
$4/9 \leq X < 5/9$	-5	4	$success$	0	4
$5/9 \leq X < 6/9$	-4	4	$success$	0	4
$6/9 \leq X < 7/9$	-3	4	$success$	0	4
$7/9 \leq X < 8/9$	-2	4	$success$	0	4
$8/9 \leq X \leq 1$	-1	4	$success$	0	4

不参加者は費用が常に 0 なので、費用と公益の和（C+B）が参加者よりも常に大きい。このことから、不参加者は自分が参加しなくても公益が得られた場合、活動への参加が消極的になる。また、公益が得られる境界と (C+B) が正になる境界は異なる。

以下に 3 つの動機変数の更新式を示す。エージェント i のステップ t における態度を A_i^t、自己効力感を E_i^t、規範意識を N_i^t、エージェント i がステップ t の活動から得た費用と公益の和を $(C+B)_i^t$ と表す。A_i^t と E_i^t から内的動機 IM_i^t が形成される。また IM_i^t と N_i^t から参加・不参加行動を決定するための行動意図 I_i^t が形成される。参加者は A_i^t を $(C+B) \geq 0$ の場合肯定的に、$(C+B) < 0$ の場合否定的に更新する。

参加者の態度 A_i^t の更新式を式 (1) に示す。一方不参加者は A_i^t を常に否定的に更新する。不参加者の態度 A_i^t の更新式を式 (2) に示す。パラメータ δ は A_i^t の変化のしやすさを表す。

$$A_i^{t+1} = \begin{cases} A_i^t + \delta \times (C+B)_i^t \times (1 - A_i^t), & \text{if}((C+B)_i^t \geq 0) \\ A_i^t + \delta \times (C+B)_i^t \times A_i^t, & \text{otherwise} \end{cases} \quad (1)$$

$$A_i^{t+1} = A_i^t - \delta \times (C+B)_i^t \times A_i^t \quad (2)$$

参加者は自己効力感 E_i^t をステップ t の活動が成功した場合に肯定的に、失敗した場合に否定的に更新する。不参加者は E_i^t を更新しない。

参加者の自己効力感 E_i^t の更新式を式 (3) に示す。パラメータ λ は E_i^t の変化の敏感さを表す。

$$E_i^{t+1} = \begin{cases} E_i^t + \lambda \times \{1 - (E_i^t)^2\}, & (task^t = success) \\ E_i^t - \lambda \times \{1 - (E_i^t)^2\}, & (task^t = failure) \end{cases} \quad (3)$$

参加者・不参加者ともに、規範意識 N_i^t を自分と繋がっている人（＝友人）の数 ($Friend_i$) とその内コミュニティ活動に参加した友人の数 ($PartFriend_i^t$) によって更新する。友人の定義は、山田らのモデルでは格子状の友人関係ネットワークにおけるムーア近傍 (8 近傍) としていたが、甲村らのモデルではノードとエッジであらわされた友人関係ネットワークにおけるノードの有無としている。

規範意識の更新式を式 (4) に示す。パラメータ ϵ は周囲の行動への流されやすさを表す。

$$N_i^{t+1} = \epsilon \times \frac{PartFriend_i^t}{Friend_i} + (1 - \epsilon) \times N_i^t \quad (4)$$

以下に、各動機変数が全体・友人の参加割合によってどう更新するかをまとめる (表 2)。表中の UP は動機変数をより大きい値に更新すること、DOWN はより小さい値に更新すること、– は更新を行わないことを表す。

表 2: 態度、自己効力感、規範意識の変化

		全体の参加割合 Y^t			友人の参加割合 Z^t	
		$Y^t < \frac{1}{3}$	$\frac{1}{3} \leq Y^t < \frac{2}{3}$	$\frac{2}{3} \leqq Y^t$	$Z^{t-1} > Z^t$	$Z^{t-1} < Z^t$
参加者	A	DOWN	DOWN	UP		
	E	DOWN	UP	UP		
	N				DOWN	UP
不参加者	A	–	DOWN	DOWN		
	E	–	–	–		
	N				DOWN	UP

リーダー以外の各エージェントは動機変数の値から行動意図を形成し、その値から次の活動への参加・不参加を決定する。リーダーに選ばれたエージェントは動機変数に関わらず強制的に活動に参加する。全てのエージェントが参加・不参加を決定した後に活動が実施され、その活動の結果によって動機変数を更新する。この一連のサイクルを **1 ステップ**と呼ぶ。このステップを繰り返し、参加行動を伝播させていく。

4. 活動の活性化とリーダー間の関係調査

リーダー間の関係がコミュニティ活動の活性化にどのように関わっているかを調査するために、リーダーが複数いるコミュニティ活動のシミュレーションを行い、その結果からリーダー間の関係と活動の活性化の相関を調べる。

この実験では友人関係推定手法 [下村 08] で得た、名古屋工業大学のあるクラスの 12 月時点の友人関係ネットワークを使用する。このネットワークは人をノード、友人関係をエッジとした有向グラフである。実際にはこのネットワークは地域コミュニティではないが、隣人との人間関係が形成されやすい地域コミュニティと、学籍番号が近い者同士で人間関係が形成されやすい大学のクラスのコミュニティは似ていると考えて、これを地域コミュニティとして扱う。このネットワークから全ての組み合わせでリーダーを **2 人選出する**。リーダーに選ばれた人は自分の行動意図に関わらず、すべてのコミュニティ活動に参加する。これにより周囲の人の規範意識を促し、参加行動を伝播させることが期待できる。

以降の実験ではシミュレーションの各初期値を $\delta = 0.01, \lambda = 0.05, \epsilon = 0.5, \sigma = 2, \beta = 30, A^{t=1} = 0.5, E^{t=1} = 0, N^{t=1} = 0.5$ として実験を行った。コミュニティ活動のシミュレーションのステップ数を 500 とし、ステップ 500 までを 1 試行と呼ぶ。この試行を 2000 回繰り返し、最終ステップでの参加割合の平均を算出した。

この結果を元に、リーダー間の関係が参加割合にどのような影響を与えているかを調査する。

4.1 調査 1：リーダー間の距離に注目した調査

調査 1 では、2 人のリーダー間の距離に注目した調査を行った。リーダー間の距離が離れているとコミュニティ全体で活動が活性化すると予想して、リーダー間の距離と活動への最終ステップでの参加割合の平均の関係を調べた。この調査では、リーダー間の距離を友人関係のエッジを無向辺として求め、エッジがつながっていないノード間の距離は、コミュニティ内のノード間の最大距離に 1 を加えたものとした。

横軸をリーダー間の距離、縦軸を最終ステップでの参加割合の平均とした散布図を図 1 に示す。

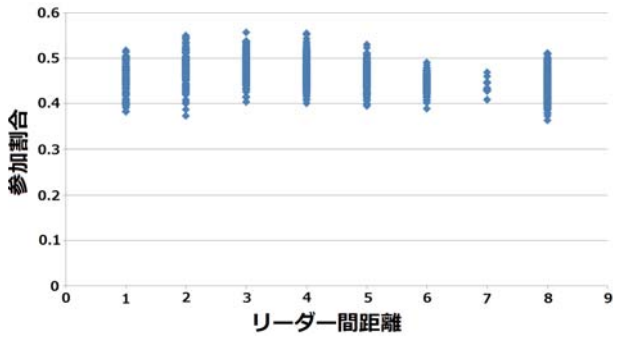


図 1: 参加割合とリーダー間距離の散布図

本結果から、リーダー間の距離と活動への参加割合はほとんど相関がないことが分かる。リーダー間の距離が大きくなると参加割合が低くなる様子が一部見られるが、これはこの際のリーダーがコミュニティの端に位置しているためであると考えられる。

4.2 調査 2：リーダーの属するグループに注目した調査

次に、リーダー間の関係をリーダーの属するグループに注目して調べるため、コミュニティをグループに分割した分析を行う。この調査では固有ベクトルに基づくアルゴリズム [Newman 06] により友人関係ネットワークをグループ分けした。その結果、図 2 のように 9 つのグループに分割された。図中のノードの色は各ノードの属するグループを示す。

シミュレーションにより、参加割合の平均が高かった 2 人のリーダーの組み合わせと属するグループについて観察を行うと、コミュニティ活動への参加割合を高めるリーダーを選ぶには、コミュニティ内の異なるグループから選ぶことと、グループ内の人数が多いことが関係していると示唆された。そこで、異なるグループからリーダーを選んだ時のコミュニティ活動への全体の参加割合と、2 人のリーダーが属するグループ内の人数の合計の関係について調べた。

図 3 に、横軸をリーダーの属するグループ内の人数の合計、縦軸を最終ステップでの参加割合の平均とした散布図を示す。

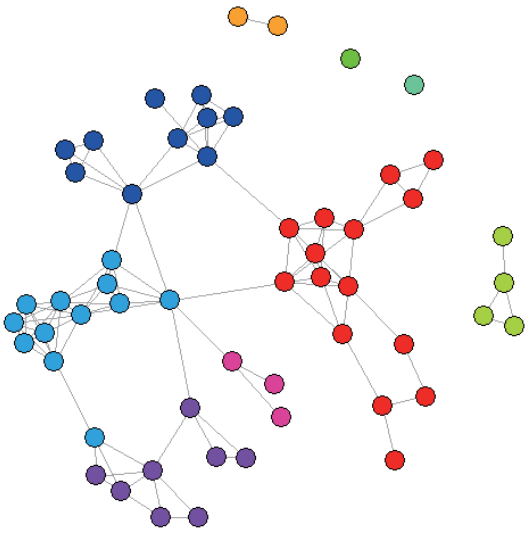


図 2: 名古屋工業大学のあるクラスをグループ分けしたネットワーク図

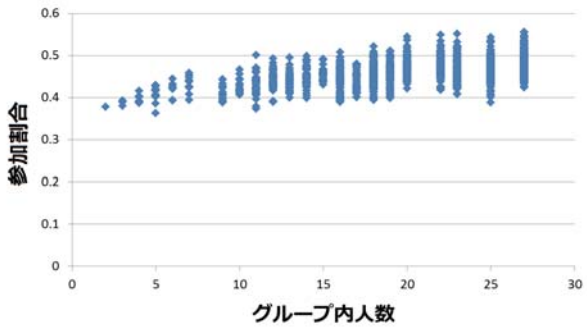


図 3: 参加割合とグループ内人数の合計の散布図

図より、グループ内人数が多い程平均して参加割合が高くなり、グループ内人数が少ないと参加割合が低くなる傾向がわかる。実際に、リーダーの所属するグループ内の人数とコミュニティ活動への参加割合の相関検定をした結果、有意水準 5%で有意な正の相関 (相関係数：0.55) を確認した。

5. 回帰分析

コミュニティ活動を活性化させるリーダーの新しい指標として「コミュニティをグループ分割したときの、リーダーが所属するグループ内の人数」という指標が得られた。その指標と**ネットワーク中心性**の指標を元に、あるリーダーとそのリーダーを選んだときの活動の活性化について回帰分析を行う。ネットワーク中心性とは、社会ネットワーク分析の分野で用いられる、ノードがネットワークにおいてどの程度中心的な存在であるかを表す指標である。本研究では、ネットワーク中心性の指標として、**近接中心性**、**次数中心性**、**媒介中心性**の 3 つの指標を扱う。

目的変数をコミュニティ活動への参加割合、説明変数をリーダーの属するグループの合計人数と 3 つのネットワーク中心性として回帰分析を行った。結果を表 2、表 3 に示す。

表 2: 4 変数による回帰分析 (1)

重決定 R^2	0.8191
補正 R^2	0.8185
標準誤差	0.0136
観測数	1286

表 3: 4 変数による回帰分析 (2)

	係数	標準誤差	p 値
切片	0.3874	0.0033	0
グループ内人数	0.0003	9.314×10^{-5}	0.0021
近接中心性	1.616×10^{-5}	0.0105	0.9987
次数中心性	0.0042	9.778×10^{-5}	7.947×10^{-251}
媒介中心性	1.296×10^{-5}	1.772×10^{-6}	4.601×10^{-13}

表 2 を見ると決定係数が高い数値を示しており、4 つの変数で参加割合がおおむね説明できていることが分かる。一方で表 3 を見ると、近接中心性の p 値が 1 に近い値を示しており、参加割合を説明する変数として有効でないことが分かった。そこで、近接中心性を除いた 3 つの説明変数で再度回帰分析を行った。結果を表 4、表 5 に示す。

表 4: 3 変数による回帰分析 (1)

重決定 R^2	0.8198
補正 R^2	0.8194
標準誤差	0.0135
観測数	1286

表 5: 3 変数による回帰分析 (2)

	係数	標準誤差	p 値
切片	0.3884	0.0011	0
グループ内人数	0.0006	1.426×10^{-4}	3.480×10^{-5}
次数中心性	0.0042	8.964×10^{-5}	2.594×10^{-276}
媒介中心性	1.320×10^{-5}	1.574×10^{-6}	1.302×10^{-16}

表 4、表 5 から、近接中心性の指標を除いた 3 つの変数でも参加割合がおおむね説明できていることが分かる。このことより、ある 2 人のリーダーを選んだ時のコミュニティ活動への全体の参加割合は、2 人のリーダーが所属するグループ内の人数の合計、次数中心性、媒介中心性の 3 つの変数でおおむね説明できるといえる。

ノード i、j をリーダーとしたときの参加割合の回帰式を以下に示す (式 (5))。

$$JoinRate_{ij} = 0.0006 \times Group_{ij} + 0.0042 \times Degree_{ij} + 1.320 \times 10^{-5} \times Betweenness_{ij} + 0.3884 \quad (5)$$

ここで $JoinRate_{ij}$ は、ノード i、j をリーダーとしたときの参加割合、$Group_{ij}$ は属するグループ内の人数、$Degree_{ij}$ は次数中心性の合計値、$Betweenness_{ij}$ は媒介中心性の合計値をそれぞれ示す。

以上より、リーダー i、j がコミュニティ活動の活性化に与える影響は、リーダー間の関係を考慮して上の式で表される。

6. おわりに

本論文では、個人が周囲の影響を受けて活動への参加・不参加を決定する山田ら、甲村らのコミュニティ活動モデルを用いて、参加行動が伝播するシミュレーションを行った。そのシミュレーションの結果から、コミュニティ活動を活性化させるリーダーはどのような特徴があるのかについて、リーダー間の関係に注目した観察をした。

調査 1 ではリーダー間の距離とコミュニティ活動への参加割合についての関係を調べた。調査の結果、リーダー間の距離を離しても活動への参加割合は上がらず、かえって参加割合が下がる傾向が見られた。これはリーダー間の距離を離そうとすると、コミュニティの中で中心的でない人物が選ばれてしまうためだと考えられた。

調査 2 ではコミュニティをグループ分けした調査を行った。参加割合の高くなったときのリーダーとそのリーダーの属するグループの関係を調べると、リーダーは異なるグループに属しており、そのグループの人数が多いほど参加割合を高めている様子が確認できた。この結果から、リーダーの属するグループ内の人数の合計と参加割合について調べたところ、相関があることが確認された。

調査 2 で得られた変数とネットワーク中心性の指標を用いて回帰分析を行ったところ、リーダーの所属するグループ内の人数の合計と次数中心性、媒介中心性の 3 つの変数を用いて、参加割合をおおむね説明できた。この 3 つの変数から参加割合の推定式を導出し、2 人のリーダーを選ぶ場合のリーダーの組み合わせと、その時の参加割合の関係を明らかにした。

今後の課題として、コミュニティの人数によってリーダーの人数を変えることなどが考えられる。

参考文献

[清水 69] 国民生活審議会調査部会コミュニティ問題小委員会：コミュニティ-生活の場における人間性の回復，大蔵省印刷局，1969.

[今村 10] 今村晴彦，園田紫乃，金子郁容：コミュニティのちから“遠慮がちな”ソーシャル・キャピタルの発見，慶應義塾大学出版会，2010.

[山田 15] 山田広明，橋本敬：規範意識と自己効力感に駆動されたコミュニティ活動形成と拡大，人工知能学会論文誌，Vol.30，No.2，pp.491-497，2015.

[甲村 16] 甲村啓伍，武藤敦子，松井藤五郎，森山甲一，犬塚信博：ネットワーク構造を導入したコミュニティ活動モデル，情処学論，数理モデル化と応用，Vol.9，No.3，pp.15-23，2016.

[賀川 17] 賀川祐耶，武藤敦子，松井藤五郎，森山甲一，犬塚信博：他者の関係に基づくコミュニティ活動リーダー決定モデル，情報処理学会研究報告，2017.

[下村 08] 下村幸作，中野智文，犬塚信博，松尾啓志：学生の出欠時間を活用した学生の友人関係分析，第 6 回人工知能学会データマイニングと統計数理研究，SIG-DMSM-A703，pp.20-26，2008.

[Newman 06] M. E. J. Newman：Finding community structure in networks using the eigenvectors of matrices，Phys. Rev. E 74，036104-Published 11 September 2006.

[1P2] [General Session] 3. Data Mining

座長:原 聡（大阪大学）

Tue. Jun 5, 2018 3:20 PM - 5:00 PM Room P (4F Emerald Lobby)

[1P2-01] Design and evaluation of visual analytics interface for time series data based on direct manipulation of trajectory

○Rei Takami[1], Yasufumi Takama[1] （1. Tokyo Metropolitan University）

3:20 PM - 3:40 PM

[1P2-02] Anomaly Detection on Sound Data Using Dynamic Mode Decomposition

○Kota Dohi[1], Naoya Takeishi[1], Takehisa Yairi[1], Koichi Hori[1] （1. Department of Aeronautics and Astronautics, The University of Tokyo）

3:40 PM - 4:00 PM

[1P2-03] Analysis of Television Viewing Pattern Transitions with Clustering Large-Scale Log Data

○Yoshiaki Mizuoka[1], Kouta Nakata[1], Ryohei Orihara[1] （1. Analytics AI Laboratory, Corporate Research and Development Center, Research &Development Division, Toshiba Corporation）

4:00 PM - 4:20 PM

[1P2-04] Verification of Factors Forming Quality Brand Image in Customers' Perception

○Takumi Kato[1], Kazuhiko Tsuda[2] （1. Honda Motor Co.,Ltd., 2. University of Tsukuba）

4:20 PM - 4:40 PM

[1P2-05] Detection of Social Bots: Quantification of Language Independent Features and Bot Clusters

○Masaki Sugimori[1], Kazutoshi Sasahara[1,2], Kei Tokita[1] （1. Graduate School of Informatics, Nagoya University, 2. JST, PRESTO）

4:40 PM - 5:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

軌跡の直接操作に基づく時系列データの視覚的分析支援インタフェースの設計と評価

Design and Evaluation of Visual Analytics Interface for Time Series Data based on Direct Manipulation of Trajectory

高見 玲　　高間 康史
Rei Takami　　Yasufumi Takama

首都大学東京大学院 システムデザイン研究科
Graduate School of System Design, Tokyo Metropolitan University

In recent years, time series data have been collected in many fields, and visual analytics interface is expected to be useful for utilizing such data. However, several issues arising when applying it to time series data should be considered. For example, when time series data is visualized using animation, collision would occur between movement of time series data itself and movement caused by interaction with users. In order to solve those issues, this paper proposes a visual analytics interface for time series data based on trajectory manipulation, which can handle temporal and spatial changes uniformly. The results of user experiment show the effectiveness of the proposed interface.

1. はじめに

近年, 様々な分野において大規模かつ高次元的特徴を持つデータが蓄積されている. 中でも, 時系列データは, センサログデータや SNS ストリームなど, 様々な分野で普及している. これらのデータから有用な知識を発見するため, 視覚的分析インタフェースが研究されている [Keim 08]. 本稿では, 可視化されたオブジェクト自体を操作し, 操作結果に基づき背後に存在するモデルやパラメータを操作し, ユーザにフィードバックする直接操作に基づくアプローチに着目する. 時系列データに対して直接操作的アプローチを適用する場合の問題点として, (1) データ自身の変化とユーザ操作による変化の時間軸上での衝突や, (2) 時間軸と空間軸の間におけるインタラクションの衝突, (3) 異なる可視化手法間のトレードオフの存在が想定される. これらの問題点を解決するために, 本稿では. データの時間的変化を空間上に表現し, 時間および空間軸を統一して扱うことで, (1) を回避できる軌跡表現に着目する. そして, アニメーションで時系列を表現する散布図上にて軌跡を直接操作することで, データの時空間的変化の特徴把握を促進し, 知識形成を支援する視覚的分析インタフェースを提案する. 提案インタフェースではアニメーションの再生/静止モードに基づく適用操作の分岐を採用する. これにより, (2) に対応し, 両モードの利点を生かすことで (3) にも対応する. さらに, 軌跡表現に対する選択操作といった基本的なインタラクションに加えて, 複数オブジェクト/軌跡のグルーピング機能も採用することで, 視覚的分析プロセス全体の支援を行う. プロトタイプインタフェースを実装し, ユーザ実験を行った結果より, 上述の問題点の解消や, 提案インタフェースの視覚的分析における有効性を示す.

2. 関連研究

2.1 視覚的分析

一般的に, ドメイン専門家 (分析者) は必ずしもデータマイニングの専門家ではない. そのため, 可視化の背後に存在するモデルやパラメータの理解が困難であることが指摘されている [Sacha 17]. この問題に対処するため, ドメイン知識によるデータの解釈と, 可視化を介した洞察の獲得支援を目的とする視覚的分析が研究されてきた [Keim 08].

視覚的分析において, 可視化オブジェクトの直接操作とフィードバックにより, データに対する理解を促進し, 知識形成を支援する手法が研究されている [Endert 13]. 代表的なアプローチとして, 直接操作に基づき, 可視化の背後に存在する次元削減などのモデルやパラメータを推定・修正することで知識形成を促進する semantic interaction のコンセプトが提案されている [Endert 12]. このコンセプトでは, システムが可視化オブジェクトへの操作内容を解釈し, 結果に基づき背後に存在するデータマイニングアルゴリズムのモデルやパラメータを調整する. 調整結果は可視化表現に反映され, 分析者に即時フィードバックされる. これによって, 分析者が可視化の背後に存在するモデルやパラメータに関する知識を有しない場合でも, それらを調整可能となる. また, ドメイン知識を調整結果に適用することで, 探索と知識形成の間の直感的な移行が可能となる. そのため, コンピュータの計算処理能力と, 可視化されたデータに対する人間の認知能力や知識の双方を活用した探索が行える [Sacha 17].

2.2 時系列データの可視化手法

時系列データを視覚的分析する場合, データの時間的特徴や, 分析対象のデータ特性, データの表現手法などの様々な考慮すべき特性が存在し, 多くの可視化手法が研究されている [Aigner 07]. 代表的な手法として, 動きで時間的変化を表現するアニメーションのような動的可視化や, 複数のグラフの併置で表現する small multiples, データの変化を空間上に重畳するトレース (軌跡) のような静的可視化が存在する [Robertson 08].

本稿で着目する軌跡表現は, 空間的座標の変化を同一ビュー上に表示する可視化手法である. 視覚的分析における軌跡表現の利用例として, Kondo と Collins は軌跡の操作に基づく時間的ナビゲーション手法 DimpVis を提案している [Kondo 14]. DimpVis ではデータの変化軌跡をなぞる操作に基づき, 時系列データの散布図表現内の時間的遷移を行える. Bach らは, 時系列データの視覚的概要の提示手段として軌跡に着目し, データの各時点での自己類似性に基づく軌跡の描画手法を提案している [Bach 16]. Rind らは, 医療における患者の経過観測や治療の選択のためのインタフェースにおいて, 散布図上のオブジェク

連絡先: 高間康史, 首都大学東京大学院システムデザイン研究科, 〒 191-0065 東京都日野市旭が丘 6-6, ytakama@tmu.ac.jp

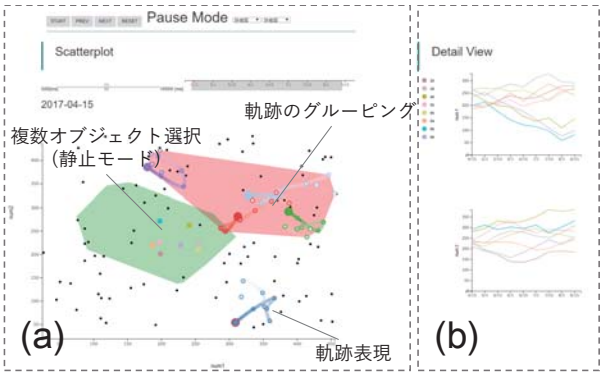


図 1: 提案インタフェース: (a) 散布図ビュー (b) 詳細ビュー

トの時間的変化を軌跡で表現している [Rind 11]. これらの既存手法では, 時間的ナビゲーションや時系列データの特性を表現するために軌跡が活用されている. しかし, 視覚的分析の包括的なプロセスへの統合に関しては議論されていない.

3. 時系列データの視覚的分析における問題点

時系列データに対して直接操作に基づく視覚的分析を適用する場合に, 以下のような問題点が想定される.

3.1 時間軸上におけるインタラクションの衝突

時系列データの可視化手法の一つであるアニメーションは, 時間的変化を実時間上の変化として表現する. そのため, 直接操作に基づく視覚的分析にアニメーションを用いた場合, 再生操作に伴いオブジェクト配置の変化が生じる. また, オブジェクトに対してユーザがドラッグ操作などの直接操作を適用した場合にも, オブジェクト配置の変化が起こる. このとき, 2 つの配置の変化はどちらも時間的なものとなる. 本稿では, この状況を時間軸上の衝突とみなし, 時系列データの視覚的分析における主要な問題点の一つとして捉える.

3.2 時間軸と空間軸の間でのインタラクションの衝突

時系列データの分析に際して必要な操作として, アニメーションの制御といった時間軸への操作が挙げられる. 加えて, 視覚的分析における, 可視化が配置されたインタフェースの画面 (空間座標) を空間軸と定義すると, 直接操作によるオブジェクトの配置変更などの操作は空間軸に対するインタラクションとみなせる. 結果として, 同一操作の適用先として 2 つの軸が同時に存在しうる. そのため, ユーザの直接操作の解釈において, 対象となる軸に関して衝突が生じると考える. 例えば, 時系列データに対して詳細を確認するために拡大 (ズームアップ) 操作を行った場合, 空間的に拡大表示したいのか, 再生速度を遅くしたいのか, 二通りの解釈がありうる. このように, 採用された解釈がユーザの意図したものと異なる場合には分析の妨げとなるため, 時系列データの視覚的分析における考慮すべき問題点の一つと考える.

3.3 可視化手法間のトレードオフ

アニメーションなどの動的な可視化手法は, 時系列データが有する意味のある変化の発見や, 聴衆に理解させるプレゼンテーションのような場面では有効である. 一方で, 変化の見落としの発生や, スライダなどによるアニメーションの制御に伴う操作回数の増加などの要因により, 詳細なデータ分析には適していない [Robertson 08]. 一方で, トレースや small multiple などの静的な可視化手法は効率と正確性の面で詳細な探索に適

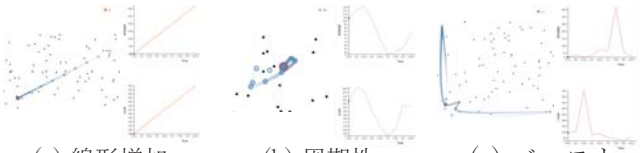


図 2: 属性値の時系列的変化特性と軌跡の形状の関係

しているが, スケーラビリティや視覚的混乱について問題がある [Robertson 08]. このように, 時系列データに対して一意に有効な可視化手法は存在しない. そのため, 分析目的や対象に応じて複数の手法を組み合わせる必要がある.

4. 提案インタフェース

3 節で述べた問題点に基づき, 本稿では, 軌跡表現と 2 次元散布図を組み合わせた時系列データの視覚的分析支援インタフェースを提案する. インタフェースは, Ruby on Rails 5 を用いて Web アプリケーションとして実装した. 可視化部とフロントエンド処理の実装には D3.js および jQuery を用いた.

図 1 に提案インタフェースのスクリーンショットを示す. 提案インタフェースは散布図ビュー (図 1(a)) と詳細ビュー (図 1(b)) から構成される. 散布図ビューでは, 選択されたオブジェクトに対応するデータから 2 属性を選択し, X, Y 軸に対応付ける. そして, 各時点での属性値を散布図上に可視化し, アニメーションによる位置の変更でデータ分布の時間的変化を表現する. ユーザは関心を持った散布図上のオブジェクトを選択し, 軌跡の表示や直接操作を行える. 詳細ビューでは, 散布図上で選択されたオブジェクトの各属性値の時間的変化を示す線グラフや, メタデータなどの詳細情報を表示する.

ユーザは散布図ビューで得た視覚的傾向に対して, 詳細ビューを用いて詳細な探索や仮説検証を行う. 両ビュー間の移行の繰り返しにより, 視覚的分析が行われることを想定する. 一方のビューへの操作は他方へも適用され, インタフェースの一貫性を保持する. 提案インタフェースの特徴的な機能として, 軌跡による可視化や, 探索モード, オブジェクトのグルーピングがある. 以降に, それぞれの機能の説明を示す.

4.1 軌跡による可視化

散布図上でオブジェクトにマウスオーバーすると, 属性値の時間的変化が軌跡として可視化される. 軌跡は各時点でのオブジェクトの空間座標を表すノードと, 各ノードを結ぶ曲線であるパスから構成される. 2.2 節で述べたように, 軌跡表現はデータの視覚的概要として用いられる. 例として, 属性値が線形増加した場合には, 図 2(a) のような直線状の軌跡が描かれる. 周期的に変化した場合には, 図 2(b) のように, 丸まった形状の軌跡が描かれる. 属性値が特定の期間内でバーストする場合には, 図 2(c) のように, 広域に渡り急峻な変化をする軌跡が描かれる. 軌跡は属性値の変化を空間上に重畳して表現するため, 対象の時系列的特性を空間上のみで判断できる. そのため, ユーザ操作に応じて軌跡を表示・操作することで, 視覚的混乱を抑制しつつ, 3.1 節で述べた時間軸上でのインタラクションの衝突を回避できると考える. また, 軌跡表現では, オブジェクトの時間的側面 (軌跡) と空間的な側面 (他のオブジェクトとの関係) の両方が同時に散布図上で空間的に表現される. そのため, 3.2 節で述べた時間軸と空間軸間のインタラクションの衝突を回避できると考える.

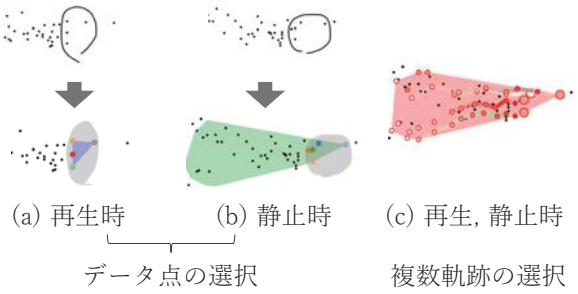


図 3: 提案インタフェースにおけるオブジェクトのグルーピング

4.2 探索モード

3.3 節で述べた可視化手法間のトレードオフへ対処するため, 探索モードとしてアニメーションの再生と静止をインタフェースに導入する. 探索モードに基づき, ユーザ入力の解釈を分離することで, 動的な可視化と静的な可視化手法の両者の利点を活かし, トレードオフの解消を図る. 再生モードではオブジェクト全体の傾向を把握するための利用を想定し, オブジェクトをインタラクティブなアニメーションで可視化する. 分析者は, データ全体の傾向に基づき, 興味を持ったオブジェクトの変化を追跡できる. 静止モードでは, 静的な散布図上で, 軌跡を直接操作したり, 再生モードで得た視覚的傾向を詳細ビューで検証したりしながら詳細な分析を行う. 分析者は再生モードで得た視覚的概要に基づき, 静止モードにて詳細な探索や仮説の検証を行い, 両モード間の遷移により視覚的分析を行うことを想定する.

4.3 オブジェクトのグルーピング

提案インタフェースでは, オブジェクトをグルーピングするためのスケッチベース入力を採用する. 散布図ビュー上でオブジェクト群を囲うような線を描画すると, 図 3(a)(b) のようにそれに含まれる全てのオブジェクトを含む凸包が散布図上に描画される. 凸包は選択されたオブジェクト群の空間的な広がりを表現可能なため, 類似性の判断に対して有効と考える.

4.2 節で述べた探索モードに基づき, 異なる形状の凸包が描画される. 再生モードでは, 特定の時点における全選択オブジェクトを含む凸包が描画される (図 3(a)). これによって, 複数オブジェクトの大局的な時間的変化の概要の把握を行える. 静止モードでは全選択オブジェクトの軌跡を含む凸包が描画される (図 3(b)). また, 複数の軌跡をマウスクリックにより選択した場合には, 探索モードによらず図 3(b) と同様の凸包が描画される (図 3(c)). スケッチベース入力による選択では, 範囲に基づく対象の暗黙的な指定により, 被選択オブジェクト群の時間的な変化傾向の把握が促進されると考える. 一方で, クリックによる選択では, 対象の明示的な指定による複数オブジェクト時間的変化の比較のための利用を想定する.

5. 評価実験

提案インタフェースの有効性を検証するため, 20 歳から 24 歳までの 32 名の工学系大学生および大学院生 (男性 30 名, 女性 2 名) を対象としたユーザ実験を行った. 分析対象のデータには, 日本プロ野球の投手データを使用した. また, 実験で行うタスクへの習熟による影響を考慮するため, セリーグとパリーグの 2 つの異なるデータセットを採用した.

5.1 実験内容

実験開始時に, 協力者はチュートリアルに従ってインタフェースの各機能を試行した. 次に, 特定のオブジェクトを探索し, 詳細ビューへ表示する可視化生成タスクを行い, その後, 特定のオブジェクト群に対する視覚的傾向を発見し, 説明を記述する説明タスクの 2 つのタスクセットを順に行った. 実験協力者は, 提案インタフェースと, 2 つの比較インタフェース (アニメーション, もしくは軌跡表現を提案インタフェースから除去) のうちどちらか一つを用いて, 両タスクを実行した. 実験終了後, 主観的フィードバック取得のため, 提案インタフェースの各機能を 5 段階リッカート尺度で評価するアンケートに回答してもらった. 一部の設問については, その理由を文章で記述してもらった. タスク毎のデータセット, インタフェースの組み合わせ, 提案・比較インタフェースにおけるタスクの実行順序は, 順序効果などを考慮して決定している. また, 定量的な考察のためにインタフェースの各機能の使用回数を記録し, 定性的な考察のために実験中の画面を録画した.

5.2 実験結果

5.2.1 可視化生成タスク

可視化生成タスクにおける実行時間について, t 検定による有意性の検証を行ったところ, 提案・比較インタフェースの間に有意な差は見られなかった. 一方で, 主観的評価では提案インタフェースの習熟コストに対して問題点が指摘されていた. また, 多くのタスクについて, 実行時間の標準偏差は提案インタフェースで最も大きかった. この結果も, 提案インタフェースへの習熟コストが影響したものと考える.

5.2.2 説明タスク

説明タスクでは, 提案インタフェースにおける各機能の操作回数が可視化生成タスクと比較して少ない傾向にあることが確認された. 特に, オブジェクトの選択操作や詳細ビューでの属性値の確認などの視覚的分析の基本的なタスクにおいて, t 検定の結果, 有意差が観測された. 記述された説明内容について, 提案・比較インタフェース間のキーワードの含有数についてカイ二乗検定を用いた有意性の検証を行った. その結果, 全体的なデータ傾向を問う問題については局所的な傾向や根拠を表すキーワードについて有意差が認められた. また, 特定オブジェクト群の傾向を問うタスクでは, 実際の値を表すキーワードについて有意差が確認された. すなわち, 提案インタフェースにおいて, 探索対象の傾向を実際の値を参照し具体的かつ詳細に記述できたことが確認できる. そのため, 提案インタフェースを用いることで, 複数オブジェクトの傾向を把握するタスクにて, 効率的な探索が可能であるといえる.

5.2.3 軌跡表現と探索モードの有効性

表 1 に, 提案インタフェースの各機能に対するアンケート結果を示す. 表内の数値は, インタフェースの各機能 (行) に対する, 5 段階リッカート尺度の各段階 (列) ごとの協力者数を表している. 表 1 より, 軌跡表現に対して高い評価が得られていることが確認できる. 理由として, 軌跡表現は直感的に理解しやすく, 視覚的混乱が少ないことが挙げられていた. また, 提案インタフェース全体について, 多くの実験協力者は, 異なる種類の可視化手法の組み合わせによりトレードオフが解消され, 探索目的ごとにモードを変えながら効率的な探索を行えたと回答した. これは, 5.2.2 節における操作回数の軽減からも確認できる. このように, 軌跡表現による時間的変化の可視化により, 散布図上の興味のあるオブジェクトに対して視覚的混乱を防止しつつ, 時間的変化の把握が可能であるため, 時間軸上におけるインタラクションの衝突の問題に対し有効と考える.

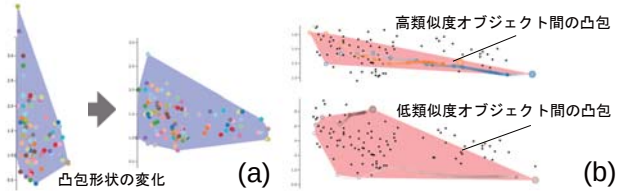


図 4: グルーピング操作における探索モード毎の実験協力者の分析行動例: (a) 再生モード (b) 静止モード

5.2.4 可視化手法毎の利点を生かした探索

ユーザの主観的評価と操作ログの集計結果より, グルーピング操作がタスクごとに異なる用途で用いられる傾向が確認された. 図 4 に, 実験協力者の分析行動の例を示す. 例えば, データ全体の傾向を問うタスクでは, 協力者は再生モードでオブジェクト全体をグルーピングし, アニメーションによる凸包形状の変化に基づき, 全体的な傾向を判断していた (図 4(a)). 一方で, 特定オブジェクト群の傾向を問うタスクでは, 静止モードで該当するオブジェクトの軌跡を複数選択することで, データ間の類似性や関係を判断していた (図 4(b)).

比較対象に対する提案インタフェースの有効性について, アニメーションは表示が簡潔である一方, データの時間的変化を把握しづらいと回答した協力者が複数存在した. 一方で, トレースはデータ全体の時間的変化の把握が容易である一方, データの重なりによって, 選択操作や値の把握が困難な場合があるという意見が確認された. 両者に対する問題点は相補的なものとなっている. そのため, 軌跡表現や, 探索モードによる操作の解釈の分離により, 可視化手法間のトレードオフの問題が解消されると考える. すなわち, 提案インタフェースにより, 動的・静的可視化手法の利点を活かした分析作業が行えるといえる.

6. おわりに

本稿では, 多次元時系列データの分析支援を目的として, 軌跡の直接操作に基づく視覚的分析インタフェースを提案した. プロトタイプインタフェースを実装し, 評価実験を行った. 結果より, 軌跡表現の直感性や, 異なる可視化手法の利点の組み合わせによる視覚的分析全体の支援に関して, 有効性が示された.

一方で, アンケートでは重なりなどについて視覚的混乱が報告された. また, 探索モードに関するインタラクションについてわかりにくいと回答した協力者もみられた. これらの問題点は, 今後の提案インタフェースのユーザビリティの向上により対応できると考える. また, 探索モードに基づく操作解釈のマッピングについて, 実験結果を元に再検討する必要があると考える. インタフェースの機能の改善に加えて, ドメイン専門家による視覚的分析を支援するため, semantic interaction 的アプローチの導入も有効と考える. また, 知識形成プロセス全体における有効性検証のため, ケーススタディによる長期間かつ定性的な評価を行うことも有用と考える.

表 1: 提案インタフェースの各機能に対する主観的評価

評価対象	5 段階評価				
	1	2	3	4	5
視覚的分析における全体的な有効性	0	3	0	23	6
比較インタフェースと比べた有効性	0	1	5	10	16
散布図ビューと詳細ビューの連携	0	0	1	7	24
軌跡による可視化	1	2	2	10	17
軌跡の直接操作	0	5	5	16	6
オブジェクトのグルーピング	1	1	2	10	18
再生モード	2	3	7	13	7
静止モード	0	2	4	7	19
全体的なユーザビリティ	0	3	6	21	2

参考文献

[Aigner 07] Aigner, W., Miksch, S., Müller, W., Schumann, H., and Tominski, C.: Visualizing time-oriented data-a systematic view, *Computers & Graphics*, Vol. 31, No. 3, pp. 401–409 (2007)

[Bach 16] Bach, B., Shi, C., Heulot, N., Madhyastha, T., Grabowski, T., and Dragicevic, P.: Time curves: Folding time to visualize patterns of temporal evolution in data, *IEEE Transactions on Visualization and Computer Graphics*, Vol. 22, No. 1, pp. 559–568 (2016)

[Endert 12] Endert, A., Fiaux, P., and North, C.: Semantic interaction for visual text analytics, in *Proceedings of the SIGCHI conference on Human factors in computing systems*, pp. 473–482 (2012)

[Endert 13] Endert, A., Bradel, L., and North, C.: Beyond control panels: Direct manipulation for visual analytics, *IEEE Computer Graphics and Applications*, Vol. 33, No. 4, pp. 6–13 (2013)

[Keim 08] Keim, D. A., Mansmann, F., Schneidewind, J., Thomas, J., and Ziegler, H.: Visual Analytics: Scope and Challenges, in Simoff, S. J., Böhlen, M. H., and Mazeika, A. eds., *Visual Data Mining: Theory, Techniques and Tools for Visual Analytics*, pp. 76–90, Springer (2008)

[Kondo 14] Kondo, B. and Collins, C.: DimpVis: Exploring time-varying information visualizations by direct manipulation, *IEEE Transactions on Visualization and Computer Graphics*, Vol. 20, No. 12, pp. 2003–2012 (2014)

[Rind 11] Rind, A., Aigner, W., Miksch, S., Wiltner, S., Pohl, M., Drexler, F., Neubauer, B., and Suchy, N.: Visually exploring multivariate trends in patient cohorts using animated scatter plots, in *International Conference on Ergonomics and Health Aspects of Work with Computers*, Vol. 6779 LNCS, pp. 139–148 (2011)

[Robertson 08] Robertson, G., Fernandez, R., Fisher, D., Lee, B., and Stasko, J.: Effectiveness of animation in trend visualization, *IEEE Transactions on Visualization and Computer Graphics*, Vol. 14, No. 6, pp. 1325–1332 (2008)

[Sacha 17] Sacha, D., Sedlmair, M., Zhang, L., Lee, J. A., Peltonen, J., Weiskopf, D., North, S. C., and Keim, D. A.: What you see is what you can change: Human-centered machine learning by interactive visualization, *Neurocomputing*, Vol. 268, pp. 164 – 175 (2017)

動的モード分解を用いた音響データの異常検知

Anomaly Detection on Sound Data Using Dynamic Mode Decomposition

土肥 宏太　武石 直也　矢入 健久　堀 浩一
Kota Dohi　Naoya Takeishi　Takehisa Yairi　Koichi Hori

東京大学 航空宇宙工学専攻
Department of Aeronautics and Astronautics, The University of Tokyo

As the evolution of sensors and computers enables collecting abundant data, methods to analyze high-dimentional data are becoming important. Dyanmic mode decompostion (DMD) is a data-driven method to extract dynamic structure from data and is attracting attention recently. In this study, we made use of DMD to analyze sound data of rotary machines with normal and abnormal states. We applied DMD to spectral distributions of the data and analyzed the dynamic structure of spectral distributions. We found that on spectral distributions of data from abnormal states, time-decaying structure is more likely to be dominant than those from normal states.

1. 背景

近年の計測技術の発達やコンピュータによる計算能力の向上により、大量の観測点を設けて測定データやシミュレーションデータを得ることが可能になった。こうして得られた高次元のデータは現象を精密に再現する一方で、処理の際多くのコストを要するだけでなく、現象の理解を困難にする可能性がある。したがって、高次元データから実現可能なコストで情報を抽出する手法が必要とされるようになった。

高次元データから次元削減により情報を抽出する手法として以前から用いられているものに、主成分分析（Principal Component Analysis, PCA）や固有直交分解（Proper Orthogonal Decomposition, POD）等がある。これらの手法は静的なデータ対して次元削減を行うことができるが、動的な情報抽出には適さない。一方で高速フーリエ変換（Fast Fourier Transform, FFT）は個々の観測点の動的な情報抽出に適しているが、系全体の挙動を把握し次元削減を行うことはできない。

動的モード分解（Dynamic Mode Decomposition, DMD）は POD と FFT の特徴を組み合わせた手法であり、高次元時系列データから動的モードと呼ばれる低次元基底を抽出して次元削減を行うことができる。DMD の最大の特徴は、系の時間発展と各観測点の系に対する寄与を同時に表すことが可能な点である。DMD は Schmid らによって 2008 年に提案されて以降、主に流体分野の解析に適用されてきた[Rowley 09, Schmid 10, Tu 14]。近年では衛星の観測データ解析[Giannakis 15]や感染症の流行解析[Proctor 15]、脳波解析[Brunton 16]など様々な分野において有用性が報告されており、今後多くの分野での適用が期待されている。

本研究では DMD を系の状態データに適用し、異なる状態の識別や状態特性の観測を行うことで、DMD の有用性を評価することを目的とした。

2. Dynamic Mode Decomposition の概要

2.1 アルゴリズムと特長

時刻$k\sim k+1$ $(k \geq 1)$においてシステムの状態データx_kからx_{k+1}への時間遷移を考える。各時刻の状態データを時系列に並べてデータ行列X, X'を生成し、時間遷移行列Aにより系全体の時間遷移を表すことができると仮定する。

$$X = [x_1 \quad x_2 \quad \cdots \quad x_k] \tag{2.1}$$

$$X' = [x_2 \quad x_3 \quad \cdots \quad x_{k+1}] \tag{2.2}$$

$$X' \approx AX \tag{2.3}$$

Xの特異値分解の結果から、Aを POD 基底に投影した$\tilde{A}$の固有値分解の結果を得る。これによりAの固有値分解の結果を得ることができる。Aの固有値行列Λ、固有ベクトル行列をΦとして係数ベクトルをbとすると、x_kは次のように再構成される。

$$A\Phi = \Phi\Lambda \tag{2.4}$$

$$x_k \approx \Phi\Lambda^k b \tag{2.5}$$

$$= \Phi\Psi \tag{2.6}$$

ここでΦの各列ベクトルϕ_iは動的モードと呼ばれ、系全体の各観測点に対する寄与を表す。Λは複素行列であり、各成分の絶対値が系の減衰、角度成分が系の振動に相当する。このようにΦとΨによって、系の時空間構造を捉えることができる点が DMD の特長である。また、固有値行列Λにより系の減衰を捉えることができるため、FFT では捉えることが困難な、減衰振動現象の動的構造を捉えることが可能である。例として、1000Hz、2000Hz、3000Hz の合成波の 3000Hz の項に減衰項を掛け合わせたデータy

$$y = sin(1000 \cdot 2\pi t) + sin(2000 \cdot 2\pi t) + sin(3000 \cdot 2\pi t) \cdot exp(-300t) \tag{2.7}$$

に対して DMD および短時間フーリエ変換（Short Time Fourier Transfer, STFT）を適用した。結果を図 2.1、2.2 に示す。図 2.2 の DMD による結果では、図 2.1 の STFT による結果では捉えられなかった振動数 3000Hz に相当するパワースペクトルを捉えることができている。

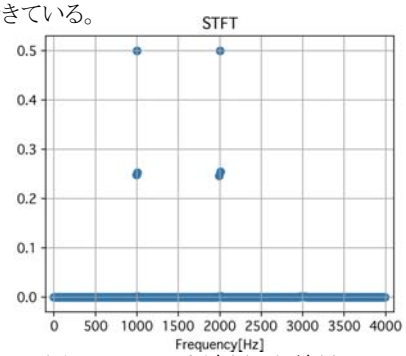


図 2.1 STFT を適用した結果.

連絡先：dohi@g.ecc.u-tokyo.ac.jp

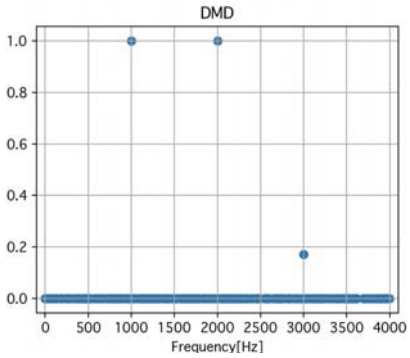


図 2.2 DMD を適用した結果.

2.2 応用研究例

動的モードの減衰率に注目した例として、エンジン燃焼室内のバッフル付き燃料注入器の最適な取り付け間隔を求めた Jourdain らの研究がある[Jourdain 13]。Jourdain らは、燃料注射器の間隔を変化させながら燃焼室内に圧力擾乱を加えた数値計算を行い、得られた音圧データに DMD を適用している。各動的モードの減衰率を比較することで、圧力擾乱を最も減衰させる燃焼注射器の間隔を求めることに成功している。

3. 実験

3.1 実験の概要

この実験では石油会社 A より提供された、製油所内の回転機の模擬音データを用いて、軸受けに傷がある場合の音（異常音と呼ぶ）と傷がない場合の音（正常音と呼ぶ）の DMD による識別、特性推定を行った。音圧データは、異常音の有無、集音地点（2種類）、軸受け回転数（600rpm、1200rpm、1800rpm）による 12 種類のデータを用いた。

まず、各時間帯の音響データに対して STFT を適用し、得られたスペクトル分布を時系列に並べて図 3.1 のようなスペクトログラムを生成した。ここで、各時間帯におけるスペクトル分布は 2.1 節で示したシステムの状態データxに相当し、スペクトログラムはxを時系列に並べたデータ行列Xに相当する。

次にスペクトログラムの時間遷移に対して DMD を適用することで、異常音と正常音のスペクトル分布の動的特性を把握することを試みた。特に DMD が系の減衰特性を捉えることができることを考え、スペクトル分布の減衰特性に注目して異常音と正常音を識別することとした。

このように、STFT によって得られる各周波数成分を一つ一つの観測点とみなして DMD を適用することで、1次元の音響データに対しても高次元のデータと同じように DMD を適用することが可能になる。このような適用方法によりデータの振動的成分を考慮せず、減衰的な成分のみを抽出することを目指した。

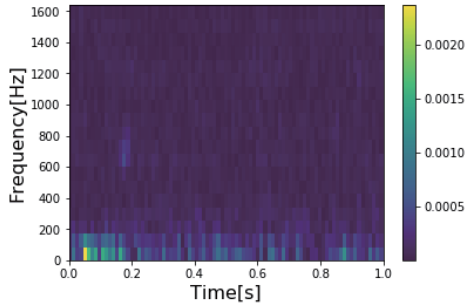


図 3.1 スペクトログラムの例.

3.2 結果

図 3.2 に示すように、各 160 秒間の音響データから時系列に 6,000 個のスペクトル分布を得た上でそれらを 10 個ずつに区切ってスペクトログラムを生成し、それぞれに対し DMD を適用した。

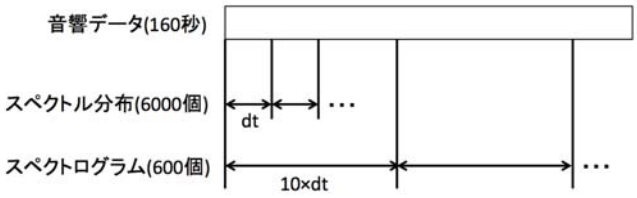


図 3.2 スペクトログラムの生成.

2.1 節で説明したように、DMD の結果得られる固有値行列Λと係数ベクトルbを用いることで、各動的モードの時間発展Ψを求めることができる。ここで、特異値分解の結果から、Ψの第i成分は系全体に対する寄与率がi番目に大きい動的モードの時間発展に相当する。以下、Ψの第i成分に相当する動的モードをモードiと呼ぶ。したがって、モード1は系の動的モードの中で系全体に対する寄与率が最も大きく、支配的なモードとなる。

多くのスペクトログラムにおいて、DMD を適用して得られた動的モードのうち最も寄与率が大きく支配的であったのは、図 3.3 のモード1のような振動数 0 の非振動的なモードであった。一方で図 3.4 のモード 1 およびモード 1 と共役なモード2のように、振動的なモードが支配的になった場合も存在した。これらの分析を 12 種類の音響データから得られるスペクトログラムに対して行った。その上で、各音響データにおいて支配的なモードが非振動的になる割合を調べた。結果を図 3.5 に示す。図 3.5 からはいずれの回転数、地点においても異常音の支配的なモードが非振動的なモードになる割合が高いことがわかる。この傾向は、特に 1200rpm のデータにおける結果で顕著である。これにより、異常音と正常音を支配的な動的モードの種類によって識別できる可能性が示された。また、異常音の各振幅スペクトルは本実験で用いた時間幅については、単調的に減衰する傾向にあることが示された。

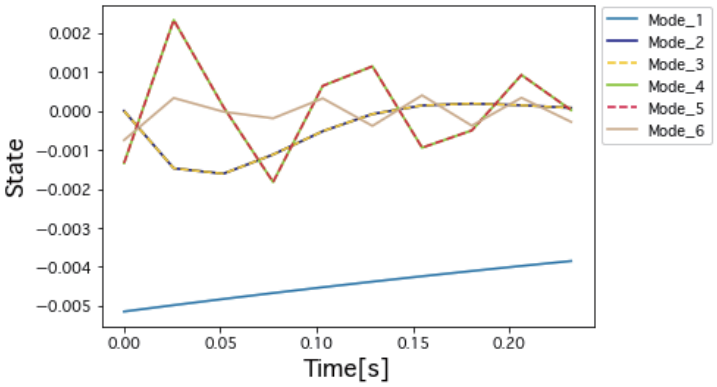


図 3.3 減衰モードが支配的な区間の例.

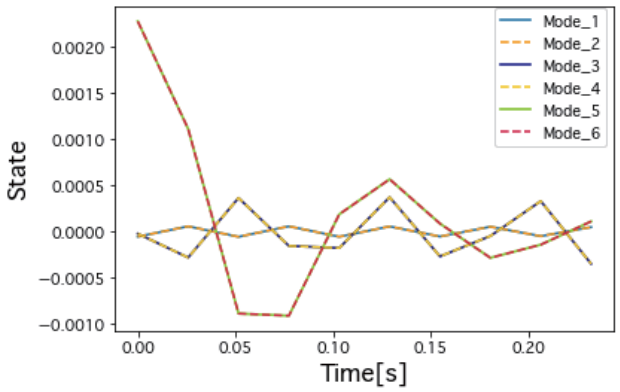


図 3.4 振動モードが支配的な区間の例.

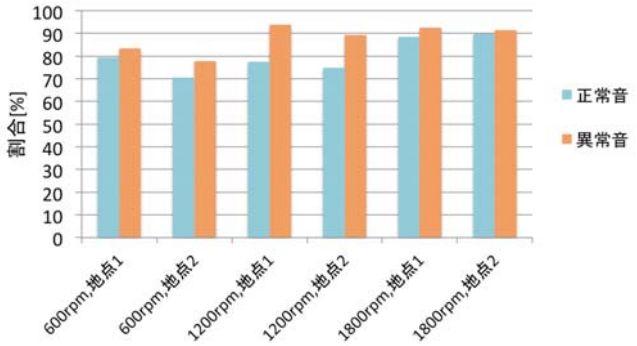


図 3.5 減衰モードが支配的になる区間の割合.

4. まとめ

DMD には系の時空間構造を同時に分析できる点や、系の減衰特性をとらえることができる点などの特長が存在する。音響データに対して、スペクトル分布の減衰特性に注目しながら DMD を適用することで、異常音と正常音でスペクトル分布の減衰構造が異なる傾向にあることがわかった。今後は、STFT や DMD を適用する時間幅を変更するなどして、異常音と減衰特性の関係性について知見を深めることがあげられる。

参考文献

[Rowley 09] Rowley, Clarence, *et al.*: Spectral analysis of nonlinear flows, *Journal of Fluid Mechanics*, **641** (2009), 115-127.

[Schimid 10] Schimid, Peter: Dynamic mode decomposition of numerilcal and experimental data, *Journal of Fluid Mechanics*, **656** (2010), 5-28.

[Tu 14] Tu, Jonathan, *et al.*: On dynamic mode decomposition: theory and applications, *Journal of Computational Dynamics*, **1** (2014), 391-421.

[Giannakis 15] Giannakis, Dimitrios, Joanna Slawinska, Zhizhen Zhao: Spatiotemporal Feature Extraction with Data-Driven Koopman Operators, JMLR Workshop and Conference Proceedings, **44** (2015), 103-115.

[Proctor 15] Proctor, Joshua, and Philip Eckhoff: Discovering dynamic patterns from infectious disease data using dynamic mode decomposition, *Int Health*, **7** (2015), 139-145.

[Brunton 16] Brunton, Bingni, *et al.*: Extracting spatial-temporal coherent patterns in large-scale neural recordings using dynamic mode decomposition, *Journal of Neuroscience Methods*, **258** (2016), 1-15

[Jourdain 13] Jourdain, Guillaume, *et al.*: Application of dynamic mode decomposition to acoustic-modes identification and damping in a 3-dimensional chamber with baffled injectors, *Journal of Sound and Vibration*, **332** (2013), 4308-4323.

大規模テレビ視聴データによる視聴パターン推移の分析

Analysis of Television Viewing Pattern Transitions with Clustering Large-Scale Log Data

水岡　良彰[*1]　Yoshiaki Mizuoka
中田　康太[*1]　Kouta Nakata
折原　良平[*1]　Ryohei Orihara

[*1] 株式会社東芝　研究開発本部　研究開発センター　アナリティクスAIラボラトリー
Analytics AI Laboratory, Corporate Research and Development Center, Research & Development Division, Toshiba Corporation

This paper presents an analysis of television viewing patterns using large-scale television log data. Television log data, collected from televisions upon users' permission, contains information of when, how, and which channels are watched in seconds. In this paper, we extract user groups based on long-term transitions of viewing patterns from television log data with a clustering technique, and we analyze the user groups from viewpoints of a fixed habit and change in a life style. As a result, new long-term transitions of viewing patterns have been found. They are expected to lead to the discovery of audience groups which are valuable to marketing or targeted advertising.

1. はじめに

数千万人以上の視聴者にニュース，ドラマ，CM などのコンテンツを同時配信できるテレビメディアは，インターネット広告市場などが伸びている現在においても巨大な広告市場であり，日本における 2017 年の総広告費は約 2 兆円（広告費全体の約 30%）を占める[電通 2018].

このテレビメディアの魅力を向上させるため，近年普及したネットワーク接続型テレビの視聴データを使用することで，従来のアンケート調査では難しかった長期の視聴分析がしやすくなった．これにより，ある番組を見始めた，あるいは見なくなった原因の分析において，ライフステージの変化などのマクロな観点を加えることで，番組内容によるものか，その時間帯の生活が変化したためかを区別して考察することができる．また，この種の長期的な視聴習慣の種類や割合を把握することで，番組内容の企画や CM の妥当性の検討にもつながる．ただし，長期間の視聴データ分析は膨大なデータを使用するため容易ではなく，長期的な視聴習慣をとらえる手法が必要である．

[Xu 2012]では，ウェブベースのテレビサービスにおける番組推薦を目的に，10 週間の視聴ログを分析しているが，1 クール以上の視聴習慣までは対象にしていない．[菊池 2016]では，ネットワーク接続型テレビのユーザから利用許諾を得て取得した視聴データを使って，番組や CM の視聴分析を行っている．この報告では，特定の番組の視聴の有無や家族構成など，分析対象を事前に決めて分析を行っており，さらに[水岡 2017][陶 2017]では，事前知識が少なく分析対象を決められない場合であっても，抽出対象期間から特徴的な視聴習慣を抽出し，抽出した視聴習慣を持つユーザに絞った分析を可能としている．しかしこの方法では，抽出対象期間が限られるため長期的な視聴習慣の分析は難しい．

本研究では特定の期間における視聴習慣を，時間帯ごとの視聴時間の組み合わせによる視聴パターンで表現し，複数の期間で視聴パターンがどう推移するか考えることで，長期的な視聴習慣を分析する．まず 1 ヶ月間の視聴データから視聴パターンを抽出し，次に抽出した視聴パターンの長期的な推移について，1 年 1 ヶ月間の長期間の視聴データを用いて分析を行う．

連絡先：水岡良彰，（株）東芝　研究開発本部　研究開発センター，〒212-8582　川崎市幸区小向東芝町 1，
yoshiaki.mizuoka@toshiba.co.jp

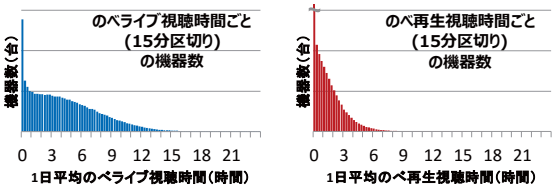


図 1　ライブ視聴または再生視聴の
のべ視聴時間ごとの機器数

以下，2 章では本研究で利用するテレビ視聴データについて説明する．3 章で注目する視聴パターンを抽出し，4 章にて注目する視聴パターンの長期的な推移を抽出し，5 章で抽出した長期的な推移について検証する．6 章でまとめる．

2. テレビ視聴データ

一部の東芝製テレビはネットワーク接続に対応し，視聴データを用いた番組推薦や自動録画等の機能をもつクラウドサービスが利用可能である．本研究では，上記サービスを提供するにあたって，テレビ機器のユーザから視聴データの利用許諾を得て取得したデータを利用し，分析を行う．

また，一部の東芝製テレビでは，放送中の番組を視聴（ライブ視聴）するほか，本体に接続されたハードディスクに事前に録画しておいた番組を視聴（再生視聴）することができる．このうち，ライブ視聴はテレビ番組の放送時間に合わせて視聴することから，時間的な視聴習慣が表れやすいと考えられる．また，ライブ視聴と再生視聴それぞれの視聴時間ごとの機器数を図 1 に示す．のべ視聴時間の長い機器が多いと，分析する機器数が多いことが期待できる．図 1 を見ると，再生視聴に比べてライブ視聴を長時間視聴するユーザの方が多いことが分かる．以上から，本研究ではライブ視聴を分析対象とする．

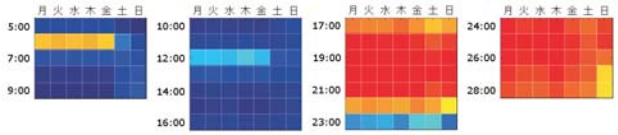
本稿において，視聴パターンの抽出，および，その長期的な推移の抽出で用いるデータは次に述べる通りとする．

(1) 視聴パターンの抽出に用いるデータ

分析対象とする期間は，2016 年 11 月の 1 ヶ月間の期間とした．10 月を終えて番組改編が落ち着いている期間であり，また 12 月の冬休みのような長期休暇が無い期間であるため，習慣的な視聴行動の抽出に適切と考えて決定した．

表 1　視聴パターン抽出時の時間帯区分

朝帯	5~10時
昼帯	10~17時
ゴールデン帯	17~24時
深夜帯	24~29時



(a) 朝帯 5～10 時　(b) 昼帯 10~17 時　(c) ゴールデン帯 17~24 時　(d) 深夜帯 24~29 時

図 2　時間帯区分別の視聴パターンクラスタリング結果（抜粋）

分析対象とする機器は，この期間中にテレビ視聴を行ったデータのある全機器とした．このとき，対象となる機器は 327,721 台であった．

(2)　視聴パターンの推移の抽出に用いるデータ

分析対象とする期間は，1 週間の開始を月曜日として，2016 年 10 月 3 日の週から 2017 年 10 月 23 日の週までの 52 週間，すなわち 1 年 1 ヶ月間とした．

分析対象とする機器については，本研究では習慣的な視聴パターンの分析が目的であるため，この期間中に毎週ライブ視聴が 1 回以上ある機器を対象とした．すなわち，2016 年 10 月 3 日より後に購入された機器や，1 週間以上ライブ視聴しない期間があった機器は対象外とした．この条件に当てはまる対象機器は，187,891 台であった．

3.　視聴パターン抽出

本研究では，各機器の視聴パターンをクラスタリングして注目する視聴パターンを抽出する[水岡 2017]の方法を用いる．ただし，抽出に用いた具体的な特徴量については本研究に合わせて変更する．本章では，視聴パターンの抽出に用いる特徴量について説明し，抽出結果を可視化して示す．

3.1　抽出に用いる特徴量

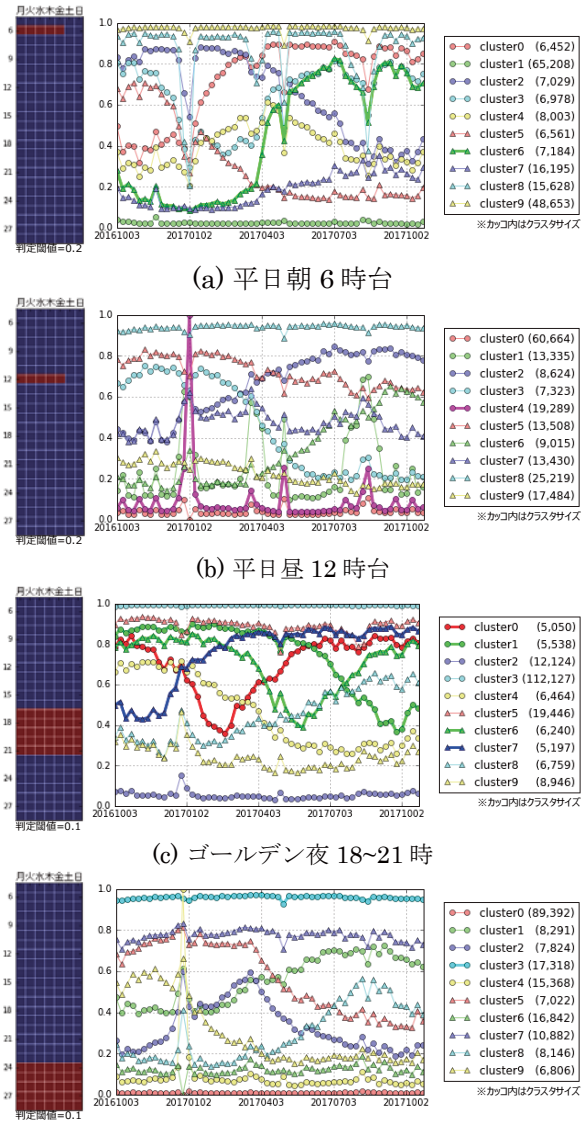
人々の行動は曜日に基づいていることが多く，またテレビで放送される内容も曜日によって決まっている場合が多い．よってテレビ視聴の習慣性は曜日単位で現れやすいと考えられる．しかしテレビ視聴は，たまたま見る・見ないといった状況が起こり得るため，実データをそのまま扱うにはノイズが大きい．

そこで特徴量として，各機器について，曜日（月曜～日曜）と時間帯（1 時間単位）ごとに，ライブ視聴時間の割合を求める．これにより，数値は月内の平均となるため，ノイズの影響が緩和される．この数値を連結したベクトルをクラスタリングの特徴量として用いる．

なお本研究では，祝日を除いて特徴量算出を行う．また，細かく特徴を抽出できるよう，4 つの時間帯区分を定義し，特徴量をそれぞれの時間帯区分に分割してクラスタリングを適用する．各時間帯区分は表 1 の通りである．

3.2　抽出結果

2 章の(1)の機器を対象に，3.1 節の特徴量を用いて，k-means 法(k=40)を適用し，クラスタリングを行った．視聴パターンのクラスタリング結果（k-means で得られた各クラスタの中心点）



(a) 平日朝 6 時台

(b) 平日昼 12 時台

(c) ゴールデン夜 18~21 時

(d) 深夜 24 時以降

図 3　視聴パターンテンプレート（各図左）と視聴パターン判定の推移のクラスタリング結果（各図右）

から，視聴する時間帯が特徴的な各時間帯区分から 1 クラスタずつ抜粋して可視化し，図 2 に示す．

各クラスタの視聴パターンはヒートマップで示されている．各時間帯のクラスタは，横軸が曜日で縦軸が 1 時間区切りの時間帯を表しており，マスの色が青→黄→赤になるに従って対応する曜日の時間帯にテレビを視聴している時間が多いことを示している．

本研究では得られたクラスタのうち，図 2 で示したクラスタを各時間帯区分の代表例として注目し，抽出する視聴パターンとして選択する．

4.　視聴パターンの長期的な推移の抽出

3 章のクラスタリングによって，抽出対象期間に注目した視聴パターンを持つ機器を特定できるようになったが，抽出対象期間外については不明である．本章では 3 章で注目した視聴パターンをテンプレートとして定義し，抽出対象期間外であっても各機器が視聴パターンを持つか否か判定できるようにした上で，

判定結果をクラスタリングすることで視聴パターンの長期的な推移を抽出する.

4.1 視聴パターンのテンプレート化

1 週間を 1 時間単位の時間帯に分割し, テンプレート化したい視聴パターンにおいて視聴している時間帯を“1”、そうではない時間帯を“0”としたベクトルでテンプレートを表現する. 次元数や各次元が意味する時間帯は, 視聴パターンに等しい.

3.2 節で注目した各視聴パターンをテンプレート化して可視化すると, 図 3 の各図の左のヒートマップとなる. 本ヒートマップは, 対応する各時間帯について, “1”を赤, “0”を青で表している. 例えば(a)の平日朝 6 時台に視聴するテンプレートであれば, 月火水木金の朝 6 時台を赤, それ以外を青で示している. 本テンプレートは, “1”となっている曜日の時間帯に視聴しており, “0”となっている曜日の時間帯は視聴していてもいなくても構わないことを意味している. テレビ視聴においては, 習慣的に見る訳ではないが, たまたまテレビを点ける場合もあり, 習慣の判定としてはノイズとなり得るが, このようにすることでノイズ除去の役割を果たすことができる.

最後に, 視聴するとした時間帯(“1”とした時間帯)を, どの程度以上視聴したときにテンプレートが表す視聴パターンを持つと判定するかの割合を, 判定時のパラメータとして設定する.

4.2 テンプレートによる視聴パターンの判定

ある 1 週間のテレビ視聴が, テンプレートの表す視聴パターンに合致するか判定する.

まず判定したい 1 週間を視聴パターンの形式で表現する. すなわち, 1 週間を 1 時間区切りとして各時間帯の視聴割合を特徴量としたベクトルを生成する. ここで各特徴量は視聴割合なので 0 から 1 の実数を取り得る. 次に, テンプレートのベクトルの“1”を, ベクトルに含まれる“1”の個数で割った上で, 前述の 1 週間の視聴パターンのベクトルとの内積を計算する. この結果が閾値以上の場合に, テンプレートが表す視聴パターンを持つと判定する.

なお本稿では, 視聴している“1”と視聴しているか問わない“0”の 2 値を用いることとしたが, 明示的に視聴していない場合を考慮したい場合も考えられる. この場合は, 視聴していない時間帯を“-1”として計算するか, あるいは視聴していない時間帯を“1”とするパターンを別途作成し, このパターンに合致すると判定された場合は判定から外す操作を行えばよい.

4.3 視聴パターン判定のクラスタリング

4.2 節の方法によって, 注目する視聴パターンを持つか否かの判定を, 期間を問わずに, すなわち視聴データが存在すれば長期に渡って可能となった. しかし分析対象とする機器が多い場合, 個別に判定結果を観察しても大きな傾向を把握することは困難である.

そこで本研究では, 4.2 節の方法による判定結果をクラスタリングすることで特徴的な推移を抽出する. 本稿での視聴パターン判定の推移の抽出対象期間は 52 週間であるため, 1 機器に付与されている判定数は 52 個となる. この 52 個の 0 または 1 の判定結果を連結し, 1 次元のベクトルとしてクラスタリングで用いる特徴量とする.

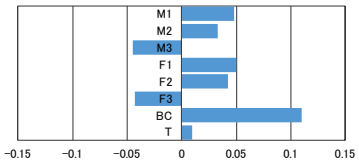
4.4 抽出結果

2 章(2)の機器を対象に, 4.3 節の方法を用いて, クラスタリング手法として k-means(k=10)を適用し, クラスタリングを行った. 視聴パターンの推移のクラスタリング結果(k-means で得られた各クラスタの中心点)を可視化した結果を図 3 の各図の右側に示す. 各クラスタの視聴パターンの推移が折れ線グラフで示されており, 横軸は対象期間内の週単位の時期, 縦軸はクラスタに含まれるテンプレートが表す視聴パターンを持つ機器の割合を表している.

以上のようにクラスタリングおよび可視化によって, 代表的な視聴パターン判定の推移を観察できるようになった. この可視化結果を観察することで, 視聴パターン判定の特徴的な推移を抽出することができる.

性年齢区分	定義
M1	男性　20~34歳
M2	男性　35~49歳
M3	男性　50歳以上
F1	女性　20~34歳
F2	女性　35~49歳
F3	女性　50歳以上
BC	男女　0~12歳
T	男女　13~19歳

(a) 世帯属性の区分



(b) 世帯属性の分布

図 4　平日朝 6 時台に 4 月から視聴する層の世帯属性の分布

表 2　平日朝 6 時台に 4 月から視聴する層の番組視聴割合リフト値上位の番組（上位 5%から抜粋）

番組名	開始時刻	チャンネル
すくすく子育て「きょうだいの子育て」	2016/12/02 13:05	ＮＨＫＥテレ
プチプチ・アニメ　ポンユタウン「ポンユタウン」	2016/12/02 08:50	ＮＨＫＥテレ
まいにちスクスク　子育てママの体のケア（１）「腰痛」	2016/11/28 10:55	ＮＨＫＥテレ
いないいないばあっ！	2016/12/02 16:15	ＮＨＫＥテレ
おかあさんといっしょ	2016/12/02 16:30	ＮＨＫＥテレ

5. 抽出した視聴パターン判定の推移の検証

本章では, 4 章の結果に基づいて, 視聴パターン判定の特徴的な推移を持つ機器のクラスタを検証する. 以下, 図 3 の各視聴パターン判定の推移から, クラスタをピックアップして検証する.

5.1 検証に用いるデータ

各クラスタの分析を行うために, 複数のデータを用いる. まず, テレビ機器利用者の世帯属性データを用いる. ここでの世帯属性は, 図 4 の(a)に示す 8 つに区分される性年齢区分であり, 時間帯ごとの平均視聴時間からランダムフォレストで推定する[菊池 2016]の方法によるものである. また属性の分布はリフト値の対数(底は 10)で示す. リフト値は, クラスタ内の対象区分の比率を, クラスタリング対象とした全機器内の対象区分の比率で割った値であり, 対数を取ることで数値間の比較をしやすくしている. 本稿では 2017 年 9 月末の推定結果を用いる.

また, テレビ機器のエリア設定データを用いる. ここで用いるエリアはテレビの視聴設定から判別できるデータであり, 世帯属性と同様にリフト値の対数で検証する. 本稿では 2017 年 9 月末時点の判別結果を用いる.

さらに, 番組視聴割合データを用いる. これは, ある期間に放送された各番組の, 放送時間に対する視聴時間の割合のランキングである. ただし単純に人気の番組が上位にならないよう, 世帯属性と同様にリフト値のランキングを用いる. 本稿では, 検証のしやすさのため関東圏の機器かつ NHK および地上波キー局のチャンネルに限定し, 2016 年 11 月 28 日からの 1 週間に放送された 1,973 番組をランキング対象とする.

表 3　各クラスタ検証結果概要

テンプレート	クラスタ	サイズ	クラスタの概要	世帯属性	エリア設定	番組視聴割合ランキング
a	6	7,184	平日朝6時台に4月から視聴している層	BC層が多い	特徴なし	Eテレが上位を占める. 子供向けあるいは親向けの番組がメイン.
b	4	19,289	平日昼12時に正月だけ視聴している層	偏りなし	東北や関東が比較的多く 近畿や九州は比較的少なめ	Eテレが上位を占める. 語学番組や短歌・手話などの教養番組がメイン.
c	7/0/6/1	5,197/5,050/6,240/5,538	17時から22時に4半期単位で視聴していない層	M1層とF1層とBC層が多い M3層とF3層とT層が少ない	特徴なし	未明や早朝の番組と, 土日の日中のEテレの教養番組が混在.
d	3	17,318	深夜にいつも視聴している層	特にT層が多く M2層とF2層も多い M1層とF1層とBC層が少ない	近畿や四国比較的多く 九州の一部も比較的多い 北海道や東北や中部は少ない	複数のチャンネルが視聴されており, ジャンルもドラマやバラエティなど 幅広く視聴されている.

5.2 検証結果

代表例として, 本節では図 3 の(a)の cluster6 に注目する. このクラスタは, 平日朝 6 時台に 4 月から視聴するようになった, 7,184 機器からなるクラスタである. 4 月は進学や就職といった生活スタイルが変化する時期であるため, 朝早く起きて活動するよう変化した層を表していると考えられる.

世帯属性の分布は図 4 の(b)の通り, 特に BC 層が多いことが分かる. このことから, 幼稚園や小学校などに通うようになった子供本人や, 朝に子供を送り出す親が早く起きて活動するようになったと推測できる.

番組視聴割合のリフト値でのランキング上位の番組を確認すると, 上位 5%の 97 番組全てが NHK の E テレであった. 具体的な番組を見てみると, 表 2 に示す番組が上位となっており, 子供や子供を持つ親向けと思われる番組が目立っていた. この結果からも子供がいる世帯であると推測でき, 前述の推測とも矛盾しない.

一方で, テレビ機器のエリア設定の分布については, 大きな傾向は見られなかった. エリアに関わらず子供がいる家庭が早く起きて活動する生活スタイルは考えられるため, これまでの推測に矛盾していないといえる.

以上の検証から, 注目する視聴パターン判定の推移を持つ機器集合に対して, 別の観点のデータから分析し矛盾がないことを確認した. この例の場合, 抽出したクラスタのユーザを分析していくことで, 幼稚園や小学校などへの入園や入学に合わせた番組や CM の制作に活用できるだろう. また, ある番組の視聴者における抽出したクラスタのユーザの割合を調査することで, 幼稚園や小学校などに入園・入学した視聴者の分布といった観点で, 番組の視聴者層を分析することもできるだろう.

その他の各クラスタについても検証し, 結果の概要を表 3 にまとめた. 表 3 のテンプレートやクラスタは, それぞれ図 3 の各図のアルファベットや各クラスタの番号と対応している.

図 3 の(b)の cluster4 は, 平日昼 12 時に普段は視聴していないが正月だけ視聴した層である. 教養番組の視聴が多いことから, 平日は仕事に外出し, 休日の日中の時間を活用してテレビで情報収集や勉強を行っていると考えられる.

図 3 の(c)の cluster7,0,6,1 は, 四半期単位で 17～22 時に視聴しない時期がある層である. 17～22 時はテレビ視聴率が高いと知られている時間帯を含んでおり, 主にドラマなど, 四半期の区切りで改変される番組が放送される時間帯である. これらクラスタは四半期の区切りに合わせて視聴しなくなっているため, それぞれの期間で見たい番組が無かった層と推測できる. また世帯属性の結果から, M1 層・F1 層・BC 層は改変期ごとに選択的に番組を視聴する傾向が高いと推測できる.

図 3 の(d)の cluster3 は, 深夜にいつも視聴している層である. エリアによる偏りは, 地域ごとの就寝時刻に起因している可能性がある. 平成 28 年社会生活基本調査の結果をもとに公開されている『夜更かし！？ランキング』[総務省 2017]を参照すると, 近畿・四国・九州の一部(福岡や沖縄など)に夜更かし上位の, 北海道・東北・中部に夜更かし下位の都道府県が多くなっており, 複数の都道府県で傾向が一致する様子が観察できる.

以上の(b)から(d)についても, それぞれのクラスタから分かる視聴者層に向けた, 番組や CM の制作に活用することができるだろう. あるいは, ある番組の視聴者層の分析にも活用できるだろう.

本章では, 提案するアプローチによって視聴パターン判定の推移から抽出した機器のクラスタを複数分析した. 機械的に得られた機器集合であるクラスタに対して, 世帯属性・エリア設定・番組視聴割合ランキングといった別の観点から検証して矛盾がない仮説を立てることができた. また, 番組や CM の制作への活用の可能性を示すことができた.

6. おわりに

本研究では, 注目する視聴パターンに該当するかどうかを判定する手法, および視聴パターンの推移を自動抽出する手法を提案した. また, テレビ視聴の実データから得られた視聴パターンの推移や, その推移を持つ機器集合を検証することで, 視聴パターン判定の推移を自動抽出する手法の妥当性を示した. これまでは難しかった, 長期的な観点からの実データの分析ができるようになったため, 新しい知見の発見や, それに基づくマーケティングなどが期待できる.

有用な視聴パターン判定の推移を抽出したら, 視聴パターンと同様にテンプレート化することで, 抽出の対象期間や対象機器以外についても判定が可能となる. ただし, 期間が異なると祝日が同じ曜日とは限らない点に考慮して計算する必要がある.

今後は, 視聴パターン判定の推移のさらなる分析や, 再生視聴を含めた分析, 分析によって発見される知見の具体的な活用方法について, 検討を進めていく.

参考文献

[電通 2018] 株式会社 電通: 2017 年 日本の広告費, http://www.dentsu.co.jp/news/release/2018/0222-009476.html .

[Xu 2012] Mengxi Xu, Shlomo Berkovsky, Irena Koprinska, Sebastien Ardon, Kalina Yacef: Time Dependency in TV Viewer Clustering, UMAP Workshops, vol. 872, 2012.

[菊池 2016] 菊池 匡晃, 坪井 創吾, 中田 康太: 大規模テレビ視聴データによる番組視聴分析, 情報処理学会デジタルプラクティス Vol.7 No.4, 情報処理学会, 2016.

[水岡 2017] 水岡 良彰, 陶 亜玲, 中田 康太, 折原 良平: 大規模テレビ視聴データクラスタリングによる視聴パターンの分析, 人工知能学会全国大会(第 31 回), 人工知能学会, 2017.

[陶 2017] 陶 亜玲, 水岡 良彰, 中田 康太, 折原 良平: 1K2-3 大規模テレビ視聴データを用いたクラスタリング技術の開発, 人工知能学会全国大会(第 31 回), 人工知能学会, 2017.

[総務省 2017] 総務省統計局: 統計局ホームページ/平成 28 年社会生活基本調査 47 都道府県ランキング http://www.stat.go.jp/data/shakai/2016/rank/index.htm.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

顧客の知覚における品質ブランドイメージを形成する要因の検証

Verification of Factors Forming Quality Brand Image in Customers' Perception

加藤 拓巳[*1]
Takumi KATO

津田 和彦[*2]
Kazuhiko TSUDA

[*1] 本田技研工業株式会社
Honda Motor Co.,Ltd.

[*2] 筑波大学
University of Tsukuba

Companies develop various activities to manage brands as assets in order to acquire target brand images. However, in fact, since companies cannot grasp the necessary elements for the image, there are companies that make inconsistent products and promotions into the world. Therefore, in this research, we verified factors to form "quality" brand image, which is said to be ambiguous and complicated, in customers' perception. Quality is said to include not only objective value (Functional value) such as performance and durability but also subjective value (Emotional value) such as beauty and perceived quality. In recent years, companies such as Apple and Samsung, which have excellent emotional value, are emerging, so the value is considered as a major source of competition in the manufacturing industry. We believe that this research will enable companies to effective decision-making without obscuring the elements necessary to acquire the target brand image.

1. はじめに

[Aaker 91]がブランド・エクイティ概念を提唱して以来，多くの企業はブランドを資産として管理し，価値を高めるために多様な活動をしている．ここで重要な点は，ブランドイメージの一貫性である．商品やプロモーションで一貫したイメージを提示することで，購買駆動機能が高まる[青木ら 97]．さらに，商品性能は優れた差別性を持ったとしても，競合他社の模倣に脆弱である一方，一貫したブランドイメージは容易に模倣されない[Aaker 96]．

このように，ブランドイメージの効用が把握されているにも関わらず，一過性の大規模な広告宣伝を展開する企業が多い[Christensen 05]．この原因の 1 つは，目指すブランドイメージを獲得するために必要な要素を把握できていないことが考えられる．そこで，本研究では，品質というブランドイメージを対象に，品質という一般的なイメージの形成要因を定量的に明らかにする．具体的には，顧客の知覚上で品質イメージのトップブランドを抽出し，その形成要因を定量的に評価した．品質を対象にしたのは，つかみどころがなく，複雑かつ抽象的と称されるためである[Adams 12]．

2. ブランドイメージの把握

2.1 品質の構成要素

[Garvin 87]は，品質には，「性能・機能・信頼性・適合性・耐久性・サービス性・美しさ・知覚品質」の 8 つの要素があると論じている．つまり，耐久性等の数字で評価しやすい客観的な機能的価値だけでなく，美しさや知覚品質といった数字で評価しにくく，顧客が主観的に感じる意味的価値まで必要だと述べている．そのうち，知覚品質の因果関係のモデル化をした事例等は見られるが[Aaker 13]，品質の形成要因を定量的に検証した例は少ない．

連絡先：加藤拓巳，本田技研工業株式会社
ビジネス開発統括部 ビジネスアナリティクス課，
〒107-0062 東京都港区南青山 2-1-1，
Takumi_Kato@hm.honda.co.jp

2.2 ブランドイメージの類型化

ブランドイメージの研究において活発に議論されてきた概念に，ブランドパーソナリティが挙げられる．[Aaker 97]は，米国のブランドを対象に 5 つのパーソナリティ因子として，誠実(Sincerity)，刺激(Excitement)，能力(Competence)，洗練(Sophistication)，素朴(Ruggedness)を特定している．ブランドイメージの研究は，こうした類型化が中心になっており，特定のブランドイメージに焦点を絞り，その形成要因を検証した例は少ない．

3. 顧客の知覚上での品質イメージの要因

本研究では，品質のブランドイメージが浸透しているトップブランドについて，その形成要因を検証している．

データは，2017/5 に実施した Web 調査で取得した．対象国は Brazil，China，Germany，India，Japan，South Africa，Thailand．UK，USA の 9 カ国で，業界は指定していない．サンプルサイズは各国 500 人の計 4,500 人である．被験者は，20 代から 60 代の男女である．設問は，バイアスを極力排除するために，選択肢を提示せずに問う，純粋想起を利用した．調査項目は，「品質が高いというイメージで想起するブランド」と「その理由(以降，想起理由と呼ぶ)」である．回答は多言語で記載されるため，各国語のネイティブが日本語翻訳した後に解析した．

研究のプロセスは，図 1 に示すとおり，大きく 3 つのフェーズから構成される．

Phase 1 では，意味理解とスコアリングを実施している．まず，想起理由のテキストデータを，オープンソース解析エンジン MeCab で形態素解析して名詞と形容詞を抽出した．そのなかで，客観的な単語を機能的価値の要素，主観的な単語を意味的価値の要素として辞書登録した．例えば，「性能」や「耐久性」といった単語は機能的価値，「スタイリッシュ」や「香り」といった単語は意味的価値になる．辞書の構成は，表1に示すとおり，各価値で 8 要素の計 16 要素として定義した．登録した単語数は 86 である．純粋想起という性質上，1回答の文数は多くても 2-3 文である．このことにより，辞書登録語数は多大にはならない．その他の要素は，4.1 項で説明する意味理解結果の構成比で 1%に届かない 30 件未満であったため除外した．

次に，口語表現を理解するために構築した，後述する意味理解アルゴリズムによって，辞書登録単語を検知した場合，要素をタグとして付与した．加えて肯定的な意味の場合にのみ，タグ別に集計し，1 回答ごとにスコア化した．口語を理解する術としては，大別して，ルールベースと統計的意味理解に分けられる．[土屋ら 14]は，8,024 のルールによって感情を判断している．[Harada 15]は，LDA 等の統計的意味理解を利用して口語を理解している．本研究で扱う純粋想起では，単語数が少ないので統計処理は困難であるため，ルールベースを採用する．ルールベースを採用するもう1つの理由は，品質のブランドイメージに限った文章表現であるため，大規模な知識 DB は必要としない．

このようなデータの性質を踏まえて，表 2 に示す 4 つの機能を意味理解アルゴリズムとして構築している．1 つ目の係り受けは，辞書登録単語の肯定・否定に着目し，肯定の場合のみスコアを付与する．2 つ目の多重否定は，複数回にわたって否定の意味を有する単語が並んだ場合，最終的に肯定か否かを判断してスコアを付与する．3 つ目の肯定疑問は，「ですよね？」等の同調を求めている文脈以外は，スコアを付与しない．4 つ目の比較は，比較の係り受けを理解し，別のブランドや過去が勝る文脈ではスコアを付与しない．また，当該フェーズにて，適合率・再現率を算出し，辞書と意味理解アルゴリズムの精度を検証する．両指標ともに，80%以上を以降の Phase 2 に進む条件と設定した．上記アルゴリズムの構築環境は，python である．

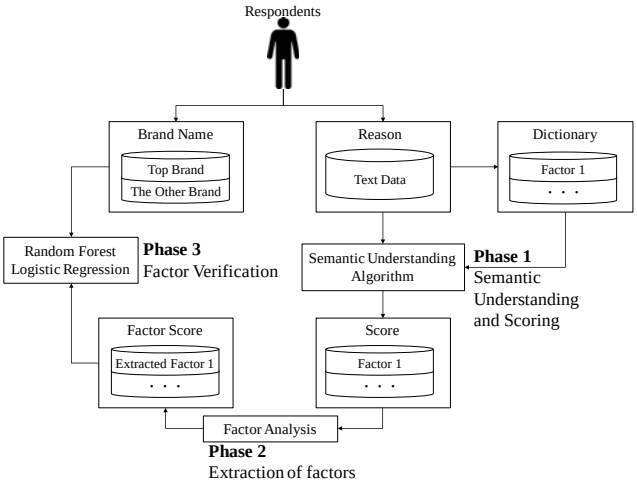


図 1 研究のプロセス

表 1 辞書の構成と登録単語例

Value	Tag	Example Word 1	Example Word 2
Functional Value	Functional_01_Quality	品質	高品質
	Functional_02_Durability	耐久性	長持ち
	Functional_03_Technology	技術	テクノロジー
	Functional_04_Function	機能	性能
	Functional_05_Safety	安全	安全性
	Functional_06_Material	材料	素材
	Functional_07_Warranty	保証	アフターサービス
	Functional_08_CostPerformance	コストパフォーマンス	
Emotional Value	Emotional_01_Design	デザイン	外観
	Emotional_02_Feeling	音質	美味しい
	Emotional_03_Comfortable	快適	使い勝手
	Emotional_04_Innovative	革新	革新的
	Emotional_05_Stylish	スタイリッシュ	洗練
	Emotional_06_Luxury	高級	ハイクラス
	Emotional_07_Relief	信頼	安心
	Emotional_08_Reputation	評判	有名

表 2 意味理解アルゴリズムの解析結果例

Function	Text	Tag	Score
係り受け	どの製品も評判が高く、耐久性のある製品を作っている。	Functional_02_Durability	1
		Emotional_08_Reputation	1
多重否定	品質が素晴らしく、悪い評判がない製品だから。	Emotional_08_Reputation	1
肯定疑問	性能の高さか、耐久性か、何のクオリティなのか？	Functional_02_Durability	0
		Functional_04_Function	0
比較	コストパフォーマンスはノンブランド製品の方が勝るが、味は良い。	Functional_08_CostPerformance	0
		Emotional_02_Feeling	1

Phase 2 では，意味理解アルゴリズムによって付与したタグのスコアを因子分析することで，品質ブランドイメージを構成する因子を抽出した．因子分析は，統計ソフト R の psych パッケージを利用し，バリマックス回転によって実施した．直行回転としているのは，因子間の相関をなくし，独自性の高い因子を抽出するためである．また，抽出する因子数は，スクリープロットを描き，固有値が 1.0 以上となる因子までで区切ることで決定した．ここで，2.1 項で述べた Garvin の品質要素と比較している．

Phase 3 では，まず，抽出した因子を説明変数として，品質のトップブランドとその他ブランドを，ランダムフォレストによって分離できるか否かを検証した．その際，ジニ係数の平均減少量(Mean Decrease Gini)によって，変数の重要度を評価した．しかし，重要性の強弱のみの理解にとどまるため，ロジスティック回帰モデルによって，効果の正負まで含めて要因を評価した．両分析ともに，環境は R であり，ランダムフォレストは randomForest パッケージを使用した．木ごとの特徴量選択を表すパラメータである mtry は，tuneRF()関数を用いて最適化した値を算出した．

データセットは，表 3 に示すように，想起理由のレコードごとに，因子スコアを算出したものを用いる．回答者数は 4,500 人であるが，回答の際にブランドを複数挙げ，想起理由を共通に述べる場合がある．その場合は，レコードをブランド数分に分割し，想起理由のテキストは同じものを格納している．その結果，合計レコード数は 5,590 となっている．

ここで，トップブランドの定義が必要になる．純粋想起で挙げられたグローバルの上位 20 ブランドの各国における構成比を表 4 に示す．Apple と Samsung は群を抜いて高く，共にグローバルで 10%以上獲得している．両者の違いとしては，Apple は若干の変動はあるものの総じて高いスコアだが，Samsung は China と Japan での存在感が低く，マーケットの強弱が見て取れる．よりブランドの性質を理解するために，表 3 の因子スコアデータをブランドごとに平均値を算出し，階層クラスター分析を実施した．クラスター分析は，R の cluster パッケージを利用し，Ward 法によって実施している．その結果，図 2 に示すとおり，Apple と Samsung が隣接しており，世界で数あるブランドの中で類似した特徴を有していることが理解できる．その両者に近似しているのは，Philips，Google，Microsoft となっており,強い品質ブランドになる可能性が高いと考えられる．

そこで，本研究では，品質イメージのトップブランドとして，上記 5 ブランドと定義する．しかし，表 5 の raw data に示すとおり，正例であるトップブランドが 18.6%の不均衡データである．そこで，まず本研究の観点では意義が少ないデータを除くために，8 つの因子スコアの絶対値合計が 1 以上のデータのみにスクリーニングした．そして，正例の 612 件に合わせて，負例の 4,434 件から同数をランダムアンダーサンプリングし，計 1,224 件とした．

[Adams 12]は Garvin の品質要素のうち，プロットで表現しにくい美しさと知覚品質が販売に寄与することが多いと述べている．

[延岡 06]は,数字で評価しやすい機能的価値ではなく，数字で評価しにくいデザインや顧客体験等の意味的価値が，顧客価値が高いと論じている．その成功例として，Apple と Samsung を挙げている．つまり，本研究で定義したトップブランドについても，品質イメージの要因として，意味的価値の方が重要であるという仮説が立てられる．

表 3 データセット例

Record	Respondent No	Reply Brand	Top Brand	Functional_01 _Quality	・・・	Emotional_08 _Reputation
1	1	Apple	1	1		0
2	2	Nestle	0	0		0
3	2	Toyota	0	0		0
4	3	NIKE	0	0		2
...						
5590	4,500	Samsung	1	0		0

表 4 品質イメージで想起される上位 20 ブランド

No	Brand	Brazil	China	Germany	India	Japan	South Africa	Thai land	UK	USA	Global
1	Samsung	25.2%	1.1%	11.6%	15.6%	0.0%	18.3%	19.0%	13.5%	14.6%	11.0%
2	Apple	12.0%	21.1%	10.4%	12.4%	8.2%	8.1%	16.8%	21.3%	15.9%	10.7%
3	SONY	6.1%	1.8%	9.4%	9.1%	5.8%	6.1%	4.7%	12.9%	8.8%	5.9%
4	NIKE	4.3%	3.9%	4.0%	5.2%	1.4%	6.3%	2.2%	5.7%	10.4%	4.1%
5	adidas	2.1%	1.8%	6.9%	5.2%	0.5%	5.1%	2.9%	2.6%	3.0%	3.0%
6	Nestle	17.2%	0.8%	0.7%	3.0%	0.5%	6.9%	1.1%	1.1%	0.5%	2.8%
7	BMW	1.5%	2.4%	7.9%	1.2%	1.0%	7.3%	5.1%	2.6%	2.6%	2.8%
8	LG	4.3%	0.3%	1.5%	5.5%	0.5%	8.5%	0.4%	1.4%	4.4%	2.8%
9	Mercedes-Benz	0.6%	2.4%	9.4%	1.5%	4.8%	1.2%	9.5%	0.3%	0.2%	2.3%
10	Unilever	2.5%	0.3%	0.0%	3.3%	0.0%	4.3%	1.8%	1.1%	1.6%	1.5%
11	Panasonic	0.9%	2.1%	2.2%	1.0%	7.7%	0.8%	1.5%	3.7%	0.7%	1.5%
12	Microsoft	4.0%	1.3%	0.5%	2.4%	0.0%	1.2%	0.0%	2.3%	3.7%	1.5%
13	HUAWEI	0.0%	17.1%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	1.4%
14	iPhone	0.9%	1.3%	1.0%	1.6%	2.4%	1.2%	9.5%	0.6%	0.5%	1.4%
15	Haier	0.0%	16.3%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	1.4%
16	Google	2.5%	0.3%	0.5%	4.8%	0.0%	0.2%	0.7%	1.1%	2.3%	1.3%
17	CHANEL	0.3%	0.5%	0.7%	0.3%	7.2%	0.4%	4.4%	3.7%	1.6%	1.3%
18	Philips	0.3%	2.1%	3.0%	4.6%	0.0%	0.6%	0.0%	0.0%	0.0%	1.2%
19	Lenovo	0.3%	9.5%	0.5%	0.7%	0.0%	0.6%	0.0%	0.3%	0.7%	1.1%
20	VW	1.5%	1.8%	3.0%	0.4%	0.0%	4.3%	0.0%	0.3%	0.2%	1.1%
	The others	13.5%	11.8%	26.9%	22.2%	59.9%	18.5%	20.4%	25.3%	30.2%	39.8%
	Total	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%

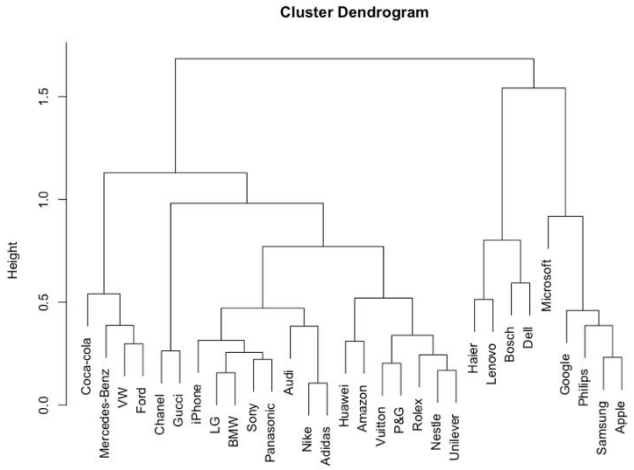


図 2 因子スコアによるブランドの階層クラスター

表 5 ランダムアンダーサンプリング による不均衡データの補正

	raw data	Screened data	Balanced data
Positive	1,039	612	612
Negative	4,551	4,434	612
Total	5,590	5,046	1,224

4. 検証と考察

4.1 Phase 1：品質ブランドの想起理由の意味理解

構築した辞書と意味理解アルゴリズムによって，ブランドの想起理由のテキストをタグ付けし，スコアの分布を各国で算出したデータを表 6 に示す．グローバルの傾向として，機能的価値の 01_Quality と 02_Durability に多くの声が集まっており，機能的価値が約 60%を占める．国別の特徴としては，日本は意味的価値の 06_Luxury が最も多く，世界では稀である．実際，表 4 のブランドを見ると，CHANEL が 7.2%想起されている．

表 6 各国の品質要素のスコア分布

Value	Tag	Brazil	China	Germany	India	Japan	South Africa	Thai land	UK	USA	Global
Functional Value	01_Quality	33.8%	44.5%	24.2%	43.7%	13.9%	23.3%	31.0%	26.5%	34.0%	32.9%
	02_Durability	10.5%	3.1%	19.4%	12.6%	5.7%	19.6%	12.9%	13.8%	18.7%	12.5%
	03_Technology	14.2%	5.6%	4.4%	3.0%	8.2%	1.9%	5.2%	4.4%	1.9%	5.1%
	04_Function	2.8%	3.8%	2.2%	5.0%	1.9%	6.2%	2.6%	2.9%	3.8%	3.5%
	05_Safety	3.1%	3.4%	0.9%	0.3%	1.3%	0.9%	2.8%	0.7%	0.3%	1.6%
	06_Material	1.4%	0.7%	7.5%	1.3%	3.2%	2.8%	3.6%	4.7%	3.2%	2.7%
	07_Warranty	1.7%	5.6%	0.0%	1.0%	1.3%	4.7%	1.8%	0.7%	0.3%	2.6%
	08_CostPerformance	0.0%	0.7%	5.3%	0.0%	1.3%	3.4%	0.0%	1.1%	0.0%	1.0%
Emotional Value	01_Design	2.3%	1.3%	0.9%	1.5%	8.9%	0.9%	3.1%	1.8%	1.9%	2.1%
	02_Feeling	2.6%	2.9%	10.1%	1.5%	5.1%	11.5%	1.8%	5.1%	7.0%	5.6%
	03_Comfortable	3.4%	2.0%	0.4%	3.0%	2.5%	0.9%	7.5%	1.1%	1.3%	2.7%
	04_Innovative	5.4%	3.6%	4.4%	3.5%	3.2%	0.6%	2.6%	6.9%	2.5%	3.4%
	05_Stylish	3.1%	0.4%	2.6%	1.5%	10.1%	0.9%	3.1%	1.8%	3.2%	2.4%
	06_Luxury	0.0%	2.7%	0.0%	3.0%	20.3%	3.7%	4.7%	5.1%	2.2%	3.6%
	07_Relief	7.4%	7.0%	8.8%	10.6%	2.5%	13.7%	6.7%	13.5%	12.4%	9.3%
	08_Reputation	8.2%	12.6%	8.8%	8.5%	10.8%	5.0%	10.6%	9.8%	7.3%	9.0%
	Total	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%

次に，意味理解アルゴリズムの精度検証を実施した．適合率と再現率について，各要素 10 件の計 160 件で評価した．結果は表 7 に示すとおり，96.9%と 93.8%となっており，当該アルゴリズムの妥当性を確認した．

表 7 適合率と再現率の評価結果

Value	Tag	Precision		Recall	
		Num	Correct	Num	Correct
Functional Value	Functional_01_Quality	10	10	10	10
	Functional_02_Durability	10	10	10	9
	Functional_03_Technology	10	10	10	10
	Functional_04_Function	10	10	10	7
	Functional_05_Safety	10	10	10	10
	Functional_06_Material	10	8	10	8
	Functional_07_Warranty	10	9	10	10
	Functional_08_CostPerformance	10	10	10	10
Emotional Value	Emotional_01_Design	10	10	10	10
	Emotional_02_Feeling	10	9	10	10
	Emotional_03_Comfortable	10	10	10	9
	Emotional_04_Innovative	10	10	10	9
	Emotional_05_Stylish	10	9	10	9
	Emotional_06_Luxury	10	10	10	10
	Emotional_07_Relief	10	10	10	10
	Emotional_08_Reputation	10	10	10	9
	Total	160	155	160	150
	Index	96.9%		93.8%	

4.2 Phase 2：品質ブランドイメージの因子抽出

Phase 1 において，意味理解アルゴリズムによって付与したタグのスコアを因子分析することで，品質ブランドイメージを構成する因子を抽出する．

抽出する因子数は，固有値が 1.0 以上の因子は 8 つであったことから，この数を採用した．表 8 に示すとおり，8 つの因子の内，Safety，Material，Warranty，Durability の 4 つは機能的価値から成っており，累積説明率は 64.10%に達する．また，Garvin 説ともすべて対応づけられる．一方，Design と Reputation は同内容の Aesthetics と Perceived Quality が対応するものの，Innovative と Technology of Innovative & Comfortable は該当するものが見当たらない．つまり，近年は，意味的価値の重要性が増しており，新たな因子として現れている．

表 8 抽出因子と Garvin の品質要素の比較

No	Extracted Factor	8 Dimensions of Quality by Garvin	Proportion Var	Proportion Explained
1	Safety	Performance	6.2%	18.1%
2	Material	Features	6.2%	18.1%
3	Warranty	Serviceability	6.2%	18.1%
4	Innovative	–	5.8%	16.9%
5	Design	Aesthetics	3.7%	10.6%
6	Durability	Reliability, Durability	3.4%	9.8%
7	Technology of Innovative & Comfortable	–	1.7%	5.1%
8	Reputation of Quality	Perceived Quality	1.1%	3.3%
		Conformance		
	Total		34.3%	100.0%

4.3 Phase 3：品質ブランドイメージ要因の検証

表 5 で説明した 1,224 件のデータセットのうち，ランダムサンプリングした 80%をランダムフォレストで学習し，残りの 20%で検証した結果を表 9 に示す．なお，グリッドサーチをかけて最適化した結果，mtry = 4 としている．その結果，検証データの予測精度は，74.3%となっている．純粋想起というデータの性質上，1 レコードで表出する変数が少ない中，固有名詞や顧客属性等の他の説明変数を利用せずに一定の精度で判別できている．もちろん，「スマートフォン」「IT」といった Apple や Samsung を特定しやすい単語をモデルに組み込めば，一層精度の向上は見込めるが，ハードコーディングは研究の目的に沿わないため，ここでモデル構築を完了とする．ロジスティック回帰モデルについても，76.3%と同等の予測精度であった．

表 10 に示すとおり，ランダムフォレストのジニ係数の平均減少量，ロジスティック回帰モデルのオッズ比ともに，EF_08_Reputation が最大の要因となっていることが確認できる．

表 9 ランダムフォレスト(左)とロジスティック回帰(右)の予測精度

		予測 0	予測 1	Accuracy
実測	0	95	27	77.9%
	1	36	87	70.7%
Total				74.3%

		予測 0	予測 1	Accuracy
実測	0	96	26	78.7%
	1	32	91	74.0%
Total				76.3%

表 10 ジニ係数の平均減少量とオッズ比

No	Ectracted Factor	Random Forest Mean Decrease Gini	Logistic Regression Odds rate	p-value	
1	EF_01_Safety	20.7	0.9	0.3	
2	EF_02_Material	21.8	0.9	0.4	
3	EF_03_Warranty	11.0	1.0	0.5	
4	EF_04_Innovative	12.0	1.3	0.0	**
5	EF_05_Design	11.4	1.4	0.0	***
6	EF_06_Durability	7.9	1.7	0.0	***
7	EF_07_Technology	16.8	3.4	0.0	***
8	EF_08_Reputation	24.7	4.0	0.0	***

'***' 0.001 '**' 0.01 '*' 0.05

オッズ比を見ると，統計的に有意になった変数は，機能的価値では EF_06_Durability，意味的価値では EF_05_Design，EF_07_ Technology of Innovative & Comfortable(表中では省略して記載)，EF_08_Reputation である．つまり，壊れてはいけないが，それに加えてデザインや快適さ，評判が重要であることがわかる．したがって，3 章で述べた「品質イメージの形成要因として，意味的価値が重要である」という仮説は支持された．

5. おわりに

本研究の貢献は，複雑かつ抽象的と称される，品質というブランドイメージを対象に，顧客の知覚上におけるトップブランドを抽出し，その形成要因を定量的に評価したことである．顧客の声から抽出した構成因子は，Safety，Durability といった機能的価値が根幹をなしているが，Garvin の品質要素では明確に論じられていなかった，Innovative 等の意味的価値が含まれることを確認した．さらに，品質ブランドイメージの形成要因をランダムフォレストとロジスティック回帰分析で評価した結果，壊れてはいけないが，それに加えてデザイン性や快適性，評判が重要であることが把握できた．その中で，最も影響力のある因子は，評判であった．企業のブランド戦略において，目指すブランドイメージを一貫して醸成するには，本研究で提案したように当該イメージの形成要因を定量評価することが重要である．

参考文献

[Aaker 91] Aaker, D. A：Managing Brand Equity ―Capitalizing on the Value of a Brand Name, The Free Press New York, 206 (1991)

[Aaker 96] Aaker, D. A：Building strong brands, A diviision of Simon and Cluster Inc. New York (1996)

[Aaker 97] Aaker, J.L：Dimensions of brand personality, Journal of marketing research, pp. 347-356 (1997)

[Aaker 13] Aaker，D．A ： Brand Equity & Advertising: Advertising's Role in Building Strong Brands，Psychology Press, pp.143-161 (2013)

[Adams 12] Adams, J：Good Products, Bad Products ―Essential Elements to Achieving Superior Quality，McGraw-Hill Education (2012)

[Christensen 05] Christensen, C., Cook, S., Hall, T, Marketing malpractice: the cause and the cure, Harvard business review, 83(12), pp. 74-83 (2005)

[Garvin 87] Garvin, D. A：Competing on the Eight Dimensions of Quality，Harvard Business Review，NOVEMBER－DECEMBER (1987)

[Harada 15]Harada，T，et al．: The Estimate Method of the Omission of Japanese Inquiry Texts using an LDA Algorithm, International Journal of Computer Applications in Technology 52. 2-3, pp. 186-195 (2015)

[青木ら 97] 青木幸弘，亀井昭宏，小川孔輔，田中洋，最新ブランド・マネジメント体系―理論から広告戦略まで，日経広告研究所，pp. 149-173 (1997)

[土屋ら 14] 土屋誠司，鈴木基之，芋野美紗子，吉村枝里子，渡部広一，口語表現に対応した知識ベースと連想メカニズムによる感情判断手法．人工知能学会論文誌 29(1)，pp.11-20 (2014)

[延岡 06] 延岡健太郎，意味的価値の創造 コモディティ化を回避するものづくり，國民經濟雜誌，194(6)，pp.1-14 (2006)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

ソーシャルボットの検出：言語非依存性の特徴量とボット集団の定量化

Detection of Social Bots: Quantification of Language Independent Features and Bot Clusters

杉森 真樹 *1　笹原 和俊 *1 *2　時田 恵一郎 *1
Masaki Sugimori　Kazutoshi Sasahara　Kei Tokita

*1 名古屋大学大学院情報学研究科　*2 JST さきがけ
Graduate School of Informatics, Nagoya University　JST, PRESTO

With the advent of social media, social bots—computer programs that automatically post news—have become popular, and some of these have been purposefully used to disseminate fake news. This is an increasingly serious problem in the digital era. Although a lot of bot detection methods have been proposed, such methods often cannot overcome their language dependencies and fail to find bot clusters. This research aims at constructing a language-independent method for detecting social bots and their clusters on Twitter using machine learning. The results provide new information available for the development of such methods.

1. 導入

近年, Twitter や Facebook といったソーシャルメディアが普及し, 単なるコミュニケーションのツールにとどまらず, 様々な目的に利用されるようになり, 社会において重要な役割を果たすようになっている. このような背景のもと, コンピュータープログラムによって自動化された「ソーシャルボット」と呼ばれるアカウントによって引き起こされる様々な悪影響が大きな問題となっている [Ferrara 16].

ソーシャルボットが引き起こす問題には次のようなものがある.

- **スパムの拡散**：従来のスパムと同様に, 一般ユーザーに対して有害な Web ページへのリンクをクリックさせ, 特定の Web ページにアクセスさせたり, マルウェアに感染させることを目的とする.
- **人気の操作**：ソーシャルボットの投稿によってソーシャルメディアのトレンド (話題となっているキーワード) が影響を受ける可能性がある. また, 特定のアクティビティを集中的に行うことで, 特定のユーザーや商品などが人気, 影響力があるように見せかけることができる. これは, マーケティングなどに悪影響を及ぼすことが考えられる.
- **意見の操作**：ソーシャルボットによるフェイクニュースなどの拡散により, 特定の対象に関する人々の印象を操作しようとする可能性がある. 具体的な例としては選挙が挙げられ, 2016 年のアメリカ合衆国大統領選挙では, フェイクニュースなどが大量に発信されており, 選挙に影響を及ぼしていた可能性がある [Bessi 16].
- **市場の操作**：ソーシャルボットによるフェイクニュースの拡散により, 株式市場などの動向が操作される可能性がある. 2013 年には, テロに関するフェイクニュースによって, 一時的にダウ工業株 30 種平均が約 140 ドル急落した. また, ほとんど資産価値のない企業の株価を高騰させようとするソーシャルボットの動きが確認されている [Ferrara 16].

連絡先: 杉森 真樹, 名古屋大学大学院情報学研究科,
〒 464-8601 名古屋市千種区不老町, sugimori@nagoya-u.jp

このような様々な悪影響をもたらすソーシャルボットを検出して, ユーザーに注意を喚起し, ソーシャルメディアから排除するために, ボットの特性や検出手法, 情報の拡散過程などについて様々な研究を行っていく必要がある.

2. 関連研究

ソーシャルメディアの普及と発展に伴い, ボットがもたらす悪影響は大きな問題を引き起こしており, 様々な先行研究が行われている.

(1) 単体のアカウントを対象とした観察的手法

Varol らは, Twitter の英語アカウントを対象として, 1150 個の特徴量と機械学習を用いて, AUC 値が 0.94 という高精度な分類モデルを構築した. 彼らは, この分類モデルを応用して, アカウントがボットであるかどうかのスコアを [0〜1] の範囲で算出する “Botometer” というシステムを開発し, 公開している [Varol 17, Davis 16]. Chu らは, 半自動化されているアカウントを「サイボーグ」と定義し, 機械学習を用いて, 人間, ボット, サイボーグの 3 クラスの分類に取り組んでいる [Chu 10, Chu 12].

(2) ボットの集団を対象とした観察的手法

Abokhodair らは, シリア内戦に関する情報を拡散しているボットの集団を対象として, ボットの集団の構造や成長過程, ソーシャルメディア上の議論に与えた影響などを調査した [Abokhodair 16]. Chavoshi らは, アカウント同士の過度に同期的な活動に注目して, 学習用のデータを必要としないボット検出手法を提案するとともに, “DeBot” というボット検出システムを開発, 公開している [Chavoshi 16a, Chavoshi 16b, Chavoshi 17a, Chavoshi 17b].

(3) 単体のアカウントを対象とした実験的手法

Freitas らは, それぞれ異なる特徴と戦略を持つ 120 個のボットアカウントを作成し, これらが Twitter 上のコミュニティに侵入する過程や結果について調査を行なった. その結果, 単純なメカニズムを採用しているボットであってもコミュニティに侵入することができ, 必ずしも複雑なメカニズムを必要としないことを示した [Freitas 15].

(4) ボットの集団を対象とした実験的手法

Boshmaf らは, ボットの集団による活動を想定して, 102 個のボットアカウントと 1 個のマスターアカウントからなるボットの集団のプロトタイプを構築し, これを Facebook 上で稼働させて, ボットの集団がもたらす影響とソーシャルメディアの脆弱性を調査した [Boshmaf 11, Boshmaf 13].

ソーシャルボットの性質の調査や検出方法については様々な先行研究が行われている. しかし, ソーシャルメディアには世界中に多くのユーザーが存在し, 多様な言語が利用されているにもかかわらず, ボット検出に関する研究において, 言語の違いに注目した研究はほとんど行われていない. また, 単体のボットよりも大きな影響を及ぼす可能性があるボット集団を検出する手法の研究はほとんど行われていない.

そこで本研究では, Varol らによる Botometer に関する研究 [Varol 17] を主に参考にして, Twitter を対象として英語と日本語それぞれの言語において, ボット検出に関連する重要な特徴量について比較, 分析を行う. そして, 言語に依存しないユニバーサルなボット検出手法について検討を行う. さらに, 特徴量の組の分布に注目して, ボット集団を対象とする機械学習を用いた検出手法について検討を行う.

3. データ

本研究では, Twitter アカウントが持つ様々な特徴量と機械学習を用いて, 分類モデルを構築する. 分類モデルを訓練するために, 学習用のデータとして, 各アカウントのメタデータと連続した一定量のツイートから算出した特徴ベクトルと人間かボットかを事前に判別した正解ラベルが必要となる. 先述した Botometer による分類が正しいと仮定し, 正解ラベルの作成には Botometer を利用した. 日本語アカウントの分類には, 言語的な特徴を無視したスコアを利用した.

データを収集するにあたり, 英語または日本語で投稿を行なった Twitter アカウントの最新 200 件の投稿を収集し, 特徴ベクトルと正解ラベルを算出した. 最新の投稿 200 件を対象とするのは, API 制限のためであり, 先行研究においても最新の 200 件以降の投稿は対象とされていない. 2017/12/7〜2018/1/4 の期間, 英語についてはボット 12193 件と人間 73616 件, 日本語についてはボット 8951 件と人間 63866 件のアカウントのデータを収集した.

英語については, ボット 12193 件と無作為抽出した人間 12193 件の合計 24386 件を用いて, 言語ごとの分類モデルを構築する. 日本語については, ボット 8951 件と無作為抽出した人間 8951 件の合計 17902 件を用いて, 言語ごとの分類モデルを構築する.

4. 結果

4.1 分類モデル

本研究では, 先行研究 [Varol 17, Chu 10, Chu 12] で利用されている特徴量と独自の特徴量の中から, 次のリストに示した 4 つの特徴クラス, 326 個の特徴量を利用する.

分類モデルの構築には “scikit-learn” [Pedregosa 11] を利用し, 機械学習のアルゴリズムはランダムフォレストを採用する [Breiman 01]. これは, 先行研究においてランダムフォレストを利用した場合の精度が最も高いことに加え [Varol 17, Lee 11], 特徴量の重要度を導出することができるためである.

英語と日本語それぞれについて, アカウントが人間であるかボットであるかを判別する分類モデルを特徴クラスごとに構築する. 精度の指標には AUC を採用する.

1 コンテンツクラス

- 1-1 品詞の出現頻度[1][2]
- 1-2 品詞の割合[1][2]
- 1-3 単語の総数[1]
- 1-4 単語の種類の数[1]
- 1-5 単語のエントロピー[1]

2 メタデータクラス

- 2-1 スクリーンネーム（登録名）の長さ
- 2-2 スクリーンネームに含まれる数字の個数
- 2-3 タイムオフセット
- 2-4 アカウントの日齢
- 2-5 自己紹介文の長さ
- 2-6 自己紹介文中に URL を含むか
- 2-7 フォロー数
- 2-8 フォロワー数
- 2-9 お気に入りの数
- 2-10 プロファイルがデフォルトのままか
- 2-11 プロファイルイメージがデフォルトのままか
- 2-12 投稿数（総数, 1 時間あたりの数）
- 2-13 通常のツイート数（最新 200 件）（総数, 1 時間あたりの数）
- 2-14 リツイート数（最新 200 件）（総数, 1 時間あたりの数）
- 2-15 メンション数（最新 200 件）（総数, 1 時間あたりの数）
- 2-16 リプライ数（最新 200 件）（総数, 1 時間あたりの数）
- 2-17 リツイートされた数（最新 200 件）（総数, 1 時間あたりの数）
- 2-18 リツイートされた数（最新 200 件）[1]
- 2-19 お気に入りされた数（最新 200 件）[1]
- 2-20 メンションした数（最新 200 件）[1]
- 2-21 URL 数（最新 200 件）[1]
- 2-22 ハッシュタグ数（最新 200 件）[1]
- 2-23 メディア数（画像数+動画数）（最新 200 件）[1]
- 2-24 画像数（最新 200 件）[1]
- 2-25 動画数（最新 200 件）[1]
- 2-26 投稿元に関する指標（最新 200 件）[1][3]
- 2-27 フォロー比
- 2-28 フォロワー比
- 2-29 リストされている数

3 タイミングクラス

- 3-1 通常のツイートの投稿時間間隔（分）[1]
- 3-2 リツイートの投稿時間間隔（分）[1]
- 3-3 リプライの投稿時間間隔（分）[1]
- 3-4 メンションの投稿時間間隔（分）[1]
- 3-5 投稿の時間間隔（分）[1]

4 ネットワーククラス（ハッシュタグ共起ネットワーク）

- 4-1 ノード数
- 4-2 エッジ数
- 4-3 ネットワークの密度
- 4-4 ネットワークの強度[1]
- 4-5 クラスタリング係数[1]

注釈
[1] [最小値, 最大値, 中央値, 平均, 標準偏差, 歪度, 尖度, エントロピー] を算出し, 特徴量とする.
[2] 品詞は, 英語 [名詞, 動詞, 形容詞, 副詞, 助動詞, 限定詞, 間投詞, Wh-, 代名詞], 日本語 [名詞, 動詞, 形容詞, 副詞, 助動詞, 助詞, 接続詞, 感動詞, 接頭詞] を考慮する.
[3] 投稿元に関する指標については, 各投稿において, 自動化が行われていないと思われる投稿元の値を 1, 自動化が行われていると思われる投稿元の値を-1, それ以外の値を 0 とする.

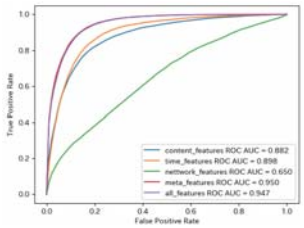


図 1-a：分類モデルの精度（英語）

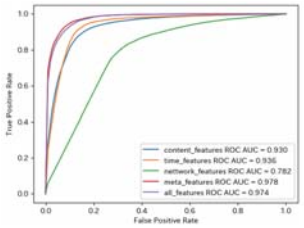


図 1-b：分類モデルの精度（日本語）

図 1-a と b を見ると, 英語と日本語の双方のアカウントにおいて, メタデータクラスが最も高い精度を示しており, コンテンツクラスとタイミングクラスがこれに続いていることが分かる. 一方で, ネットワーククラスはある程度の精度を示しているが, 他のクラスと比較すると精度が低いことが分かる.

また, コンテンツクラスの特徴量よりもメタデータクラスとタイミングクラスの特徴量が高い精度を示していることから, 言語に依存しないユニバーサルな分類モデルにおいて, コンテンツクラスの特徴量を考慮せずとも高い精度を示すことは可能であると考えられる.

4.2 重要な特徴量

主に 2 つの手法を用いて, 英語と日本語それぞれの分類モデルにおいて重要な特徴量の選択を行う.

(1) 分類モデルにおける特徴量の重要度の測定
ランダムフォレストを用いた分類モデルにおける特徴量の重要度を, 決定木ごとにその特徴量によって減少する基準値（ジニ不純度）の平均として算出する.

(2) 人間とボットの特徴量の分布が異なるかどうかの判定
コルモゴロフ・スミルノフ検定（KS 検定）によって, 人間とボットで特徴量の分布が異なることを確認する.

重要な特徴量を特定するための手順としては, 分類モデルにおいて重要度が高い特徴量を 50 個選択し, その中で人間とボットで分布が異なっていることが確認できたものを重要な特徴量とする.

また, 双方の言語の分類モデルで共通している重要な特徴量の中でも, 2 つの言語を統合した場合でも, KS 検定によって人間とボットで分布が異なっていることが確認できた特徴量を言語に依存しない重要な特徴量とする.

4.3 言語非依存の分類モデル

言語に依存しないユニバーサルな分類モデルの構築について検討を行うために, 英語と日本語について言語に依存しない分類モデルの構築を行う. また, この分類モデルが学習用のデータ以外に有用であるか検証を行う.

英語と日本語について言語に依存しない分類モデルの構築にあたり, 言語に依存しない重要な特徴量の中で, 後に行う分類モデルの検証において, 精度を大きく低下させていた特徴量や, 共通したデータやアクティビティに基づく特徴量の中で重要度が低い一部の特徴量は利用しないものとする. 最終的には, 次のリストに示した 20 個の特徴量を用いて分類モデルを構築する.

この分類モデルの構築には, 学習用のデータから英語と日本語それぞれについて無作為抽出した, ボット 8000 件, 人間 8000 件の計 32000 件を用いる. 精度については, クロスバリデーション（10 分割）を利用して, 平均 AUC を測定する.

結果として, この分類モデルの平均 AUC の値は約 0.95 となり, 先行研究や全 326 個の特徴量を考慮した言語ごとの分類モデルとほぼ同等の精度を有することが確認できた.

- コンテンツクラス
  - 単語のエントロピーの標準偏差
- メタデータクラス
  - リプライの総数
  - リツイートの総数
  - 被リツイートの総数
  - 被リツイート数の最大値, 平均, 標準偏差
  - 被お気に入り数の平均
  - メンション数の標準偏差
  - URL 数の平均
  - ハッシュタグ数の平均
- タイミングクラス
  - リツイートの時間間隔の最大値, 中央値, 平均, エントロピー
  - リプライの時間間隔の最大値, 中央値, 平均, エントロピー
  - 全投稿の時間間隔のエントロピー

分類モデルが学習用のデータ以外のデータに対しても, 同様の精度で分類を行えることを確認するために, 検証用のデータとして英語と日本語それぞれについて手動で正解ラベルを作成した, ボット 250 件, 人間 250 件ずつ, 計 1000 件のデータを用意する.（手動による分類は正しいと仮定する.）

検証の結果, 1000 件のうち約 95%のアカウントを正しく分類できることが確認でき, 英語と日本語について言語に依存しない分類モデルを構築できたと結論づけることができる.

このように, 英語と日本語について言語に依存しない分類モデルを構築することができたことから, 他の言語についても同様の研究を行うことで言語に依存しないユニバーサルな分類モデルの構築は可能であると考えられる.

4.4 ボット集団

ソーシャルボットの検出に関する先行研究の多くは, 単体のボットを対象とするものであった. しかし, ソーシャルボットの集団は相互作用することで, 単体のボットよりも大規模な問題を引き起こす可能性がある. そのため, ボット集団の検出についても検討を行う必要がある.

ボット集団は, マスター（製作者または操作者）によって, 共通の目的のために製作または操作されることから, 同一のコンピュータープログラムに基づいて活動していると考えられる. そのため, 複数の特徴量が近い値をとることが予測される. 本研究では, この複数の特徴量が近い値をとることに注目して, 特徴量の組の分布を確認するとともに, クラスタリングを行うことで特徴量の組について分析を行い, ボットの集団が検出できるか検証を行う. なお, クラスタリングのアルゴリズムには, 密度（距離）に注目したアルゴリズムである DBSCAN [Ester 96] を採用する.

図 2 は, 学習用データに含まれる全てのボットアカウントを対象とした, 投稿に含まれる URL 数の平均と投稿間隔のエントロピーの 2 つの特徴量の組の散布図とクラスタリング（DBSCAN）の結果を示したものであり, 特徴量の組の分布が集中している複数の領域が存在していることが確認できる.

これらの分布が集中している領域の中でも, 本来は分布が集中しにくい領域がボット集団の存在を示唆していると考え, 実際に確認を行った. その結果, 日本の芸能, ゴシップニュースを拡散しているボットの集団が確認された（図 2：青色）.

このように, 特徴量の組の分布に注目してクラスタリング（DBSCAN）を行い, 不自然に分布が集中している領域を特定することで, ソーシャルボットの集団を検出することができた. このことから, 複数の特徴量に注目することで, ボット集団の検出が可能であると考えられる.

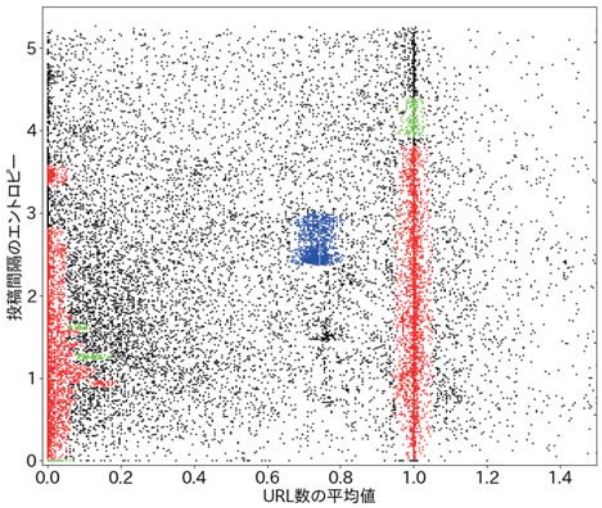


図 2：URL 数の平均と投稿間隔のエントロピー（散布図）

赤：1000 個以上のアカウントからなるクラスタ
緑：1000 個未満, 50 個以上のアカウントからなるクラスタ
青：緑のクラスタの中でボットの集団の存在が確認できたもの

今後は, ボットの集団の検出に利用可能な特徴量やクラスタリングを行う上で最適なパラメーターなどについてさらなる調査を行うことで, 複数の特徴量とクラスタリングを用いたソーシャルボットの集団を対象とする検出手法の構築に取り組む.

5. 結論

ソーシャルメディアには世界中に多くのユーザーが存在し, 多様な言語が利用されているにもかかわらず, ソーシャルボットの検出手法において, 言語の違いに注目した研究が行われていなかった. また, ソーシャルボットの集団は相互作用し, 単体のボットよりも大規模な問題を引き起こす可能性があるにもかかわらず, ソーシャルボット集団の検出手法に関する研究がほとんど行われていなかった.

そこで本研究では, 言語に依存しないユニバーサルな分類モデルの構築について検討を行うとともに, ソーシャルボットの集団を対象とする新たな検出手法について検討を行った. 結果として, 英語と日本語を対象とした分類モデルにおいて, 言語に依存しない重要な特徴量を特定し, これらの特徴量を利用して英語と日本語の双方の言語に対して精度の高い分類モデルを構築することで, 言語に依存しないユニバーサルな分類モデルを構築できる可能性を示した. また, 単体のソーシャルボットの検出手法で利用されている特徴量の組の分布に注目し, クラスタリングを行うことでソーシャルボットの集団を検出できることを確認した.

今後は, 言語に依存しないユニバーサルな分類モデルの構築に取り組むとともに, ソーシャルボットの集団を対象とする検出手法について, より詳細な調査と検討を行う.

謝辞

本研究は JSPS 科研費 (JP16K16112, JP17H06383), JST さきがけ (JPMJPR16D6), JST CREST(JPMJCR17A4) の助成を受けたものです.

参考文献

[Abokhodair 16] Abokhodair, N., Yoo, D., and McDonald, D. W.: Dissecting a Social Botnet: Growth, Content and Influence in Twitter, in *Proceedings of the 18th ACM Conference on Computer Supported Cooperative Work & Social Computing* (2016)

[Bessi 16] Bessi, A. and Ferrara, E.: Social bots distort the 2016 U.S. Presidential election online discussion, in *First Monday* (2016)

[Boshmaf 11] Boshmaf, Y., Muslukhov, I., Beznosov, K., and Ripeanu, M.: The Socialbot Network: When Bots Socialize for Fame and Money, in *Proceedings of the 27th Annual Computer Security Applications Conference* (2011)

[Boshmaf 13] Boshmaf, Y., Muslukhov, I., Beznosov, K., and Ripeanu, M.: Design and Analysis of a Social Botnet, in *Computer Networks: The International Journal of Computer and Telecommunications Networking* (2013)

[Breiman 01] Breiman, L.: Random Forests, in *Machine Learning* (2001)

[Chavoshi 16a] Chavoshi, N., Hamooni, H., and Mueen, A.: DeBot: Twitter Bot Detection via Warped Correlation, in *IEEE 16th International Conference on Data Mining* (2016)

[Chavoshi 16b] Chavoshi, N., Hamooni, H., and Mueen, A.: Identifying Correlated Bots in Twitter, in *International Conference on Social Informatics* (2016)

[Chavoshi 17a] Chavoshi, N., Hamooni, H., and Mueen, A.: On-Demand Bot Detection and Archival System, in *Proceedings of the 26th International Conference on World Wide Web Companion* (2017)

[Chavoshi 17b] Chavoshi, N., Hamooni, H., and Mueen, A.: Temporal Patterns in Bot Activities, in *Proceedings of the 26th International Conference on World Wide Web Companion* (2017)

[Chu 10] Chu, Z., Gianvecchio, S., Wang, H., and Jajodia, S.: Who is Tweeting on Twitter: Human, Bot, or Cyborg, in *Proceedings of the 26th Annual Computer Security Applications Conference* (2010)

[Chu 12] Chu, Z., Gianvecchio, S., Wang, H., and Jajodia, S.: Detecting Automation of Twitter Accounts:Are You a Human, Bot, or Cyborg?, in *IEEE Transactions on Dependable and Secure Computing* (2012)

[Davis 16] Davis, C. A., Varol, O., Ferrara, E., Flammini, A., and Menczer, F.: BotOrNot: A System to Evaluate Social Bots, in *Proceedings of the 25th International Conference Companion on World Wide Web* (2016)

[Ester 96] Ester, M., Kriegel, H. P., Sander, J., and Xu, X.: A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise, in *Proceedings of the Second International Conference on Knowledge Discovery and Data Mining* (1996)

[Ferrara 16] Ferrara, E., Varol, O., Davis, C. A., Menczer, F., and Flammini, A.: The Rise of Social Bots, in *Communications of the ACM* (2016)

[Freitas 15] Freitas, C. A., Benevenuto, F., Ghosh, S., and Veloso, A.: Reverse Engineering Socialbot Infiltration Strategies in Twitter, in *Proceedings of the 2015 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining* (2015)

[Lee 11] Lee, K., Eoff, B. D., and Caverlee, J.: Seven Months with the Devils: A Long-Term Study of Content Polluters on Twitter, in *Proceedings of the Fifth International AAAI Conference on Weblogs and Social Media* (2011)

[Pedregosa 11] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., and Duchesnay, É.: Scikit-learn: Machine and Learning in Python, in *Journal of Machine Learning Research Scikit-learn: Machine and Learning in Python* (2011)

[Varol 17] Varol, O., Ferrara, E., Davis, C. A., Menczer, F., and Flammini, A.: Online Human-Bot Interactions: Detection, Estimation, and Characterization, in *Proceedings of the Eleventh International AAAI Conference on Web and Social Media* (2017)

[1P3] [General Session] 3. Data Mining

座長:岡田 将吾（北陸先端科学技術大学院大学）

Tue. Jun 5, 2018 5:20 PM - 7:00 PM Room P (4F Emerald Lobby)

[1P3-01] Twitter Actuates the Cryptocurrency Market

○Koichiro Tamura[1], Shohei Ohsawa[1], Yutaka Matsuo[1] （1. The University of Tokyo）

5:20 PM - 5:40 PM

[1P3-02] Finding Representatives via Nearest Neighbor Based Binarization and Frequent Pattern Mining

○Yuka Yoneda[1], Mahito Sugiyama[2], Takashi Washio[1] （1. The Institute of Scientific and Industrial Research , 2. National Institute of Informatics）

5:40 PM - 6:00 PM

[1P3-03] Inference of Local Feature Correlations by Hints

HongJie ZHAI[1], ○Makoto HARAGUCHI[1], Hideyuki IMAI[1] （1. Hokkaido University）

6:00 PM - 6:20 PM

[1P3-04] Studies on Normal Boiling Point of Chemical Substances and Eigen Values of Their Molecular Matrices

○Kiryu Yamashita[1], Yoshimasa Takahashi[1], Tetsuo Katsuragi[1] （1. Graduate School of Engineering , Toyohashi University of Technology）

6:20 PM - 6:40 PM

[1P3-05] Extraction of the operational skills by analysis of CAD operation log

○KEISUKE NIIMI[1], Akio Sotoike[1], Tatsuya Arisato[1] （1. Toyota Motor Corporation）

6:40 PM - 7:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

Twitterから仮想通貨市場に対する作用の分析

Twitter Actuates the Cryptocurrency Market

田村浩一郎　大澤昇平　松尾豊
Koichiro Tamura　Shohei Ohsawa　Yutaka Matsuo

東京大学大学院 工学系研究科 技術経営戦略学専攻
Department of Technology Management for Innovation, The University of Tokyo

Social media is not only a sensor but also an actuator. A *social sensor* can detect various social phenomena or trends by using the data obtained from social media. Though the information from social sensors has vastly enhanced our potential to observe and predict real-world phenomena, the causality from the social media itself to the real world has not been studied to date. Meanwhile, recent trends in SNS-driven consumer behavior, such as taking beautiful photos for Instagram, so-called "Instagenic," have further highlighted the importance of studying the causality from social media to the real world. This paper demonstrates a new concept of *social actuator*. We introduce internal states, which represent the states of the social media users influenced by others, and show how to address the confounding structure in the inference of causality from social media to the real world. Using the results of our experiments on Twitter data and cryptocurrency-market data, we show that our proposed method can detect the influences between the users on social media, and describe the causation from Twitter to the cryptocurrency market. Finally, we discuss the effectiveness of the proposed method for different datasets and suggest that we all have the potential to impact the real world through social media either intentionally or unintentionally.

1. 序論

ソーシャルメディアは，ソーシャルセンサ [Sakaki 10] としての機能を持つだけでなく，アクチュエーターとしての機能も持っている．ソーシャルセンサは様々な社会現象やトレンドなどを，ソーシャルメディアにおける投稿やお気に入りといった情報を用いることで検知する [Sakaki 10]．その一方で，近年，インスタグラムに投稿するための見栄えの良い写真，所謂「インスタ映え」する写真を取るために消費行動が観測されている．また，投資家は他の投資家のツイートを元に投資判断を行い，株価が特定のユーザーのツイートに連動している可能性も述べられている [Oda 18]．この研究は，ソーシャルメディアが実世界に作用するソーシャルアクチュエーターとして機能しているという仮説を実証することを目的とする．

実世界の観測や予測を行う際に，social sensor によって観測されたデータの有用性や，実世界のデータとの相関が議論されていた [Sakaki 10, Tumasjan 10, Asur 10, Bollen 11, Kristoufek 13] が，social media から実世界の現象に対する因果については十分に議論されて来なかった．social media と対象としている実世界の事象の双方に介入する交絡因子が存在する場合，social media と対象とする実世界の事象の関係は疑似相関である可能性がある．例えば [Kristoufek 13] では，google trend と bitcoin market の値の双方向の関係性が存在していることが示されているが，Bitcoin について google で検索したから価格が変動したのではなく，Google trend が Bitcoin market に影響を与え得る実世界の trend を反映しているにすぎず，google trend から Bitcoin に対する因果関係については疑似相関である可能性が考えられる．

そこで本研究は，Twitter から現実世界に対する因果関係を検証するための手法を提案する．そして 9401 人の twitter users を対象に，2017-01-01 から 2017-12-31 までの tweet および follow/followee 関係と，cryptocurrency market の値を用いて実験を行い，提案手法を用いた将来の cryptocurrency market value の予測精度がいくつかのベースラインを上回る精度であることを示した．そしてその結果より，twitter における internal states が，cryptocurrency market に対して働きかけていることを説明した．

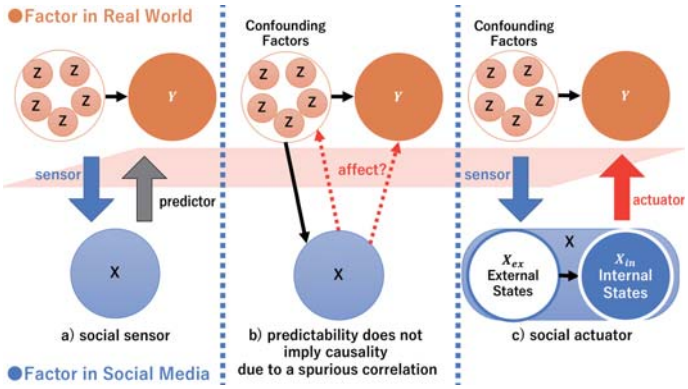


図 1: A new concept of social actuator

本研究の貢献は以下の通り．

- 提案手法が，twitter 内におけるリツイートなどの直接観測される interaction だけでなく，直接観測することができないユーザー間の影響を考慮し，学習の枠組みの中でユーザー間の影響度を獲得できるものであることを示した．
- Twitter における他者の post から影響を受けて蓄積された実世界に働きかける *social motivation* が，cryptocurrency market に働きかけていることを示唆し，social media を通して誰もが実世界にインパクトを与えうる可能性を提示した．

連絡先: 田村浩一郎，東京大学大学院工学系研究科，koichirot11@weblab.t.u-tokyo.ac.jp

2. 関連研究

2.1 Social Sensor

2000 年代後半，Twitter や Facebook と行ったソーシャルメディアが登場した．スマートフォンの普及と共に,「人々は，実世界に情報端末をもち出し，そこで起こった出来事や感じたことをソーシャルメディアに投稿するようになったため，社会や実世界で起きていることが計算機に記録されるようになった．このことは，社会現象の実態やその発生メカニズムを解明しようとしてきた社会学において，貴重なデータ資源になることになった」[Hijikata 16]．ソーシャルメディアにおけるユーザーの投稿や，投稿に対する「いいね」などの反応によって，ユーザーの興味や関心を観測することが可能になり,「社会で起こりつつあるイベントやトレンド，現象などを検出する」[Hijikata 16]「ソーシャルセンサ」[Sakaki 10] としての役割を果たしている．ソーシャルセンサを用いて実世界の現象の観測や予測を行う研究は数多くなされていた [Sakaki 10, Tumasjan 10, Asur 10, Bollen 11, Kristoufek 13, Zhang 11]．しかしこれらの既存研究は，ソーシャルメディアが実世界に影響を与えるという因果関係を議論していない．

2.2 Information Diffusion on Social Network

ソーシャルメディアは，任意のユーザーがそこでの出来事や感じたことを投稿するという特徴に加えて，ユーザー間でネットワークを構成し，社会相互しているという特徴がある．「Twitter や Facebook などのソーシャルメディアが普及し，そこで構築された友人関係のネットワークは，本物の人間のつながりを表したものと認識される」[Hijikata 16] ようになり，実世界では直接観測することが難しい友人関係のネットワークを分析することが可能になったことから，ソーシャルメディアで構築されるネットワークに関する研究も多くなされ，情報拡散 (information diffusion) を行うメディアとしての強力さを示すこととなった」[Hijikata 16]．ソーシャルネットワークにおける情報拡散の一つに，information cascades[Zafarani 14] があげられる．iinformation cascades は”An information cascade describes the process of diffusion when individuals merely observe their immediate neighbors” [Zafarani 14] と定義され，information cascades を予測する研究 [Li 17, Cheng 14, Budak 11] がなされている．しかしこれらの研究は，ソーシャルメディア内部での情報拡散を対象としたものであり，実世界との関係を分析した研究は筆者の知る限り存在していない．

3. 提案手法

本研究は，以下の手法を提案し，Twitter から実世界に対する因果関係を実証することを試みる．

1. figure 1 で表されるように，social media の要素を以下の 2 つの因子に分解し表現する

   external states social sensor によって観測されるユーザーの投稿などを表す因子 X_{ex}

   internal states 他のユーザーから受ける影響が蓄積されたユーザーの内部状態を表す因子 X_{in}

2. 対象としている将来の実世界の事象 Y の予測において，以下の 2 つの手法を比較し，Granger causality の存在の有無を確かめる

   - 対象としている実世界の事象 Y と X_{ex} を入力とする回帰モデル

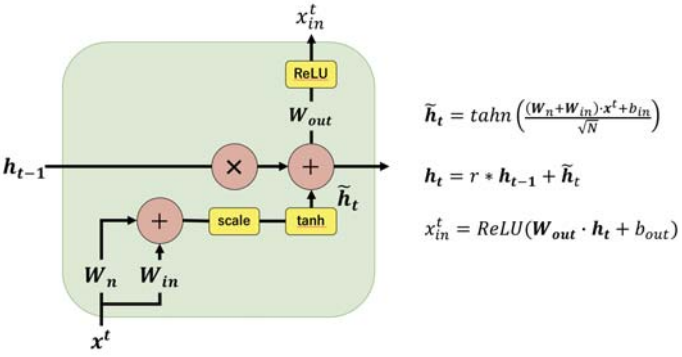


図 2: Social Internal States Module

   - 対象としている実世界の事象 Y と X_{ex} および X_{in} を入力とする回帰モデル

この時，social media に対する external states は実世界の要因 Y や交絡要因 Z に影響を受けるのに対して，短期的には social media 内での internal states は，ユーザーの投稿などの external states にのみ介入を受けると仮定できる時，因果の逆転や疑似相関の可能性を否定し，Granger causality から，internal states から対象としている将来の実世界の事象 Y に対する因果関係を示唆することができる．

3.1 Social Internal States Module

ソーシャルメディアにおけるユーザーが他のユーザーとの相互作用によって影響を受け，蓄積されたユーザーの内部状態，internal states を獲得するために，Social Internal States Module(Figure 2) を提案する．

まず，N 人のユーザーのクラスタをサンプリングし，サンプリングされたユーザー同士の follow/followee 関係を分析する．そして，follow/followee 関係に基づき，隣接行列 $\boldsymbol{W_n} \in \boldsymbol{R}^{N\times N}$ を作成する．なお，$\boldsymbol{W}_n$ の要素 $w_{ij} = 1$ である場合，$user_i$ が $user_j$ を follow していることを意味する．時刻 t において実験対象について言及する投稿を行なったユーザーを one-hot vector $\boldsymbol{x^t}$ で表現する．例えば，Bitcoin の将来の出来高を予測する場合，$user_j$ が Bitcoin について言及した投稿を行なったとき，$\boldsymbol{x_t}[j] = 1$ とする．そして，以下のようにユーザーが他のユーザーから受ける影響を表すベクトル $\tilde{\boldsymbol{h}}_t$ を計算する．

$$\tilde{\boldsymbol{h}}_t = tanh\left(\frac{(\boldsymbol{W_n} + \boldsymbol{W_{in}}) \cdot x^t + \boldsymbol{b_{in}}}{\sqrt{N}}\right),$$

なお $\boldsymbol{W_{in}} \in \boldsymbol{R}^{N\times N}$ および $\boldsymbol{b_{in}} \in \boldsymbol{R}^N$ は学習パラメタである一方，$\boldsymbol{W_n}$ は定数パラメタである．そして，再帰的アルゴリズムによってユーザーに蓄積する内部状態を以下に計算する．

$$\boldsymbol{h}_t = r * \boldsymbol{h}_{t-1} + \tilde{\boldsymbol{h}}_t,$$

$r \in \boldsymbol{R}^1$ は学習パラメタで，初期値を 0.1 とする．最後に Social Internal States Module の出力として以下を計算する．

$$x_{in} = ReLU\left(\boldsymbol{W_{out}} \cdot \boldsymbol{h}^t + b_{out}\right),$$

$\boldsymbol{W_{out}} \in \boldsymbol{R}^N$ および $b_{out} \in \boldsymbol{R}^1$ は学習パラメタである．

3.2 Comparing Regression Models

ソーシャルメディアの内部状態から現実世界への因果関係の存在を検証するために，まず，以下の 2 つの方法を比較し Granger 因果関係の存在を確認する．

Social sensor model

実世界の事象 Y を予測するために，ソーシャルセンサによって観測されるソーシャルメディアにおける事象 X_{ex} を用いた回帰モデル．

$$\hat{y} = \boldsymbol{W}_{ss} \cdot concat(\boldsymbol{x}_y, \boldsymbol{x}_{ex}) + b_{ss},$$

$\boldsymbol{x}_y$ は事象 Y を表す特徴ベクトル, $\boldsymbol{x}_{ex}$ は X_{ex} を表す特徴ベクトルであり，$\boldsymbol{W}_{ss}$ and b_{ss} は学習パラメタである．

Social actuator model

実世界の事象 Y を予測するために，ソーシャルセンサによって観測されるソーシャルメディアにおける事象 X_{ex} およびソーシャルメディアのユーザーの内部状態 X_{in} を用いた回帰モデル．

$$\hat{y} = \boldsymbol{W}_{sa} \cdot concat(\boldsymbol{x}_y, \boldsymbol{x}_{ex}, x_{in}) + b_{sa}, \qquad (1)$$

x_{in} は social internal states module から取得した X_{in} を表す特徴ベクトル, $\boldsymbol{W_{sa}}$ and b_{sa} は学習パラメタである．

social actuator model の予測が social sensor model の予測よりも正確であるとき，ソーシャルメディアの内部状態から現実世界へのグレンジャー因果関係の存在を推論することができる．

しかし，グレンジャー因果は通常の因果の必要条件にすぎず，擬似相関の可能性がある．本研究では，FIgure 1 で示されるように，ソーシャルセンサによって得られた external states の要素 X_{ex} は現実世界の対象要素 Y 以外の現実世界の交絡因子 Z に介入されるが，ソーシャルメディアの内部状態 X_{in} は短期的には external states の要素 X_{ex} のみに介入されると仮定する．これは，follow/followee や相互作用といったソーシャルメディアにおける関係性は，予測を行うような短期的な期間においては実世界の事象と独立であると考えることができるからだ．この場合，擬似相関の問題を仮想的に解決し，internal states から実世界の現象 Y に対する因果関係を述べることができる．

4. 実験

近年，ブロックチェーンという技術に基づいた仮想通貨の存在が話題になっている．現在, 仮想通貨の使い道は法定通貨に対して限られており，仮想通貨のなす経済圏の成長があるわけでもなく，また保有することによる金利なども存在していないため，現在の仮想通貨の市場はほとんどすべて需要と供給によって決定している [Kristoufek 13]．よって，ソーシャルメディアにおける影響が存在するならば，他の要因が比較的少ないため検証しやすいと考え，今回，実験対象として仮想通貨市場を取り扱う．

実験には，CoinGecko [*1] から取得した Bitcoin, Ethereum, Ripple の 3 つの仮想通貨の価格および出来高と，Twitter REST API[*2] から取得した投資家のツイートおよび follow 関係のデータを用いる．仮想通貨のデータは，2017 年 1 月 1 日から 2017 年 12 月 31 日までの一年間の価格および出来高の日足データを利用する．取得したデータから，1,3,5 日前比の出来高変化率，および 1,3,5 日前比の価格変化率を作成し，仮想通貨の情報を表す入力特徴量とする．そして，1,3,5,30 日後の出来高変化率を作成し，予測対象とする．1 月 1 日から 10 月 31 日までの約 300 データを学習データとし，11 月 1 日から 11 月 30 日までの 30 データをテストデータとして用いる．Twitter のデータは，Okasanman, one of the famous twitter accounts of investors in Japan を follow しているユーザーのうち，2016 年 9 月から 12 月までの 3ヶ月間で 5 回以上ツイートがあるアクティブユーザーでかつ follower が 100 人以上いる 9401users のアカウントを対象として，取得していた全てのツイートおよび follow/followee 関係を用いる．

そして，以下の 4 つのモデルの mean squard error(MSE) を比較検証する．

BASE: predict 0 all

常に 0 と予測を行うモデルをベースラインとする．このベースラインの MSE よりも悪い場合，そのモデルの予測は意味をなさないということになる．

$$\hat{y} = 0.$$

VAR: only cryptocurrency market values

まず，仮想通貨市場の値のみを用いた自己回帰モデル (VAE) [Toda 94] を検証する．出力として，以下を得る．

$$\hat{y} = \boldsymbol{W}_{var} \cdot \boldsymbol{x}_y + b_{var},$$

$\boldsymbol{x}_y$ は仮想通貨市場の値の入力ベクトル， $\boldsymbol{W}_{var}, b_{var}$ は学習パラメタである．

Social Sensor: with external states of Twitter

次に，ソーシャルセンサによって獲得される external states を用いた回帰モデルを検証する．予測対象となる仮想通貨に対するツイートは，それぞれ以下のワードを含むものを検出する．

Bitcoin: Bitcoin, BTC，ビットコイン

Ethereum: Ethereum, ETH，イーサリアム

Ripple: Ripple, XPR，リップル

モデルの出力は以下の通り．

$$\hat{y} = \boldsymbol{W_{ss}} \cdot concat(\boldsymbol{x}_y, \boldsymbol{x}_{ex}) + b_{ss},$$

$\boldsymbol{x}_{ex}$ は ツイート数などソーシャルセンサから得られた入力ベクトル ， $\boldsymbol{W}_{ss}, b_{ss}$ は学習パラメタである．

Information Cascades: with DeepCas pipeline

DeepCas [Li 17] は cascades graph の構造をノードをサンプリングすることで表現し，End-to-end の枠組みで cascades を予測する手法である．この手法は，ネットワークにおける関係性を表現している点で上述した internal states を表現していると考えることもできる．そこで，social internal states module の代わりに，DeepCas pipline を用いる．

得られた結果は表 1 の通り．ほとんどの場合で提案手法である Social Actuator のモデルが他のモデルよりも優れた予測を行なっている．

∗1 https://www.coingecko.com/en

∗2 https://dev.twitter.com/twitterkit/android/access-rest-api

表 1: Performance measured by MSE

	Bitcoin				Etheruem				Ripple			
	volume_1	volume_3	volume_5	volume_30	volume_1	volume_3	volume_5	volume_30	volume_1	volume_3	volume_5	volume_30
BASE	0.2335	0.4507	0.5316	0.4126	0.1865	0.5913	0.5530	1.1061	0.9345	2.0870	1.9373	**0.6639**
VAR	**0.2150**	0.3122	0.3225	0.3184	0.1639	0.3687	0.3890	1.1070	0.6279	0.7111	1.1307	1.2217
Social Sensor	0.2287	0.3551	0.3141	0.2576	0.1636	0.3679	0.3755	1.1195	0.6142	0.5660	0.9268	1.3226
Information Cascades	0.2569	1.0195	1.1131	1.4950	0.4321	0.4458	0.4088	2.8378	0.6220	1.6445	1.1410	2.4280
Social Actuator	0.2236	**0.3087**	**0.3076**	**0.2117**	**0.1489**	**0.3640**	**0.3226**	**0.9291**	**0.5570**	**0.5298**	**0.9156**	1.2951

5. 考察

実験では，VAR による手法，Socail sensor を用いて投稿数に着目した手法，information diffusion を考慮した DeepCas を用いた手法に対して，提案手法の精度が高いという結果を得た．既存の Social sensor を用いた予測手法は，実世界を観測したユーザーがソーシャルメディアに投稿することを利用して実世界の現象を間接的に観測・予測するものであって，誰が，どれくらいの数のユーザーが投稿するかということは，実世界の現象によるものだとされていた．ソーシャルセンサからの情報に加えて，Twitter の投稿者と情報の受信者の間の影響という，ソーシャルメディア内の社会相互を入力に加えた提案手法の精度が高いということは，Twitter における社会相互から仮想通貨の市場へのグレンジャー因果性が存在していることを意味する．

グレンジャー因果は通常の因果性が存在する必要条件ではあるが，十分条件ではなく，擬似相関である可能性がある．今回の実験の場合，仮想通貨の市場と Twitter における現象に対して，共通の交絡要因がある場合である．例えば，仮想通貨のマイニングに必要な電力に対する料金の変化や，新たに仮想通貨に対する規制など，ファンダメンタルズな要因が仮想通貨の市場と Twitter のユーザー双方に影響を及ぼす可能性があり，両者の交絡要因であると考えられる．本研究の提案手法の入力として追加した Twitter の投稿者と情報の受信者の間の関係において与える影響は小さいと仮定できる．なぜなら，比較的短期的な期間におけるファンダメンタルズ要因によって，Twitter における follow/followee 関係が変化する可能性は低く，user 同士の影響度が変わることは考えにくいからだ．もし Twitter における社会相互が実世界の現象と独立である場合，Twitter における社会相互から仮想通貨の市場へのグレンジャー因果性から，Twitter における社会相互と仮想通貨の市場への因果関係を推論することができる．

参考文献

[Asur 10] Asur, S. and Huberman, B. A.: Predicting the future with social media, in *Proceedings of the 2010 IEEE/WIC/ACM International Conference on Web Intelligence and Intelligent Agent Technology-Volume 01*, pp. 492–499IEEE Computer Society (2010)

[Bollen 11] Bollen, J., Mao, H., and Zeng, X.: Twitter mood predicts the stock market, *Journal of computational science*, Vol. 2, No. 1, pp. 1–8 (2011)

[Budak 11] Budak, C., Agrawal, D., and El Abbadi, A.: Structural trend analysis for online social networks, *Proceedings of the VLDB Endowment*, Vol. 4, No. 10, pp. 646–656 (2011)

[Cheng 14] Cheng, J., Adamic, L., Dow, P. A., Kleinberg, J. M., and Leskovec, J.: Can cascades be predicted?, in *Proceedings of the 23rd international conference on World wide web*, pp. 925–936ACM (2014)

[Hijikata 16] Hijikata, : 社会学と AI ー社会と人間を映すソーシャルメディアー, 人工知能学会誌, Vol. 32, No. 3 (2016)

[Kristoufek 13] Kristoufek, L.: BitCoin meets Google Trends and Wikipedia: Quantifying the relationship between phenomena of the Internet era, *Scientific reports*, Vol. 3, p. 3415 (2013)

[Li 17] Li, C., Ma, J., Guo, X., and Mei, Q.: DeepCas: An end-to-end predictor of information cascades, in *Proceedings of the 26th International Conference on World Wide Web*, pp. 577–586International World Wide Web Conferences Steering Committee (2017)

[Oda 18] Oda, S.: The Mysterious Twitter User Drawing a Swarm of Japan Traders, https://www.bloomberg.com/news/articles/2018-01-14/the-mysterious-twitter-user-attracting-a-swarm-of-japan-traders (2018)

[Sakaki 10] Sakaki, T., Okazaki, M., and Matsuo, Y.: Earthquake shakes Twitter users: real-time event detection by social sensors, in *Proceedings of the 19th international conference on World wide web*, pp. 851–860ACM (2010)

[Toda 94] Toda, H. Y. and Phillips, P. C.: Vector autoregression and causality: a theoretical overview and simulation study, *Econometric reviews*, Vol. 13, No. 2, pp. 259–285 (1994)

[Tumasjan 10] Tumasjan, A., Sprenger, T. O., Sandner, P. G., and Welpe, I. M.: Predicting elections with twitter: What 140 characters reveal about political sentiment., *Icwsm*, Vol. 10, No. 1, pp. 178–185 (2010)

[Zafarani 14] Zafarani, R., Abbasi, M. A., and Liu, H.: *Social media mining: an introduction*, Cambridge University Press (2014)

[Zhang 11] Zhang, X., Fuehres, H., and Gloor, P. A.: Predicting stock market indicators through twitter “I hope it is not as bad as I fear”, *Procedia-Social and Behavioral Sciences*, Vol. 26, pp. 55–62 (2011)

近傍法による2値化と頻出パターンマイニングを用いた代表点抽出

Finding Representatives via Nearest Neighbor Based Binarization and Frequent Pattern Mining

米田 友花 *1　杉山 麿人 *2　鷲尾 隆 *1
Yuka Yoneda　Mahito Sugiyama　Takashi Washio

*1大阪大学産業科学研究所
The Institute of Scientific and Industrial Research
*2国立情報学研究所
National Institute of Informatics

We propose to find representative data points from continuous data via a two-step procedure: We first binarize data points based on the nearest neighbor search, followed by performing frequent pattern mining on the binarized data. Since frequent patterns correspond to combinations of data points shared by many other data points as their neighbors, they are expected to well summarize the entire dataset. We empirically show that representative data points detected by our method have competitive quality with random sampling in the classification scenario.

1. はじめに

機械学習技術を用いた大量データの解析が，様々な分野で盛んに行われている [3]．例えば，センサーによって温度や心拍数などを連続値データとして大量に取得し，製品開発に役立てることができる．大量のデータを解析することで初めて分かる変数間の関係性など，それまでの人の手による解析では得られなかった知見を得ることができる可能性がある．しかし，大量データ解析には，大きく二つの問題点がある．(1) 取得したデータが大きくなるほど，計算機によって一括で扱うことが困難となり，詳細な解析が行えない．(2) データにはセンシングの際の雑音や複製されたデータが含まれてしまうことがあり，すべてが有用なデータであるとは限らない．雑音データと有用なデータを混同したままデータを解析すると，間違った結果を導く可能性がある．また雑音の少ない大量データであっても効率的に大量のデータ解析を行うためには，できるだけ同じようなデータの処理は避けたい．そこで，大量のデータから不要なデータを取り除き，有用なデータを抽出する手法が求められている．

この目的を達成するため，本研究では，連続値データからデータの代表点を抽出する手法を提案する．提案手法ではまず，連続値データを k 近傍法を用いて二値化する．そして，頻出パターンマイニングを用いることで，頻出するデータ点の組合せを得る．これらのデータ点は，多くのデータ点に対して近傍として共有されているため，データ集合を代表する点となっている．

本稿は以下のような構成となっている．まず 2. 節で提案手法を説明する．最初に概要を述べた後，2.1 節では二値化，2.2 では頻出パターンマイニングについて述べる．3. 節で提案手法の動作例を示した後，4. 節で提案手法を実験によって評価し，結果を考察する．最後に 5. 節で本研究の結論と今後の課題について述べる．

2. 提案手法

提案手法の概要について述べる．提案手法には，2 つの段階があり，第 1 段階は k 近傍法による二値化，第 2 段階は頻出パターンマイニングである．表 1 に概念図を示す．

連絡先: 米田友花, 大阪大学産業科学研究所, 06-6879-8540, 大阪府茨木市美穂ケ丘 8-1, yoneda@ar.sanken.osaka-u.ac.jp

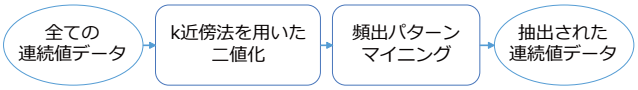


図 1: 提案手法の概念図

具体的には，第 1 段階では，連続値をとるデータにおいて，各データ点に対して他のデータ点との距離を計算し，k 番目に近い点までのデータ点であるかどうかを示す二値データに変換する．この二値データは，パターンマイニングにおけるトランザクションデータに対応する．第 2 段階では，第 1 段階で得たトランザクションデータに対して頻出パターンマイニングを適用することで，複数のトランザクションに頻出するデータ点の組合せを得る．これによって，多くのデータ点に近傍として共有されているデータ点を見つけることができ，データの分布を推定することなくデータの代表点を検出できる．提案手法のアルゴリズムの擬似コードを，Algorithm 1 に示す．2 つの段階におけるそれぞれのアルゴリズムは，2.1 節と 2.2 節で説明する．

提案手法への入力データは，連続値をとる多次元ベクトルの集合である．各データ点は，n 次元の実数値ベクトル $\boldsymbol{x}_i = (x_i^1, x_i^2, \ldots, x_i^n) \in \mathbb{R}^n$ $(i = 1, \ldots, N)$ である．

2.1 二値化

k 近傍法を用いた二値化では，連続値の特徴を要素にもつ各特徴ベクトルを二値化することで，二値の特徴ベクトルを得る．変換された二値特徴ベクトルは，元の特徴空間においてデータ点同士が近いかどうかという情報を保持している．

各データ点 $\boldsymbol{x}_i \in \mathbb{R}^n$ を二値化した後の N 次元二値ベクトルを $\boldsymbol{d}_i = (d_i^1, d_i^2, \ldots, d_i^N) \in \{0,1\}^N$ $(i = 1, \ldots, N)$ と表記する．各要素 d_i^j の値は以下の定義によって与えられる．

$$d_i^j = \begin{cases} 1 & \boldsymbol{x}_j \text{が} \boldsymbol{x}_i \text{から} l \text{番目} (l \leq k) \text{に近い点であるとき,} \\ 0 & \text{その他の場合.} \end{cases}$$

ここで，k は入力パラメーターである．

以下では，二値化の動作について説明する．入力データは n 次元実数値ベクトルであり，出力は N 次元二値ベクトルである．まず，あるデータ点 $\boldsymbol{x}_i$ に注目し，他の点 $\boldsymbol{x}_j$ との距離を計算する．すべてのデータ点との距離を計算した後，$\boldsymbol{x}_j$ と

の距離が k 番目までに近い場合，d_i^j に 1 を代入する．$\boldsymbol{x}_j$ が k 番目よりも遠い点であった場合，d_i^j に 0 を代入する．これらの処理を全てのデータ点に対し実行することで，二値化された N 次元特徴ベクトル $\boldsymbol{d}_1, \boldsymbol{d}_2, \ldots, \boldsymbol{d}_N$ を得る．

2.2 頻出パターンマイニング

提案手法では，入力データから得られた二値ベクトルに対して，頻出パターンマイニングを適用することで，例外的なデータを取り除き，データの代表点の組合せを得る．

頻出パターンマイニング [1] とは，組合せの集合から頻出する組合せを取り出すことを目的とするデータマイニング手法の 1 つである．あらかじめ与えられた集合 A について，A の各要素 $i \in A$ を**アイテム**（item）と呼び，A の部分集合 $F \subseteq A$ を**アイテム集合**（itemset）と呼ぶ．**トランザクション**（transacition）T はアイテム集合である．頻出パターンマイニングにおいて解析の対象となるデータは，**トランザクションデータ**（transaction data）と呼ばれるトランザクションの集合 $\mathcal{D} = \{T_1, T_2, \ldots, T_m\}$ である．あるアイテム集合 F について，データベース $\mathcal{D}$ における F を含むトランザクションの割合を**サポート**（support）と呼ぶ．あるアイテム集合 F について，データベース $\mathcal{D}$ における F を含むトランザクションの割合を**サポート**（support）と呼び，F のサポート $S(F)$ は $S(F) = |\{T \in \mathcal{D} \mid F \subseteq T\}|/|\mathcal{D}|$ で定義される．サポートは，アイテム集合 F が頻出であるかどうかの判定に用いる．サポートの値が，**最小サポート**（minimum support）s と呼ばれるユーザーが与える閾値以上となるとき，この F を**頻出アイテム集合**（frequent itemset）と呼ぶ．本研究では，全ての頻出アイテム集合のうち，特に**極大頻出アイテム集合**（maximal frequent itemset）と呼ばれるアイテム集合の発見に注目した．極大頻出アイテム集合とは，任意のアイテム $a \in A$ に対して $F \cup \{a\}$ のサポートが s より小さくなるアイテム集合 F のことを指す．極大頻出アイテム集合の部分集合は，必ず頻出アイテム集合となることが分かっている．本研究では，頻出パターンマイニングを適用して極大頻出アイテム集合を得るために，LCM (Linear time Closed itemset Miner) [5] を使用した．

提案手法では，まず二値ベクトルの集合をトランザクションデータに変換する．各二値ベクトル $\boldsymbol{d}_i$ に対して，対応するトランザクションを T_i とする．二値ベクトル $\boldsymbol{d}_i$ に対して，その要素のうち 1 である要素のインデックスをすべて T_i に格納する．つまり，各 T_i は

$$T_i = \{j \in \{1, 2, \ldots, N\} \mid d_i^j = 1\} \tag{1}$$

で与えられる．頻出パターンマイニングに入力するトランザクションデータは，インデックス集合の集合 $\mathcal{T} = \{T_1, T_2, \ldots, T_N\}$ である．提案手法において，頻出パターンマイニングによって得られる極大頻出アイテム集合を $\mathcal{S} = \{S_1, S_2, \ldots, S_L\}$ とする．これが提案手法の出力となる．本稿では，この組合せ集合の和集合をとることで，データの代表点を得る．具体的には，$\bigcup \mathcal{S} = S_1 \cup S_2 \cup \cdots \cup S_L \subseteq \{1, 2, \ldots, N\}$ で与えられる．この和集合 $\bigcup \mathcal{S}$ は，元の実数値データのインデックスを示す 1 から N の数字の集合であり，$\bigcup \mathcal{S}$ に含まれるインデックスに対応するデータ点を抽出する．

3. 提案手法の動作例

提案手法の動作例を紹介する．表 1 に示した特徴数 $n = 2$，データ数 $N = 7$ の実数値データを入力とし，まず $k = 2$ として k 近傍法により二値化して，表 2 を得る．そして，各二値

Algorithm 1 提案手法のアルゴリズム

```
Input k, s
for all i = 1 to N do
    for all j = 1 to N do
        Calculate the distance between x_i and x_j
    end for
    for all j = 1 to N do
        if the distance between x_i and x_j is lth smallest
        with l ≤ k then
            d_i^j = 1
        else
            d_i^j = 0
        end if
    end for
end for
for all i = 1 to N do
    Generate T_i by Equation (1)
end for
T ← {T_1, T_2, ..., T_N}
Apply T to frequent pattern mining
                        with the minimun support s
S ← maximum frequent itemsets
Outout ⋃S
```

表 1: 入力の連続値データ

	特徴 1	特徴 2
$\boldsymbol{x}_1$	1.1	2.1
$\boldsymbol{x}_2$	1.9	1.8
$\boldsymbol{x}_3$	2.2	1.2
$\boldsymbol{x}_4$	3.9	5.1
$\boldsymbol{x}_5$	5.2	2.5
$\boldsymbol{x}_6$	5.3	5.4
$\boldsymbol{x}_7$	2.4	4.3

ベクトルを表 3 のようにトランザクションデータに変換した後，最小サポート 4 を満たす極大頻出アイテム集合を頻出パターンマイニングによって得る．この例において抽出されたデータ点は $\boldsymbol{x}_2$ および $\boldsymbol{x}_4$ である．また，図 2 において入力の実数値データ及び抽出後の実数データをプロットした．横軸は特徴 1，縦軸は特徴 2 を表している．

4. 評価実験

提案手法を人工データに適用して性能評価を行い，その結果について考察する．まず，4.1，4.2 節で実験を行った条件について述べる．その後 4.3 節で実験結果を示し，4.4 節で結果について考察する．

4.1 実験環境

実験に用いた計算機は，Intel Core i7-4790 CPU 3.60 GHz のプロセッサ，実験メモリ 8.00 GB，OS は Windows 8 Enterprise 64 bit である．提案手法および比較手法は，ともに Python 言語（version 3.5.2）で記述されている．LCM 本体は，著者によって公開されている C 言語での virsion5.3 の実装 [*1] を用いた．

*1 http://research.nii.ac.jp/~uno/codes-j.htm

表 2: 表 1 に示したデータを二値化して得られる二値データ

	1	2	3	4	5	6	7
$\boldsymbol{d}_1$	1	1	1	0	0	0	0
$\boldsymbol{d}_2$	1	1	1	0	0	0	0
$\boldsymbol{d}_3$	1	1	1	0	0	0	0
$\boldsymbol{d}_4$	0	0	0	1	0	1	1
$\boldsymbol{d}_5$	0	0	0	1	1	1	0
$\boldsymbol{d}_6$	0	0	0	1	1	1	0
$\boldsymbol{d}_7$	0	1	0	1	0	0	1

表 3: 表 2 から得たトランザクションデータ

	トランザクション
T_1	{1,2,3}
T_2	{1,2,3}
T_3	{1,2,3}
T_4	{4,6,7}
T_5	{4,5,6}
T_6	{4,5,6}
T_7	{2,4,7}

4.2 実験方法

本稿では，人工的に生成したデータを用いて評価実験を行った．生成した人工データは，10 個の正規分布からなるデータ数が N，特徴数が n のデータである．生成したデータは，1 つの大きなクラスタと 9 つの小さいクラスタからなり，それぞれデータ数の割合が 0.55 および 0.05 となるように異なる正規分布から生成した．正規分布のそれぞれの平均値はランダムに定めて，分散は 1 に固定した．本実験では，$k = 10$ の k 近傍法を用いた二値化を適用した．提案手法を適用することで，データの代表点を適切に抽出できているかを確認するため，10 個の正規分布からなるデータそれぞれに異なるクラスを割り当てた．そして，(1) データ抽出前の全データ，(2) 提案手法を適用したデータ，また (3) 提案手法と同じデータ数だけランダムに抽出したデータをそれぞれ決定木分析に入力し，10 分割の交差検証法で分類精度を評価した．決定木分析には，CART [2] を採用した．Python の機械学習ライブラリ scikit-learn [4] では，決定木分析の標準的手法として採用されており，本実験でもこの実装を用いた．

本実験においては，2 種類の実験を行った．(i) データ数，特徴数を固定し，最小サポートを変化させたときの，提案手法とランダム抽出における抽出点の数と分類精度の測定および (ii) データ数，特徴数を変化させたときの，全データを使用した場合，提案手法，ランダム抽出における抽出点の数と分類精度の測定である．ただし，実験 (ii) において，提案手法における最小サポートは，極大頻出アイテム集合が存在する最大限の値をそれぞれのデータ数や特徴数に応じて設定した．また，実験結果の値は，小数第 3 位を四捨五入したものを記載した．

4.3 実験結果

実験 (i) では，データ数を 1000，特徴数を 2 で固定し，最小サポートを変化させた場合の提案手法およびランダム抽出における抽出点の数と分類精度を測定した．結果を表 4 に示す．最小サポートが 15 から 17 に増加すると，抽出されるデータ数の平均が 144.9 から 52.5 に減少し，よりデータが圧縮できている．さらに，分類精度はランダム抽出と同程度であり，ランダム抽出においては分類精度が 0.97 から 0.94 の 0.03 だけ下がったことに対し，提案手法では 0.93 から 0.92 の 0.01 の低下にとどまった．

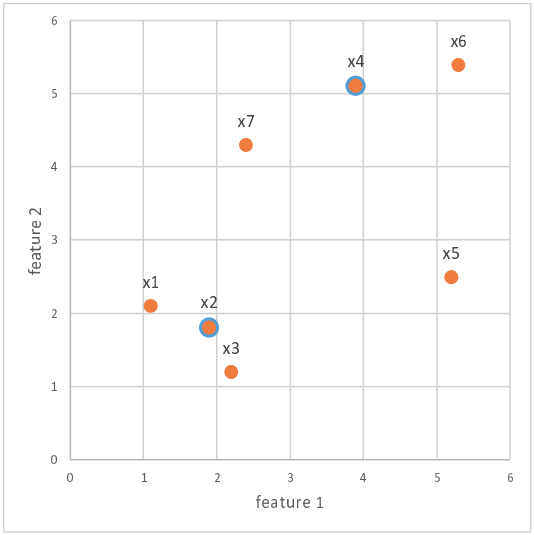


図 2: 実数値データのプロット．提案手法で選び出された点を青色で示す．

表 4: データ数 1000 特徴数 2 のデータにおいて最小サポートを増加させたときの実験結果

最小サポート	抽出点数	分類精度	
		提案手法	ランダム抽出
15	144.9	0.93	0.97
16	88.8	0.93	0.96
17	52.5	0.92	0.94

次に，実験 (ii) において，特徴数を 2 で固定し，データ数を 1000 から 4000 に変化させたときの全データを使用した場合，提案手法およびランダム抽出における抽出点数と分類精度を測定した．結果を表 5 に示す．まず，データ数を 1000 から 4000 まで変化させると，抽出点数が 52.5 から 115.3 と 2 倍程度増加することが分かった．また，分類精度はどの手法も高い値になっている．

最後に，実験 (ii) において，データ数を 3000 で固定し，特徴数を 2 から 10 に変化させたときの全データを使用した場合，提案手法およびランダム抽出における抽出点数と分類精度を測定した．結果を表 6 に示す．まず，特徴数を変化させると，抽出点数が 119.5 から 377.5 へ増加した．ここでも，分類精度はどの手法も同水準となった．

4.4 実験の考察

実験 (i) の表 4 から，データの抽出点の数が大幅に減少したとき，提案手法の方がランダム抽出よりも分類精度の低下が抑えらている．これは，提案手法の頻出パターンマイニングによって，周辺に同じようなデータがたくさんあるデータ点を抽出することができるため，抽出した点が少ない場合でもある程度の分類精度を保つことができるためと考えられる．

また実験 (ii) の表 5 から，データ数を多くしたとき，データ数 1000 のときは提案手法とランダム抽出の分類精度の差が 0.02 だったことに対しデータ数 4000 のときは 0.01 と縮まった．そのため，データが大きくなるほど，提案手法の方がラン

表 5: データ数 N を増加させたときの実験結果

データ数	特徴数	抽出点数	分類精度		
			全データ使用	提案手法	ランダム抽出
1000	2	52.5	0.98	0.92	0.94
2000	2	91.6	0.95	0.93	0.94
3000	2	119.5	0.99	0.96	0.96
4000	2	115.3	0.99	0.98	0.99

表 6: 特徴数 n を増加させたときの実験結果

データ数	特徴数	抽出点数	分類精度		
			全データ使用	提案手法	ランダム抽出
3000	2	119.5	0.99	0.96	0.96
3000	5	359.5	0.99	0.98	0.99
3000	10	377.5	1.00	0.99	0.99

ダム抽出より適切にデータの代表点を抽出することができると考えられる．これは，同じ特徴数のデータにおいては，データ数が増えると，各クラスタのデータの密度が大きくなり，提案手法での頻出パターンマイニングでデータの代表点を適切に抽出することができたからであると考えられる．

最後に実験 (ii) の表 6 から，特徴数を多くしたとき，抽出されたデータ数は大幅に増加し，分類精度は提案手法とランダム抽出は同じように上昇した．これは，データが高次元になると，データ数に対し元の特徴空間が指数関数的に大きくなるため，それぞれのデータ同士の距離の差が少なくなる．その結果，データ周辺にあるデータの数の偏りがなくなり，提案手法における頻出パターンマイニングによって適切なデータを抽出することと，ランダム抽出のようにランダムにデータを抽出することの差がなくなったためと考えられる．

5. おわりに

本稿では，実数値データの集合からデータの代表点を抽出する手法を提案した．この手法では，実数値データを k 近傍法を用いた二値化によって二値データに変換したあと，頻出パターンマイニングによってデータの代表点を抽出する．実験による性能評価の結果，提案手法をもちいることで，特にデータ数が増加させた場合に，ランダムにデータを抽出する手法よりも分類精度を向上させることができた．

一方，今回の評価実験においては，データ数が比較的小さい場合の実験にとどまった．より大規模なデータに対して，提案手法がどのようなふるまいをするのかを評価し考察していく必要がある．また本稿では，提案手法の出力である極大頻出アイテム集合の和集合を取ることで，データ集合の代表点を得た．ここで，和集合を取ることなくアイテム集合を直接利用することで，クラスタリングなどの解析が直接可能である．今後は，このような提案手法の発展に取り組む予定である．

参考文献

[1] C. C. Aggarwal and J. Han, editors. *Frequent Pattern Mining*. Springer, 2014.

[2] L. Breiman, J. Friedman, C. J. Stone, and R. A. Olshen. *Classification and regression trees*. CRC press, 1984.

[3] J. Leskovec, A. Rajaraman, and J. D. Ullman. *Mining of Massive Datasets*. Cambridge University Press, 2014.

[4] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12:2825–2830, 2011.

[5] T. Uno, T. Asai, Y. Uchida, and H. Arimura. An efficient algorithm for enumerating closed patterns in transaction databases. In *Discovery Science*, pages 16–31, 2004.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

ヒントによる局所相関推論

Inference of Local Feature Correlations by Hints

ジェイ ホンジェ　Hongjie ZHAI
原口 誠　Makoto HARAGUCHI
今井 英幸　Hideyuki IMAI

北海道大学 大学院情報科学研究科
Graduate School of Information Science and Technology, Hokkaido University

We propose in this report a method for searching local correlations among features, where the locality means that the correlations are verified only for some parts of non-negative data matrix. As the number of such local correlations is large, we try to control the diversity by presenting a hint set, a small set of feature pairs demonstrating local correlations. Then a subspace with composite features as its axes is constructed so that the paired features become close on the subspace. The process of searching such a subspace is realized by applying NMF for shared subspace with a graph regularization term.

1. はじめに

データベースにおいて観察可能な属性やアイテムの相関 (correlation, association) 関係の検出は，データマイニングにおける基本問題の一つであり続けている．ここで，多数の個体により支持される大域的相関のみが興味の対象ではなく，相関を支持する個体数が比較的に少数であるがゆえに,「目立たない」局所的相関も重要である．特定のユーザにとっては発想や発見のトリガーとなりえるからである [Taniguchi 2006].

似たような問題は，類似性を論じるときにも生じる．類似性と同時に細かな差異はいくらでも存在し，よって可能な類似性の中から妥当な類似性に絞り込む操作を必要とする．通常，そうした絞り込み操作はタスクや文脈・観点に依存する．類推学習における先駆的研究 [Greiner 1985] では，類推における類似物の対をヒント $f_i^{(1)} \sim f_i^{(2)}$ として与え，ヒントと整合的な類似性のみに絞り込む．つまり，ヒントを文脈や観点の例示として扱うわけである．類推図式としては

$$\frac{f_1^{(1)} \sim f_1^{(2)}, ..., f_m^{(1)} \sim f_m^{(2)}}{f_{m+1}^{(1)} \sim f_{m+1}^{(2)}}$$

ただし，$f_j^{(1)} \sim f_j^{(2)}$ は同じ類似性 $\sim$ を共有 (SIM).

こうした類推的な操作は異なるデータセット間での属性の対応付け問題にも適用でき，実際，[Zhai 2017] で既に報告済である．本稿では，単一データセット内で成立する局所相関検出問題に対し，[Zhai 2017] のアイデアを適用する．すなわち，データセットにおいて対応付けられるべき属性 (feature) の対 $< f^{(1)}, f^{(2)} >$ のいくつかをヒントとして与え，属性の無相関部分（行）を捨象できる部分空間の生成系で，対になった属性を近接したベクトルに射影できるものを求める．別の言い方をすれば，射影ベクトルは元の属性ベクトルの（行に関する）部分を表現させ，類推図式における条件 (SIM) を部分空間における近接性で捉える．一旦，こうした部分空間が得られれば，ヒントに出現しない属性対も，射影した結果が近接すればヒントが与える観点に従って対応付け可能だと推論・推測するわけである．

部分空間（厳密には凸多面体錘）の生成系は元の属性の線形結合で得られる合成項である．線形結合による合成属性はデータが非負の場合，非負行列分解によるデータ圧縮で得ることができ，ヒント属性対の近接性条件を正則化項として組み込んだ非負行列分解を施せばよいことも直ちにわかる．具体的には，共通空間法 [Gupta 2010] とグラフ正則化項 [Cai 2011] を伴う非負行列分解を用いる．ただし，図 1 で示すように，相関部分を表す生成系は無相関部分を考慮しないために，実際問題としては，ヒントとの整合性と圧縮精度のトレードオフ問題として扱い，テクニカルには正則化項の重みであるラグランジェ定数で調整を行うとする．

連絡先: 原口誠，北海道大学大学院情報科学研究科，札幌市北区北１４西９，011-706-7106，mh@ist.hokudai.ac.jp

データ行列 X がブール値の場合．ヒント $\mathcal{H} = \{< f_1, f_2 >, < f_3, f_4 >\}$ 右図は X の列をヒント属性 $\{f_1, f_2, f_3, f_4\}$ に制限した部分行列．属性対の無相関部分（行）は，生成系 $G = (\boldsymbol{g}_1\ \boldsymbol{g}_2)$ が張る部分空間への射影により無視できるが，$H = (\boldsymbol{f}_1\ \boldsymbol{f}_2\ \boldsymbol{f}_3\ \boldsymbol{f}_4)$ の圧縮としての G は，無相関部分の捨象に起因する近似精度劣化を伴う．

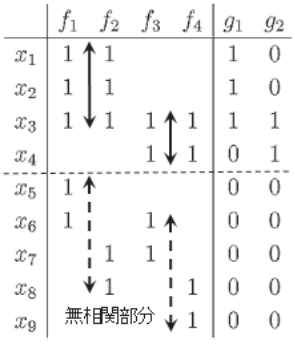


図 1: 局所相関と生成系の例

2. ヒントと局所相関

$X = \begin{pmatrix} \boldsymbol{f}_1 & \cdots & \boldsymbol{f}_N \end{pmatrix}$ を非負の $M \times N$ データ行列とする．$\boldsymbol{f}_i$ は列 f_i の M 次元列ベクトルである．局所相関推論のためのヒント $\mathcal{H}$ とは，列の対の集合 $\mathcal{H} \subseteq \{f_1, ..., f_N\}^2$ で，一般に列の多対多関係であってよい．本稿では，前節で述べたように，

> ヒントと一定の整合性を持ち，かつ，ヒントを構成する列の圧縮表現をＮＭＦにより求め，これを残りの列の圧縮の一部として組み込むことにより局所相

なお，用語としての「局所相関」は部分で成り立つ自己相関を本稿では意味し，ブール値の場合はアイテム集合に対する集合論的相関と概念的には同じである．また，本稿の枠組みはヒント数を増加させれば「関係学習」ともみなせるが，個々のユーザが興味を示すヒントを多数与えるのは骨のおれるタスクであり,「学習」ではなく，あくまでも比較的少数のヒントからの推測・推論問題として捉えている．

関推論を実現する．

ヒントに現れる属性を $H = P_1(\mathcal{H}) \cup P_2(\mathcal{H})$ とし，以下，H 中の属性を先行して配置した行列を同じ記号 H で記す．ここで P_i は属性の関係 R に対する射影である．また Y は X から H 中の属性の列ベクトルを除去してできる部分行列である．

ヒント属性からなる部分行列 H の非負行列分解

$X = \left(\boldsymbol{f}_1 \ \cdots \ \boldsymbol{f}_N\right) = \left(H \ Y\right)$,
$H \approx GW$ をヒントの非負行列分解とする．ただし，
生成系 $G = \left(\boldsymbol{g}_1 \ \cdots \ \boldsymbol{g}_{K_H}\right)$，係数行列 $W = \left(\boldsymbol{w}_1 \ \cdots \ \boldsymbol{w}_{|H|}\right)$

要請１：部分空間におけるヒント属性の近接性

$< f_i, f_j > \in \mathcal{H}$ とする．生成系 G に関する座標 $\boldsymbol{w}_i$ と $\boldsymbol{w}_j$ は近接しなければならない．これは制約だが，ラグランジェ定数 λ を用い，グラフ正則化項を伴う非負行列分解 [Cai 2011] のやり方を踏襲する．すなわち，行列分解の近似誤差 $\|H - GW\|^2$ に下記の項の $\lambda/2$ 倍を加えた量の最小化を試みる．

$$\sum_{<f_i,f_j>\in\mathcal{H}} \|\boldsymbol{w}_i - \boldsymbol{w}_j\|^2 = \sum_{f_i,f_j\in H} s_{ij} \sum_{k=1}^{K_H} \left(w_{ki} - w_{kj}\right)^2 = 2 \ \mathrm{Trace}\left(WLW^t\right)$$

ただし，s_{ij} は f_i と f_j の結合重みで，ヒント中の対のときに１，それ以外で０とする．また，L は ヒント属性 f_i, f_j を頂点とし，辺重み s_{ij} を持つグラフのラプラシアンである．

要請２：共通部分空間制約

ヒントに出現しない Y の列を 生成系 G が張る部分空間に射影するために，G とその「補空間」として残りの部分行列 Y の圧縮 $\left(G \ G^{(Y)}\right)$ を求める．

$$Y \approx \left(G \ G^{(Y)}\right) \begin{pmatrix} W^{(G)} \\ W^{(Y)} \end{pmatrix}$$

Y の圧縮として H と同じ圧縮 G を含ませた形が部分空間共有制約を表していることに注意する．また，係数行列のうち，部分行列 $W^{(G)}$ の第 j 列 $\boldsymbol{w}_j^{(G)}$ が非ヒント属性 $f_{|H|+j}$ の共通空間における座標ベクトルになる．

以上をまとめると，最適化（最小化）の式を下記で与えることができる．反復式と収束性の詳細は省略するが，共通空間法およびグラフ正則化項を持つ非負行列分解に対する論証を組み合わせることにより示せる．

$$\|H - GW\|^2 + \lambda \mathrm{Trace}\left(WLW^t\right) + \left|\left|Y - \left(G \ G^{(Y)}\right) \begin{pmatrix} W^{(G)} \\ W^{(Y)} \end{pmatrix}\right|\right|^2$$

局所相関推論

ヒント属性以外の属性 $f_{|H|+i}$，$f_{|H|+j}$ に対しても共通空間の座標ベクトル $\boldsymbol{w}_i^{(G)}, \boldsymbol{w}_j^{(G)}$ が近接しているときに，ヒントと同じ観点で相関していると推論する．

3. 実験

実験では，３千個の Reuters 記事（行）で約７千個の名詞（列）を持つデータセットに対し，G が張る部分空間 において近接してくる非ヒント属性について調べた．局所相関実験としては，類似・相似関係にある名詞対をいくつか与え，それを説明できる部分空間の軸の構成実験が最も適当であると考えるが，それらは記事における話題に必ずしも関連してくるとは限らず，今回の小規模実験においてはある観点から名詞間の結合強度を結果的に推論する課題を選定した．具体的には，事故という観点から `<bike,accident>`，`<motorcycle -- crash>` 等の１２個のヒントを与え，ヒント以外の属性対を射影空間での余弦類似度の降順に並べ，その上位のものについて調べた．その結果，`<automobile,danger>` `<aircraft,dysfunction>` `<aircraft,scratch>` など，ヒントが与える視点に照らして関連づけられる語彙対が部分空間で近接することを確認できた．これは，H の圧縮次元を１０に設定した場合だが，１２個の属性対を近接性制約を守る形で圧縮するためにどの程度の次元が必要なのかが明らかになったわけではない．感覚的には，１２個の対に対して１０次元だと，λ の設定にもよるが，非相関部分をかなり表現する余裕を残していると思われ，逆に言えば，部分空間の生成系には研究意図とは外れたものが含まれている可能性も残っている．ただし，現在の最適化とパラメータ設定でも，部分空間の非直交基底の中には例えば `death` に関係する軸の形成に成功している．

4. 今後の課題と展望

最も重要な課題は，ヒントの属性対が共起・相関する行の規模と複雑さの問題を明らかにすることである．今回の最適化はトレードオフ問題として安直に攻めたので，この課題が陽には表現できていない．そもそも，局所相関部分があまりにも微小な場合は，ヒントの証拠となる行が存在しないとみなせるからである．この目的のためには，(1) ヒント行列の圧縮生成系に非相関部分の表現を許した形にする，あるいは (2) 所与のヒントと整合的な行を離散的な方法で直接求める，などが考えられ，これらを順次テストしていく予定である．さらには，今回の方法はベクトル化されたデータであれば何でも良いので，規模を大きくした問題，例えば，分散意味表現なども当然試行すべき対象データとなるだろう．

参考文献

[Taniguchi 2006] T. Taniguchi, M. Haraguchi: Discovery of Hidden Correlations in a Local Transaction Database Based on Differences of Correlations, Engineering Application of Artificial Intelligence, 19(4), pp. 419 – 428, Elsevier (2006).

[Greiner 1985] R. Greiner. “Learning by understanding analogies”. Ph.D.Thesis, Stanford University (1985).

[Gupta 2010] S.K. Gupta, D.Phung, B.Adams, T. Tran and S. Venkatesh: Nonnegative Shared Subspace Learning and Its Application to Social Media Retrieval, KDD’10, 1169 – 1178 (2010).

[Cai 2011] D. Cai, X.He, J.Han, T.S.Huang: Graph regularized nonnegative matrix factorization for data representation, IEEE Trans. Pattern Anal. Mach. Intell. , 33(8), 1548-1560 (2011).

[Zhai 2017] H. Zhai, M. Haraguchi: A Linear Algebraic Inference for Feature Association, 12th KICSS, IEEE CPS, 102 – 107 (2017).

分子行列の固有値と化合物の沸点に関する研究

Studies on Normal Boiling Point of Chemical Substances and Eigen Values of Their Molecular Matrices

山下 希流[*1] 桂樹 哲雄[*1] 高橋 由雅[*1]
Kiryu Yamashita Tetsuo Katsuragi Yoshimasa Takahashi

[*1] 豊橋技術科学大学大学院工学研究科 情報・知能工学専攻
Department of Computer Science and Engineering, Graduate School of Engineering, Toyohashi University of Technology

Abstract: Boiling point is one of the most basic physical properties of chemical compounds. If it is possible to know the boiling point, it can be used to identify an unknown compound. The boiling point can be also used to predict other physical properties of the compound. Thus, estimation of boiling point is one of the important research areas in computational chemistry, and is still being studied actively. It is empirically known that there is a close relationship between chemical structure and physical properties, so that physical properties can be thought of as a function of chemical structure. On other hand, various graph invariants derived from molecular graphs can also be considered as a function of chemical structure. In this study, we tried to construct a prediction model by multiple linear regression analysis using eigenvalues obtained from matrix representations of molecular graphs. For 51 chemical compounds of saturated hydrocarbons, a regression model obtained with the first four largest eigenvalues and the number of carbon atoms gave us good estimates of their boiling points.

1. はじめに

化学構造が変われば物性も変わる。すなわち、化合物の種々の物理的特性(物性)は化学構造に依存する事が知られている。特に、沸点は未知物質の同定にも広く使われる最も基礎的かつ重要な物理化学的特性の一つであると同時に、他の物性推算のためのパラメータとしても重要な役割を果たしている[Ponce 2013]。沸点に限らず、化合物の様々な物性は化学構造の関数と見なす事が出来る。

一方、化学構造式のグラフ表現(分子グラフ)から数学的操作によって導出される様々な数量(グラフ特性量)もまた化学構造の関数と見なすことができる。先に宮脇らは，与えられた分子グラフに対し、対応する分子行列から固有値解析によって固有値を求め，元の分子グラフの構造記述子として用いることを提案するとともに、類似構造解析への応用を試みている[宮脇 2012]. 彼らは単純グラフ表現レベル(分子のトポロジカルな単純骨格表現)で同型となる種々の分子グラフを用いた構造類似性評価に対する応用例の中で、分子行列から得られた固有値が頂点原子の種類や結合タイプの違いによる構造差異を反映していることを明らかにするとともに、最大固有値から降順に並べた固有値パターンベクトルによる類似構造検索の有用性を示した。

本研究では、化学構造の行列表現から導出される固有値と化合物分子の代表的な物性の一つである沸点との関係を調べ、未知化合物の沸点予測のための定量的構造物性相関(QSPR)モデルの構築を試みた。

2. 方法

2.1 データセット

本研究ではデータセットとして、文献[Kier 1976]より参照した炭素数が 5～9 の飽和炭化水素 51 化合物の沸点の実測値を用いて解析を行った。

2.2 分子グラフの行列表現と固有値解析

化学構造をグラフとみなすことで、行列として表現することができる。分子グラフの行列表現には、頂点原子の種類を対角項に、結合の有無または多重度を非対角要素に示した原子結合行列が広く用いられている。本研究では、分子グラフの行列表現に際し、この原子結合行列を用いた。図1に 2-メチルブタンに対する分子グラフと原子結合行列の例を示す。本研究では化学構造はすべて水素原子省略グラフとして表現した。本研究ではこのようにして得られた分子行列に対して固有値解析を行い、最大固有値から降順に第 1 固有値、第 2 固有値…として個々の化合物の構造特徴を記述するための説明変数として用いた。固有値解析には Jacobi 法を用いた。例として、図 1 に 2-メチルブタンの分子行列と対応する固有値を示す。

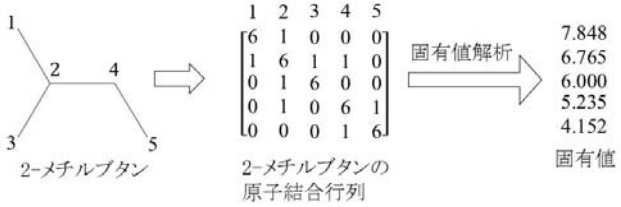


図 1 2-メチルブタンの分子行列と固有値

3. 結果

はじめに、最大固有値(第 1 固有値)のみを説明変数とした単回帰モデルを生成し、決定係数および標準誤差を調べた。得られた回帰式を(1)式に示す。

$$\text{boiling point}(℃) = 128.18\lambda_1 - 930.03 \quad (1)$$

N=51, R=0.552, R^2=0.305, S=26.777

(1)式でλ_1は第 1 固有値、N はサンプル数、R は重相関係数、R^2は寄与率(決定係数)、S は標準誤差を表す。
次に第 2 固有値、第 3 固有値と順次追加していき、各々のモデルに対する決定係数と標準誤差の変化を調べた(図 2)。

連絡先：山下希流，〒441-8580 愛知県豊橋市天伯町雲雀ヶ丘 1-1 豊橋技術科学大学大学院 情報・知能工学系，
Tel: 0532-44-6872, yamashita@mis.cs.tut.ac.jp

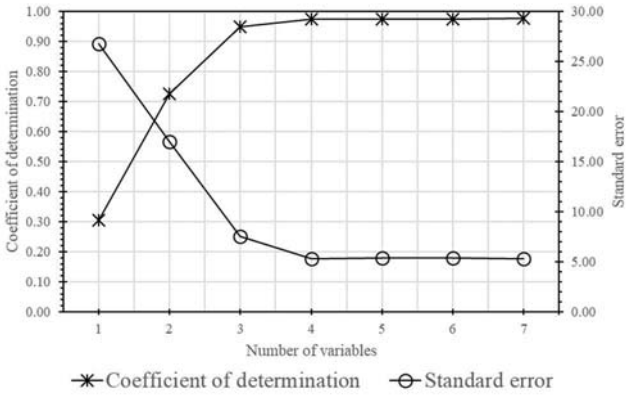


図 2 固有値の数と回帰モデルの近似精度

図 2 に示されるように、第 2 固有値、第 3 固有値の追加とともに標準誤差も大きく減少していることが分かる。一方、第 5 固有値以降は変数（固有値）を追加しても回帰モデルの精度にはほとんど変化が見られなかった。そこで、各分子グラフに対応する分子行列の第 1 固有値から第 4 固有値までの 4 つの値を説明変数とした重回帰モデルを構築した。

$$\text{boiling point(℃)} = 69.88\lambda_1+49.98\lambda_2+35.40\lambda_3+20.51\lambda_4 - 1183.52 \quad (2)$$

N=51, R=0.987, R^2=0.974, S=5.303

決定係数 = 0.974、標準誤差 = 5.303 と良好な近似結果が得られていることが分かる。得られた回帰モデルによる沸点の計算値と実測値の相関プロットを図 3 に示す。

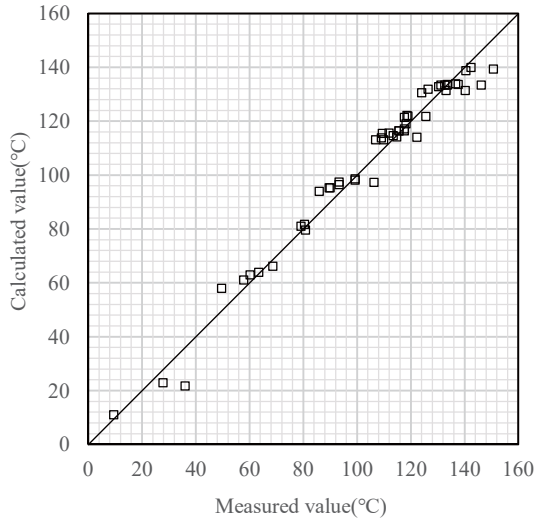


図 3 重回帰式(2)を用いて得られた沸点の計算値と実測値の相関プロット

図 3 では相関プロットの散布図にクラスターの形成が見られることから、これらの化合物群を調べたところ、炭素数が同じ異性体ごとに群を形成していることがわかった。このことから、炭素数が同じ化合物同士では似た沸点を持つ事より、炭素数を説明変数に追加すると更に良好な結果が得られるのではないかと考えた。第 1 固有値から第 4 固有値の 4 つの固有値のほかに炭素数を加えた 5 つの説明変数による重回帰モデルの作成を試みた。得られた回帰式を(3)式に示す。また、(3)式による計算値と実測値の相関プロットを図 4 に示す。

$$\text{boiling point(℃)} = 12.66n_c+21.15\lambda_1+25.60\lambda_2+23.34\lambda_3 + 23.34\lambda_4 - 585.36 \quad (3)$$

N=51, R=0.991, R^2=0.983, S=4.378

n_cは炭素数を表す。(3)式に示されるように、説明変数に炭素数を追加する前よりも標準誤差が約 1℃減少し、より良好な近似結果を得ることができた。また、これらの回帰モデルの予測安定性についても交差検証法を用いて検討を試みた。その結果、10 分割交差検証による予測実験においても予測的決定係数(Q^2)が 0.965 となり、良好な結果を与えることを確認した。

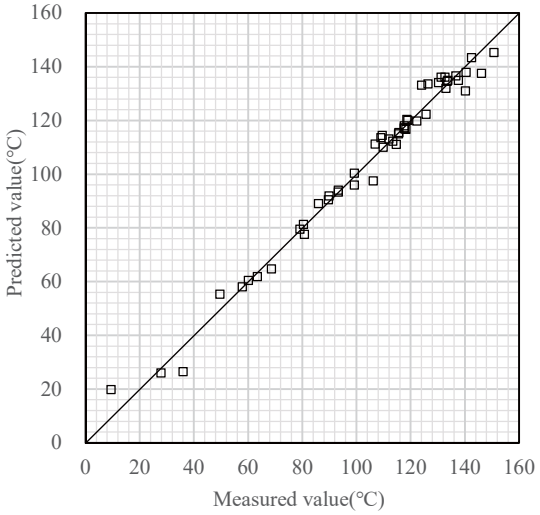


図 4 説明変数に炭素の数を追加した場合の沸点の計算値と実測値の相関プロット

4. まとめ

本研究では、化学構造の行列表現から導出した固有値と炭素数を使用した重回帰モデルを構築し、沸点の予測を試みた。鎖状飽和炭化水素 51 種を用い、第 1 固有値から第 4 固有値と炭素数の 5 変数を用いた重回帰モデルの場合で最も良い近似結果が得られた。また、10 分割交差検証を行い、予測性能を確認したところ、良好な結果が得られることを確認した。

今後はデータセットを拡張し、不飽和炭化水素やヘテロ原子を含む有機化合物一般に対しても同様に実験を試みるとともに、沸点以外の物性予測に対する有用性についても検討して行きたい。

参考文献

[Ponce 2013] Pérez Ponce, A. A. , Salfate, I. , Pulgar-Villarroel, G. , Palma-Chilla, L. Lazzús, J. A. : New Group Contribution Method for the Prediction of Normal Melting Points. J. Eng. Thermophys , Springer vol22 (3), pp.226-235 , (2013)

[宮脇 2012] 宮脇康司, 高橋由雅 : 分子行列の固有値に基づく構造プロファイリング , 第30回構造活性相関シンポジウム講演要旨集, pp.103-104 , (2011)

[Kier 1976] Kier, L. B. , Hall, L. H. : Molecular Connectivity in Chemistry and Drug Research. Academic Press , pp.132-133 , (1976)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

CADソフトの操作ログ分析による操作スキルの抽出

Extraction of the operational skills by analysis of CAD operation log

新實　桂佑[*1]　Keisuke　Niimi
外池　昭雄[*1]　Akio　Sotoike
有里　達也[*1]　Tatsuya Arisato

[*1] トヨタ自動車株式会社
Toyota Motor Corporation

The acquisition of the CAD operational skills is necessary to effective car development. In this study, we tried extraction of the operational skills by analysis of CAD operation log. As a result, we succeeded in extracting the tacit knowledge from CAD operation log.

1. まえがき

自動車の効率的な開発には，開発者の意図する部品形状を，なるべく短期間で 3D モデル化する必要がある．3D モデルの作成期間は CAD ソフトの操作スキルに依存するが，現状では全開発者が十分な操作スキルを習得できているとは言えない．

このため，CAD ソフトの操作を客観的に分析し，操作スキルを漏れなく抽出できる手法が求められている．

一方で，スキルサイエンスの分野では，チェロ演奏時の動作をデータ化し演奏スタイルを分類する[古川 16]など，動作データをクラスタリングや決定木により統計的に知見化する検討が知られている．

本検討では，CAD ソフトの全操作が記録される操作ログを作成工数の大小で分類して特徴を比較することで，暗黙知となっている CAD ソフトの操作スキルを抽出する手法を構築した．

2. 検討の方向性

2.1 CAD ソフトによる 3D モデルの作成

(1) 3D モデル作成方法

3D モデルは，2 次元の断面図に奥行き又は中心軸と回転角度を定義して得られた単純な立体を組合せて作成される．作成の流れを図 1 に示す．

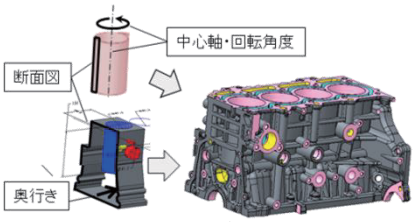


図 1. 3D モデル作成の流れ

(2) CAD 操作の特徴

同形状の 3D モデルであっても異なるコマンド，手順で作成できる．そのため，「コマンドや手順の選択（＝操作スキル）」が作成工数に大きく影響を与える．概念を図 2 に示す．



図 2. 操作スキルの違い(概念)

連絡先：新實桂佑，トヨタ自動車(株)，愛知県豊田市トヨタ町 1，
tel.050-3165-8814，keisuke_niimi@mail.toyota.co.jp

2.2 従来の操作スキル抽出手法の問題点

従来は，CAD ソフトのベテラン利用者へのインタビューなどで操作スキルを抽出しようとしていた．問題点を以下に示す．

問題点① 利用者が無意識に行っている操作は抽出不可
問題点② 利用者により選択するコマンドや手順が異なることが多く，どれが最適か判断することが困難

2.3 問題点①②への対応方針

CAD ソフトの全操作が記録される操作ログを活用し，操作スキルを漏れなく客観的に抽出できる分析モデルを構築する．

(1) 自社の CAD 環境と操作ログ

CAD 環境の構成図を図 3 に示す．操作ログは，保守用サーバに自動蓄積されている．

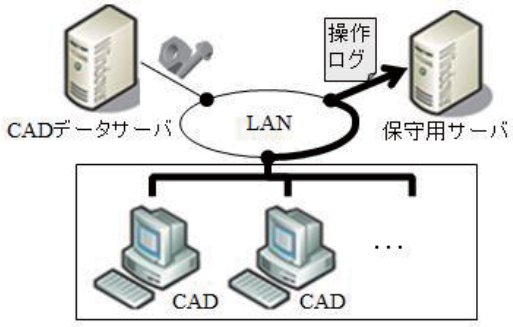


図 3. CAD 環境の構成

(2) 分析モデルの構成

分析モデルは，データ準備，データクレンジング，分析（機械学習），操作スキル抽出の 4 層で構成した．各層の役割を図 4 に示す．

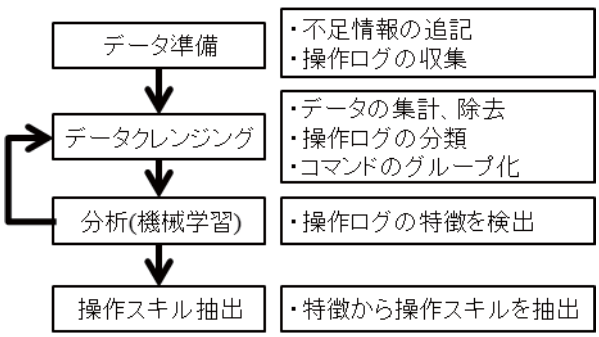


図 4. 分析モデルの構成

3. 分析モデルの試行結果

本検討では，実際の自動車開発時の操作ログを使用し，図 4 の分析モデルで操作スキルの抽出を試行した．

3.1 データ準備

分析には，3D モデルの作成プロセス，実行コマンド，タイムスタンプ，作業中のファイル名（命名規則から 3D モデル形状を特定可）の情報が必須であると考えた．

(1) 不足情報の追記

ベースとなる操作ログには，作成プロセス，実行コマンドが含まれていた．一方，タイムスタンプとファイル名が記録されていないため，ツールを作成し追記した．実例を図 5 に示す．

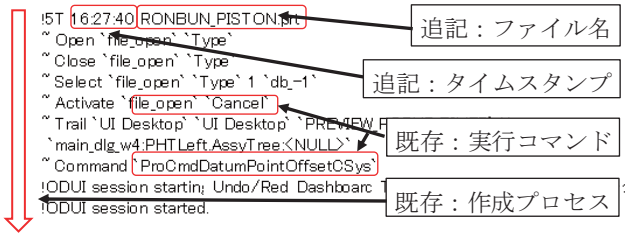


図 5. 操作ログの実例

(2) 操作ログの収集

50 名，1 ヵ月分の操作ログを収集した．詳細を表 1 に示す．

表 1. 収集した操作ログ

項目	収集結果
ファイル数	4,708(個)
操作ログの行数	70,059,428(行)
合計データ容量	13(GB)

3.2 データクレンジング

以下(1)～(3)を複数サイクル実施した．結果を表 2 に示す．

表 2. 分析対象の操作ログ

項目	クレンジング前	クレンジング後
操作ログの行数	70,059,428 (行)	6,111,243(行)
コマンド種類	1,215(種)	1,063(種)

(1) データの集計・除去

タイムスタンプから，形状の作成工数，各コマンドの実行間隔，単位時間当たりの実行頻度などを集計した．また，「保存」など操作スキルに関連しないコマンドやシステムログを除去した．

(2) 操作ログの分類

ファイル名から 3D モデル形状を特定し，類似形状毎に操作ログをグループ化した．さらに，各グループ内を作成工数の大小で 2 つのグループに分類した．

(3) コマンドのグループ化

1 操作で連続的に記録されるコマンドを 1 回とカウントし，類似コマンドをグループ化した．実例を図 6 に示す．

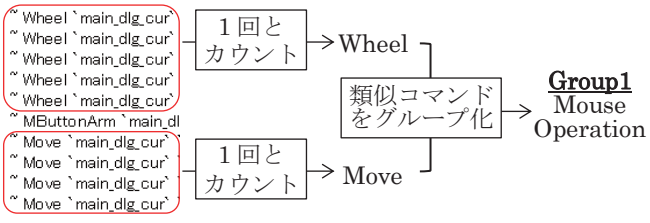


図 6. グループ化の例（マウス操作）

3.3 分析（機械学習）

機械学習を実施し，「作成工数大/小のグループ」の特徴を比較した．各機械学習手法のねらいを表 3 に示す．

表 3. 機械学習手法のねらい

機械学習手法	ねらい
(1)決定木	実行方法，実行間隔など， 実行コマンド以外の特徴を抽出
(2)アソシエーション分析	コマンドの組合せの 特徴を抽出

(1) 決定木の分析結果

目的変数を「作成工数の大/小」，階層数を「3~5 層」として決定木を作成した．大物部品の操作ログ（713 個，4,002,189 行）に関する結果を図 7 に示す．

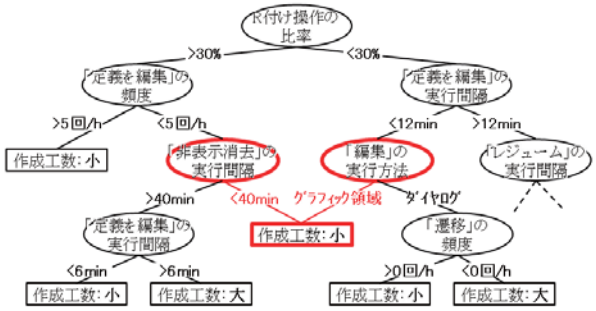


図 7. 決定木の結果（抜粋） ※赤字：詳細後述．

3.3.1.1. 決定木の結果の評価

決定木の“良さ”の尺度を分類の正解率と，過学習の有無により評価した．精度よく，過学習のない決定木であることが確認できた．詳細を表 4 に示す．

表 4. 決定木の確からしさの評価

指標	目標	結果
分類の正解率	全データの 正解率 80%以上	80% (713 個中，568 個正解)
過学習なし	Hold-Out 法での 正解率の低下が 学習データ比 10%以内	正解率の低下：7% 学習データ(573 個)：78% テストデータ(140 個)：71%

3.3.1.2. 決定木から得られた特徴

決定木から得られた「作成工数小のグループの特徴」の例を以下に示す．

特徴 1.「編集」をグラフィック領域で実行（図 8）

特徴 2.「非表示消去」を 40 分以内の間隔で実行

特徴 1. は無意識の操作であるため，従来の手法では抽出できなかった．また，特徴 2. は操作自体は既知だが，40 分以内に実行すると良いという閾値は明確化できていなかった．

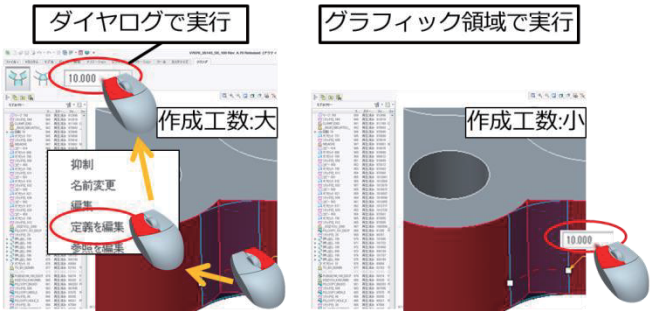


図 8. R 値を「編集」する際の実行方法の違い

(2) アソシエーション分析の分析結果

アソシエーション分析は，マーケティング分野で，購入記録を基に「よく一緒に購入される商品の組合せ」の抽出に使用される．

今回は，購入記録:操作ログ，商品:実行コマンド として分析し，約 15,000 通りの組合わせを抽出できた．詳細を表 5 に示す．

表 5. 結果の一覧

区分	件数
「作成工数小のグループ」のみ抽出	2,137(通り)
「作成工数大のグループ」のみ抽出	2,271(通り)
両方のグループで抽出	11,060(通り)

3.3.2.1. アソシエーション分析の結果の評価

結果の“良さ”の尺度を Lift 値により評価した．Lift 値は，コマンド A を実行した場合にコマンド B,C の実行確率がどの程度上がるかを定量化した指標である．Lift 値の定義を式(1)に示す．

$$\text{Lift値} = \frac{\dfrac{(\text{コマンドAとBCの組合わせ回数})}{(\text{コマンドAの実行回数})}}{\dfrac{(\text{コマンドB,Cの実行回数})}{(\text{全コマンドの実行回数})}} \quad (1)$$

今回は，Lift 値 6 以上を有意な結果として採用し，抽出された約 15,000 通りの組合せを 450 通りに絞り込んだ．

3.3.2.2. アソシエーション分析から得られた特徴

アソシエーション分析から得られた組合せの例を表 6 に示す．

抽出された組合せ自体は既知であったが，従来手法では，「作成工数大/小のグループ間」で実行頻度に偏りがあることは明確化できていなかった．

表 6. アソシエーション分析の結果(抜粋)

結果の比較	コマンド A	コマンド B	コマンド C
作成工数小のみ抽出（図 9）	ラウンド	オプション「セット」	オプション「ピース」
作成工数大のみ抽出（図 10）		面生成	延長

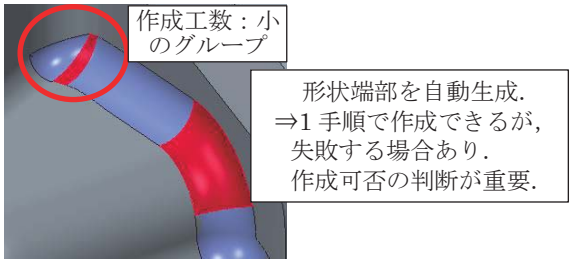


図 9.「ラウンド」と「セット」「ピース」を組み合わせた操作

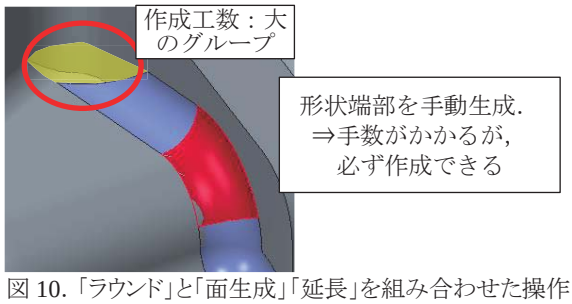


図 10.「ラウンド」と「面生成」「延長」を組み合わせた操作

3.4 操作スキル抽出

機械学習の結果を CAD ソフトのベテラン利用者と考察し，有意な結果を全 24 件に絞込み，操作スキルとして標準化した．抽出の流れを図 11 に示す．

また，標準化した操作スキルの実行回数を操作ログから集計し，利用者へ展開した際の効果を試算した．結果として，作成工数を低減できることが確認できた．例を表 7 に示す．

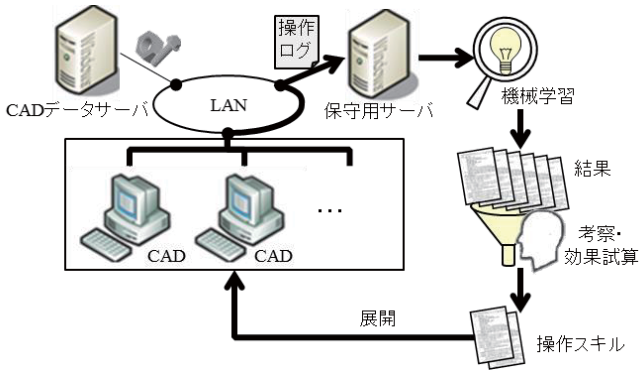


図 11. 操作スキル抽出の流れ

表 7. 結果の考察と効率化効果(抜粋)

機械学習の結果	考察
「作成工数:小のグループ」では「編集」をグラフィック領域で実行	マウス移動量が少なく作業時間短（5sec/回）
「作成工数:小のグループ」では「ラウンド」を「セット」「ピース」と組合せる	形状端部を自動生成作業時間短（15min/回）

4. 考察

本検討により，操作ログから操作スキルを漏れなく客観的に抽出できる手法を開発した．その結果，実際のログから有益な操作スキルの抽出にも成功し，CAD 利用者へ展開できた．

今後は，分析時間の短縮に取り組み，リアルタイムに不足スキルを提供するなど，より早期に利用者を育成できるしくみを検討していく．

最後に，分析時間の短縮には，3 層目「データクレンジング」の効率化が必須である．これは，本検討以外にも，ビッグデータ分析全般の共通課題であるため，人工知能を活用した効率的な手法の開発など基礎技術の発展に期待したい．

謝辞

論文中の分析モデル構築について，日本アイ･ビー･エム 株式会社様，株式会社 トヨタコミュニケーションシステム様に多大なるご協力を頂いた．深謝する．

参考文献

[古川 16] 古川康一，升田俊樹，西山武繁: チェロ演奏動画の目視によるデータ獲得と演奏スタイルの分類，第 30 回人工知能学会全国大会，2016.

Oral presentation | General Session | [General Session] 2. Machine Learning

[1Z1] [General Session] 2. Machine Learning

座長:大塚 琢馬（NTT）

Tue. Jun 5, 2018 1:20 PM - 3:00 PM Room Z (3F Matsu Take)

[1Z1-01] Concept-drift-aware Stochastic Gradient Descent

○Kohei Miyaguchi[1], Hiroshi Kajino[2] （1. Graduate School of Information Science and Technology, The University of Tokyo, 2. IBM Research - Tokyo）

1:20 PM - 1:40 PM

[1Z1-02] Statistical Evaluation for Mode Selection in Sparsity-promoting Dynamic Mode Decomposition

○Masashi Hiraoka[1], Yoshinobu Kawahara[1,2], Takashi Washio[1] （1. The Institute of Science and Industrial Research, Osaka University, 2. Center for Advanced Intelligence Project, RIKEN）

1:40 PM - 2:00 PM

[1Z1-03] Expert-based reward function training: the novel method to train sequence generators

○Joji Toyama[1], Yusuke Iwasawa[1], Yutaka Matsuo[1] （1. The University of Tokyo）

2:00 PM - 2:20 PM

[1Z1-04] Dynamic mode decomposition using supervised principal component analysis

○Takehito Bito[1], Yoshinobu Kawahara[1,2], Takashi Washio[1] （1. Osaka university, 2. RIKEN）

2:20 PM - 2:40 PM

[1Z1-05] Bayesian Estimation and Model Averaging of CNN by Hypernet

○Kenya Ukai[1], Takashi Matsubara[1], Kuniaki Uehara[1] （1. Graduate School of System Infomatics, Kobe University）

2:40 PM - 3:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

非定常時系列予測のための確率的勾配法

Concept-drift-aware Stochastic Gradient Descent

宮口航平 *1　　梶野洸 *2
Kohei Miyaguchi　　Hiroshi Kajino

*1東京大学　　*2IBM 東京基礎研究所
The University of Tokyo　　IBM Research - Tokyo

We present a stochastic gradient descent for the time-series forecasting problem in the presence of concept drift.

1. 背景と動機

データの生成確率分布が非定常に変化するような，コンセプト・ドリフト環境における時系列予測問題を考える．コンセプト・ドリフト環境においてまず考慮しなければならないことは，環境が変化した際に予測性能が極端に低下しないように，予測をしながらも常に学習を続けるということである．このため，我々は確率的勾配法 (SGD) に基づくオンライン学習の枠組み—データを一つ観測するごとにモデルのパラメタを更新する—に則った方法を考えることにする．SGD に基づくオンライン学習の枠組みにおいて，学習の収束と適応のトレードオフを制御し，予測精度に大きく寄与するパラメタが SGD の学習率である．環境が定常である間は，学習を最適パラメタに向かって収束させるために学習率は小さくなるべきであるが，ひとたび環境が変化したならば，その変化に適応するために学習率を大きく取る必要がある．従って特に，本研究では学習率の自動調整を通じて環境の変化に対応した収束と適応を行う方法について考える．

SGD の学習率自動調整には幾つかの方法が知られているが，我々は特に収束と適応の調整を感度の高いハイパーパラメタなしに行うことができる手法として，variance-based SGD (vSGD) [Schaul 13] に着目する．彼らのアイデアの本質は，最適な学習率が勾配のモーメント統計量を用いて与えられるというものである．このことから，学習率の自動調整問題はそれら統計量の推定問題に帰着される．vSGD の欠点は，各統計量の推定がヒューリスティクスに基づくものであり，推定バイアスが持続してしまうケースが有ることである．本研究ではこの問題を解決するため，より理論的根拠の確かな推定法を導く．

本研究では上記の統計量を推定するアルゴリズムである逐次平均追跡法 (sequential mean tracker, SMT) とともに，コンセプトドリフトのための SGD (concept-drift-aware stochastic gradient descent)，すなわち Cogra を提案する．鍵となるアイデアは，期待予測損失を統計量の推定誤差によって上から抑えることにある．これにより，時系列の予測損失最小化問題が推定量の誤差最小化問題に帰着される．SMT はこの考え方に基づき推定誤差が小さくなる様に各モーメントを推定しており，vSGD のヒューリスティックな推定量を SMT で置き換えることで，Cogra が得られる．

本研究ではさらに，幅広い実験を通して提案法の有効性を検証する．特に次の 3 点を明らかにするため，2 つの実験を行った．**(Q1)** SMT は vSGD の推定器よりもより良くモーメントを推定するか？**(Q2)** SMT の導入は予測性能を改善するか？**(Q3)** どのような場合に Cogra は他の SGD に基づく手法に勝るか？最初の実験では，**(Q1)** に答えるため，人工データを用いてモーメントの推定誤差を計測した．その結果，SMT は vSGD と比較して予測誤差を全体で 60%程度低減することがわかり，**(Q1)** が肯定的に確認された．また 2 つめの実験では，**(Q2)**, **(Q3)** に答えるため，人工データと実データを用いて予測性能を評価した．結果として，Cogra は多くのデータセットにおいて良い予測性能を示し，特に劇的な変化を含むような時系列において他手法を優越する事が分かった．

連絡先: 宮口航平，kohei_miyaguchi@mist.i.u-tokyo.ac.jp

2. 問題設定

$\{X_t\}_{t=1}^{\infty}$ を確率過程とする ($X_t \in \mathcal{X} \subseteq \mathbb{R}^D$)．各時刻 $t = 1, 2, \dots$ で X_t の実現値 $x_t \in \mathcal{X}$ を観測するとする．各 t に関して，過去のデータを用いて X_t を予測するような確率モデル $p_\theta(X_t \mid x^{t-1})$ を学習したい．ただし，$\theta \in \Theta$ はモデルのパラメタ，そして $x^{t-1} \stackrel{\text{def}}{=} (x_1, x_2, \dots, x_{t-1})$ は過去の観測値の列を表すとする．データを生成する確率分布は時間とともに変化しうるものであって，ある時刻の最適なパラメタが次の時刻においても最適であるとは限らないので，最適なパラメタの系列 $\theta_1^\star, \theta_2^\star, \dots$ をオンラインで学習したい：

$$\theta_t^\star = \operatorname*{argmin}_{\theta \in \Theta} \mathcal{L}_t(\theta), \quad \mathcal{L}_t(\theta) \stackrel{\text{def}}{=} \mathbb{E}_{X_t \mid x^{t-1}} \left[\ell(\theta; X_t) \right]. \qquad (1)$$

ここで，$\ell(\theta; X_t) \stackrel{\text{def}}{=} -\log p_\theta(X_t \mid x^{t-1})$ は X_t を観測した際にパラメタ θ が受ける損失を表す．以降，損失関数からは X_t を略し，単に $\ell_t(\theta)$ と表記する（添字 t は $X_t \mid x^{t-1}$ の時間変化に依存して損失関数が変化しうることを表す）．

3. 既存手法：vSGD

本節では問題 (1) に対する既存手法である vSGD [Schaul 13] について簡単に説明する．SGD ではパラメタを $\theta_t = \theta_{t-1} - \eta_t \nabla \ell_t(\theta_{t-1})$ と更新するが，vSGD では更新幅 η_t は $\mathcal{L}_t(\theta)$ を貪欲に最小化する様に選ばれる．すなわち，

$$\eta_t^\star = \operatorname*{argmin}_{\eta} \mathbb{E}_{X_t \mid x^{t-1}} \left[\ell_t(\theta_{t-1} - \eta \nabla \ell_t(\theta_{t-1})) \right].$$

これは問題 (1) の実行可能領域 Θ を一次元部分空間 $\{\theta_{t-1} - \eta \nabla \ell_t \in \Theta \mid \eta \in \mathbb{R}\}$ に制限するものであるが，一般には $\eta_t^\star$ は計算することができないので，vSGD では損失関数を二次近似することで $\eta_t^\star = \frac{g_t^2}{h_t v_t}$ という解析解を導

いた．ただし，$g_t \stackrel{\text{def}}{=} \mathbb{E}[\nabla\ell_t(\theta_{t-1})]$，$v_t \stackrel{\text{def}}{=} \mathbb{E}\left[\nabla\ell_t(\theta_{t-1})^2\right]$，$h_t \stackrel{\text{def}}{=} \mathbb{E}[\nabla^2\ell_t(\theta_{t-1})]$ である．

これらの推定量 g_t, v_t, h_t は一般には未知であるので，過去の勾配の観測から推定を行う．従って，問題 (1) は非定常環境下で勾配のモーメントを推定する問題に帰着される．

具体的には，Schaul らは各推定量を適応的移動平均を用いて推定することを提案した．$\overline{g}_t, \overline{v}_t, \overline{h}_t$ をそれぞれある時刻での $\mathbb{E}[\nabla\ell_t(\theta_{t-1})], \mathbb{E}[(\nabla\ell_t(\theta_{t-1}))^2], \mathbb{E}[(\nabla^2\ell_t(\theta_{t-1}))^2]$ の推定量とし，τ_t を時定数パラメタとおく．このとき各推定量は次のように更新される:

$$\begin{aligned}
\overline{g}_t &= (1-\tau_{t-1}^{-1})\overline{g}_t + \tau_{t-1}^{-1}\nabla\ell_t(\theta_{t-1}),\\
\overline{v}_t &= (1-\tau_{t-1}^{-1})\overline{v}_t + \tau_{t-1}^{-1}(\nabla\ell_t(\theta_{t-1}))^2,\\
\overline{h}_t &= (1-\tau_{t-1}^{-1})\overline{h}_t + \tau_{t-1}^{-1}(\nabla^2\ell_t(\theta_{t-1}))^2,\\
\tau_t &= \left(1-\frac{\overline{g}_t^2}{\overline{v}_t}\right)\tau_{t-1}+1.
\end{aligned}$$

vSGD は時定数 τ_t を適応的に調整することで，収束と適応のバランスをとる．最適なパラメタが定常である場合（$\theta_t^\star \approx \theta^\star$）には推定されるパラメタは $\theta^\star$ の周辺に集中することになり，$\overline{g}_t$ は 0 に近づく．従って時定数 τ_t は徐々に増加しモーメント推定量の推定が安定化するので，推定されるパラメタの列が収束に向かう．一方，一定の収束期間の後 $\theta_t^\star$ が $\theta^\star$ から変化する時．g_t も同様に 0 から非零へと変化し，遅かれ早かれ $\overline{g}_t$ を非零へと変化させることとなる．これにより時定数が減少に転じることで，vSGD を適応フェーズへと導く．

この τ_t の更新則は一見妥当なものに思えるが．ヒューリスティクスであるがゆえに適応に失敗する場合があり，収束期間が長いほどその後の適応が遅くなる．実際，収束期間が長ければモーメントの比 $\overline{g}_t/\overline{v}_t$ が小さくなり，その間 τ_t が大きくなり続けるため，$\overline{g}_t$ は勾配 $\nabla\ell_t$ の分布の変化を反映しにくくなり，図 1 からも読み取れるように，$\overline{g}_t$ の推定バイアスが長期間に渡って残留し続ける事となる．

4. 提案手法: Cogra

vSGD の枠組みを利用すると，最適学習率問題は勾配のモーメント推定問題に帰着されることがわかった．従って，我々はどのように良い推定量を構成するかということのみに集中すればよい．

良い推定量を構成する上で問題となるのが，背後の分布が変化しうるということである．つまり，どこまでの過去の観測を推定に利用するかを選択しなければならない．分布が変化している時には，最近の観測のみを用いるべきであるし，分布が変化していなければ，より多くの観測データを用いてより精度の高い推定量を計算すべきである．前章で示したように，vSGD は直感的ではあるがヒューリスティックな推定量を用いているため，目的の推定量の推定に失敗することがあり，結果として予測性能をも劣化させることがある．

我々は推定量の良さを新たに定義することでこの問題に対処する．まず各時刻 t で被る予測損失に関して推定量の誤差 $\eta_t^\star$ による上界を導く (4.1 節)．次に，その上界を毎時刻最小化するような移動平均を用いた平均推定オラクルを定義する (4.2 節)．最後に，オラクルを近似する逐次平均追跡法 (SMT) を示し，SMT を用いて最適な学習率を計算することで，非定常環境のための SGD である Cogra を得る．

4.1 リスク：モーメント推定量の良さの指標

$\eta_t^\star$ の代わりに推定量 $\overline{\eta}_t$ を用いてパラメタを更新すると，期待予測損失は定数 C を除いて $\eta_t^\star$ の推定誤差に比例する：

$$\mathbb{E}_{\overline{\eta}_t}\left[\mathcal{L}_t(\theta_{t-1}-\overline{\eta}_t\nabla\ell_t(\theta_{t-1}))\right] = \frac{hv}{2}r^2(\overline{\eta}_t;\eta_t^\star)+C.$$

ここで，$r(\overline{\eta}_t;\eta_t^\star) = \sqrt{\mathbb{E}_{\overline{\eta}_t}(\overline{\eta}_t-\eta_t^\star)^2}$ は推定量のリスクを表す．各モーメントの推定量に関してある定数 $M \geq 1$ があって $|\overline{g}_t| \leq M$, $M\overline{v}_t \geq v_t$, $M\overline{h}_t \geq h_t$ が成り立つとする．[*1] このとき，$\overline{\eta}_t$ のリスクは個々のモーメント推定量のリスクを用いて抑えることができる：

$$\begin{aligned}
&r(\overline{\eta}_t;\eta_t^*)\\
&\leq \frac{(g_t+M)M^2}{h_t v_t}r(\overline{g}_t;g_t) + \frac{g_t^2M^2}{h_t v_t^2}r(\overline{v}_t;v_t) + \frac{g_t^2M}{h_t^2 v_t}r(\overline{h}_t;h_t). \quad (2)
\end{aligned}$$

これは各モーメント推定量のリスクを抑えることが予測誤差の低減につながる事を意味するので，本研究ではリスクをモーメント推定量の良さの指標として採用する．

4.2 貪欲オラクルの存在とリスクの収束

今，誤差を抑えたい統計量はすべてとある確率変数列の各時刻での平均値の形をしているので，確率変数 $Z_t \in \mathbb{R}^d$ の実現値 z_t を逐次的に受け取ってオンラインで平均 $\mu_t = \mathbb{E}[Z_t]$ をリスク $r(\overline{z}_t;\mu_t)$ を小さくするように推定する汎用の平均推定器を考えたい．

具体的には，次のような移動平均を考える：

$$\overline{z}_0 = \mathbf{0}, \qquad \overline{z}_t = z_t + a_t(\overline{z}_{t-1}-z_t).$$

ここで $a_t \in \mathbb{R}$ を忘却率と呼ぶ．この方法は 2 つの点で今回の問題設定にふさわしい．一つは，$\overline{z}_t$ が再帰によって定義されるため，計算に有限のメモリしか要しないという点である．もう一つは，忘却率を調節することで過去の観測をどの程度反映するかをコントロールすることができるという点である．

いま，逐次リスク最小化問題

$$a_t^\star \stackrel{\text{def}}{=} \operatorname*{argmin}_{a\in\mathbb{R}} r^2(\overline{z}_t;\mu_t)$$

を考える．このとき解はただ一つ存在して，

$$a_t^\star = \frac{\sigma_t^2-\epsilon_t}{\sigma_t^2+\gamma_{t-1}^2+\delta_t^2-2\epsilon_t} \quad (3)$$

と書かれる．これをオラクルレートと呼ぶ．ここで，$\sigma_t^2 = \operatorname{tr}\operatorname{Var}(Z_t)$, $\gamma_t^2 = \operatorname{tr}\operatorname{Var}(\overline{z}_t)$, $\delta_t = \|\mathbb{E}[\overline{z}_{t-1}]-\mu_t\|$ and $\epsilon_t = \operatorname{tr}\operatorname{Cov}(\overline{z}_{t-1},Z_t)$ とおいた．

各時刻の局所的な最適性のみに基づいて導かれたオラクルレートはいくつかの望ましい性質を有する．まず，確率変数列 Z_t が互いに独立で平均 μ_t に変化がなければ，$\overline{z}_t$ のリスクは大域的最適なレートで零に収束する．また，Z_t が互いに独立でなく，平均に変化がある場合にでも，次の定理が示される．

定理．$\overline{C}_\tau \stackrel{\text{def}}{=} \sup_{|s-t|\geq\tau}\frac{|\operatorname{tr}\operatorname{Cov}(Z_s,Z_t)|}{\sigma_s\sigma_t}$ とおき，$\overline{C}_1 < 1$ かつ $\overline{C}_\tau \stackrel{\tau\to\infty}{\longrightarrow} 0$ と仮定する．このとき，平均の全変動 $\sum_{t=1}^\infty \|\mu_{t+1}-\mu_t\|$ が有界であって，分散 σ_t^2 が一様に有界である時，オラクルレートを用いた推定量のリスク $r(\overline{z}_t;\mu_t)$ は零に収束する．

*1 これらの仮定は $\overline{g}_t$ に関して適当な上限を設定し，$\overline{v}_t$ と $\overline{h}_t$ を適当な正の下限で下から抑えることで満たされる．

Algorithm 1 Cogra algorithm

Input: Losses $\{\ell_t\}_{t=1}^{\infty}$, initial parameter θ_0, SMT $\mathcal{A}_0$.
Output: Parameters $\{\theta_t\}_{t=1}^{\infty}$.
for each loss function ℓ_t $(t = 1, 2, \ldots)$ **do**
  Incur loss $\ell_t(\theta_{t-1})$
  Receive forgetting rate: $\overline{a}_{t-1} \leftarrow \mathtt{ask}(\mathcal{A}_{t-1})$
  Update estimates:
  $\overline{g}_t \leftarrow \nabla\ell_t + \overline{a}_{t-1}(\overline{g}_{t-1} - \nabla\ell_t)$,
  $\overline{v}_t \leftarrow \nabla\ell_t^2 + \overline{a}_{t-1}(\overline{v}_{t-1} - \nabla\ell_t^2)$,
  $\overline{h}_t \leftarrow \nabla^2\ell_t + \overline{a}_{t-1}(\overline{h}_{t-1} - \nabla^2\ell_t)$
  Update SMT: $\mathcal{A}_t \leftarrow \mathtt{push}(\mathcal{A}_{t-1}, \nabla\ell_t)$
  Compute learning rate: $\overline{\eta}_t \leftarrow \frac{\overline{g}_t^2}{\overline{h}_t \overline{v}_t}$
  Update parameter: $\theta_t \leftarrow \theta_{t-1} - \overline{\eta}_t \nabla\ell_t(\theta_{t-1})$
end for

この定理は，確率過程 $\{Z_t\}$ がとある混合条件を満たし，推定対象の変化量と分散がそれぞれ有界であるときには，各確率変数が従属していても推定量 $\overline{z}_t$ が真値 μ_t に収束するということをを意味し，ごく一般的な仮定のもとでもオラクルレートを用いた推定量のリスクは零に収束する事がわかる．

4.3 逐次平均追跡法 (SMT)

上で述べたオラクルに基づいて平均 μ_t を推定する方法について示す．オラクルレート $a_t^\star$ は未知の量であるが，式 (3) は確率過程の期待モーメントを用いて書き下すことができることを利用し，期待モーメントを経験的なモーメントで置き換えて近似的にオラクルレートを計算する：

$$\overline{a}_t \stackrel{\text{def}}{=} \frac{\overline{\sigma}_t^2}{\overline{\sigma}_t^2 + \overline{\gamma}_t^2 + \overline{\delta}_t^2}$$

を得る．ここで，ϵ_t については自己相関が十分小さいと仮定して 0 を代入しており，経験モーメントは再帰的に

$$\overline{\sigma}_t^2 = \overline{z^2}_t - \|\overline{z}_t\|^2,\ \overline{\gamma}_t^2 = \overline{\overline{z}^2}_t - \left\|\overline{\overline{z}}_t\right\|^2,\ \overline{\delta}_t = \left\|\overline{\overline{z}}_t - \overline{z}_t\right\|,$$

$$\begin{aligned}
\overline{\overline{z}}_t &= \overline{z}_t + \overline{a}_{t-1}(\overline{\overline{z}}_{t-1} - \overline{z}_t),\\
\overline{z^2}_t &= \|z_t\|^2 + \overline{a}_{t-1}(\overline{z^2}_{t-1} - \|z_t\|^2),\\
\overline{\overline{z}^2}_t &= \|\overline{z}_t\|^2 + \overline{a}_{t-1}(\overline{\overline{z}^2}_{t-1} - \|\overline{z}_t\|^2)
\end{aligned}$$

と計算される．ただし，最初の忘却率については $\overline{a}_1 = 1/2$ と初期化する．このアルゴリズムを逐次平均追跡法 (SMT) と名付ける．SMT を用いることで平均の推定量の列 $\{\overline{z}_t\}_{t=1}^{\infty}$ をオンラインで計算することができる．

4.4 Cogra

学習率の自動決定に SMT を用いた SGD，Cogra のアルゴリズムを Algorithm 1 に示す．ここで，3 つの推定量 $\overline{g}_t, \overline{v}_t, \overline{h}_t$ に関して，同じ忘却率 $\overline{a}_t$ を用いた．これは同じ関数 $\hat{\mathcal{L}}_t(\theta) = \sum_{s\le t}\prod_{s<i\le t}(1-a_i)a_s\ell_s(\theta)$ の勾配や曲率のモーメントの推定量を用いて最適な学習率を計算することに対応し，それぞれ個別の忘却率を用いる場合と比較して推定を安定させることができると考えられるためである．また，$\overline{g}_t$ の忘却率に統一したのは，式 (2) からわかるように，3 つのリスクのうち収束期において最も支配的な項を減少させるためである．

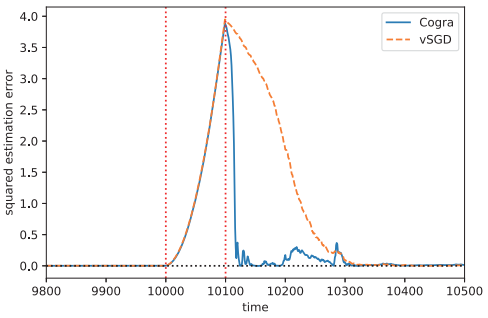


図 1: g_t **の推定誤差**．x 軸と y 軸はそれぞれ時間と g_t の二乗推定誤差を表す．垂直な点線は変化の開始時刻と終了時刻を表す．Cogra (青実線) は vSGD (橙破線) と比較して有意に早い段階で推定誤差を収束させていることがわかる．

5. 実験

Cogra の有効性について，(i)SMT のモーメント予測の精度および (ii)SMT を採用したことによる予測性能の向上について検証した．すべての実験でベクトル自己回帰モデル (VAR) [Lütkepohl 05] を用いて予測を行った．

5.1 SMT の性能

SMT のモーメントの推定精度を測るため．$d = 1$, $p = 0$, $\mu_t = -1 \to 1$ と徐々に変化させて SMT の推定誤差を vSGD のそれと比較した（図 1）．SMT の方が全体で 60%ほど累積推定誤差が小さい事がわかる．従って，**(Q1)** は肯定的に解決された．

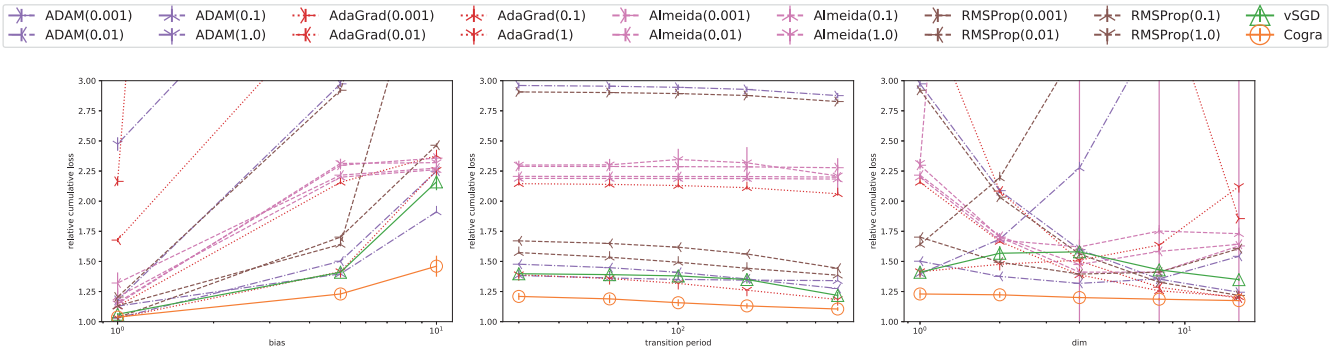
5.2 予測性能

次に，SMT が予測性能にどれほど貢献するかについて人工データと実データを用いて調べた．比較手法は AdaGrad[Duchi 11], ADAM[Kingma 14], Almeida[Almeida 99], RMSProp[Tieleman 12], そして vSGD を採用し，ハイパーパラメタがあるものについては適当なグリッド上でチューニングした．vSGD に関しては τ_t が小さい時に安定しないという既知の問題を避けるため，$\tau_t \ge 2$ なるとなるように更新ごとに射影した．

各実験では，相対累積予測誤差を性能の指標とした．ベンチマークとしては，人工データでは真の生成分布を既知としたときの予測，実データでは学習率 0.1 の AdaGrad による予測を用いた．

人工データの予測 人工データでは，各手法の予測性能の時系列や変化のタイプ (次元，変化期間の長さ，変化の大きさ) に対する依存性を比較した（図 2）．全体を通して vSGD に対して Cogra は予測性能を改善し，よりロバストな予測を得ることができていることがわかる **(Q2)**．また特に，Cogra は変化の程度が大きい時に他手法よりも優れた予測性能を発揮することがわかった **(Q3)**．

実データの予測 最後に，Cogra の実データにおける予測性能を検証した．予測モデルには $p = 3$ の VAR モデルを用いた．用いたデータは ActivityRecognition [Casale 12], EEGEyeState, GasSensorArray [Fonollosa 15] の三種類で，すべて UCI レポジトリ [Lichman 13] から取得した．結果は表 1 の通りで，すべてのデータにおいて Cogra が最高性能を達成しており，次に性能の良い vSGD と比較しても累積予測損失の意味で少なくとも 18%以上改善していることがわかる．



(a) 変化量 μ に対する依存性 ($d = 1$, $T = 0$). (b) 変化期間 T に対する依存性 ($d = 1$, $\mu = 5$). (c) 時系列の次元 d に対する依存性 ($T = 0$, $\mu = 5$).

図 2: **人工データにおける予測性能の依存性.** 各エラーバーは標準偏差を表す.

表 1: **相対累積予測損失.** 各テーブルごとに，第 1 行は SGD の手法，第 2 はハイパーパラメタの設定，第 3 行から第 7 行まではデータセットごとの相対累積予測損失を表す.

	AdaGrad (initial LR)				ADAM (initial LR)				Almeida (initial LR, hyper-LR)		
	0.001	0.01	0.1	1.0	0.001	0.01	0.1	1.0	(10e-9, 10e-3)	(10e-9, 10e-2)	(10e-9, 10e-1)
A(1)	257	3.62	1.0	5.35	9.56	1.95	6.07	138	3.36	3.02	2.01
A(2)	144	2.56	1.0	4.18	5.60	1.76	7.15	125	2.50	2.27	1.63
A(3)	236	4.07	1.0	5.23	9.81	2.06	5.35	68.9	3.29	2.99	2.06
EEG	16.9	0.68	1.0	77.6	2.76	1.02	9.66	945	0.485	0.483	0.482
GAS	8.79	3.10	1.0	48.1	6.15	1.87	3.98	287	1.06e+85	9.82e+65	1.73e+20

	RMSProp (initial LR)					vSGD	Cogra
	0.0001	0.001	0.01	0.1	1.0		
A(1)	80.2	7.76	3.31	200	2.00e+4	0.79	**0.621**
A(2)	46.4	4.60	2.32	110	1.10e+4	0.85	**0.701**
A(3)	74.4	7.84	2.55	120	1.20e+4	0.76	**0.595**
EEG	20.8	2.13	31.6	3.13e+3	3.13e+5	0.30	**0.182**
GAS	9.16	5.39	7.92	695	6.94e+4	0.84	**0.267**

6. 結論と今後の課題

本稿では非定常時系列のオンライン予測問題を扱った．vSGD において提案されたように，この問題は確率的勾配のモーメント推定問題に帰着される．本研究ではヒューリスティックに設計された vSGD のモーメント推定がバイアスをもち，予測性能に関しても悪影響を与えること発見した．これを解決するために，本研究では SMT と呼ばれるモーメント推定量を提案し，vSGD のモーメント推定を SMT で置き換えることで，ハイパーパラメタなしで変化に適応する SGD，Cogra を得た．実験では，Cogra は vSGD を含む既存手法の予測性能を全てのケースで改善し，特に変化量が大きい時系列においてより性能が優れることがわかった．

今後の方向性としては，Cogra をより VAR 以外の複雑な目的関数に対して応用すること，および強化学習など，環境の変化だけでなく，パラメタの変化に応じても目的関数が変化するような問題設定に拡張することがあげられる．

参考文献

[Almeida 99] Almeida, L. B., Langlois, T., Amaral, J. D., and Plakhov, A.: Parameter Adaptation in Stochastic Optimization, in *On-Line Learning in Neural Networks*, pp. 111–134, Cambridge University Press (1999)

[Casale 12] Casale, P., Pujol, O., and Radeva, P.: Personalization and user verification in wearable systems using biometric walking patterns, *Personal and Ubiquitous Computing*, Vol. 16, No. 5, pp. 563–580 (2012)

[Duchi 11] Duchi, J., Hazan, E., and Singer, Y.: Adaptive subgradient methods for online learning and stochastic optimization, *Journal of Machine Learning Research*, Vol. 12, pp. 2121–2159 (2011)

[Fonollosa 15] Fonollosa, J., Sheik, S., Huerta, R., and Marco, S.: Reservoir computing compensates slow response of chemosensor arrays exposed to fast varying gas concentrations in continuous monitoring, *Sensors and Actuators B: Chemical*, Vol. 215, pp. 618–629 (2015)

[Kingma 14] Kingma, D. and Ba, J.: Adam: A method for stochastic optimization, *arXiv preprint arXiv:1412.6980* (2014)

[Lichman 13] Lichman, M.: UCI Machine Learning Repository (2013)

[Lütkepohl 05] Lütkepohl, H.: *New Introduction to Multiple Time Series Analysis*, Part I, Springer Berlin Heidelberg (2005)

[Schaul 13] Schaul, T., Zhang, S., and LeCun, Y.: No more pesky learning rates, in *Proceedings of the 30th International Conference on Machine Learning* (2013)

[Tieleman 12] Tieleman, T. and Hinton, G.: Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude, COURSERA: Neural Networks for Machine Learning (2012)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

スパース動的モード分解におけるモード選択の統計的評価

Statistical Evaluation for Mode Selection in Sparsity-promoting Dynamic Mode Decomposition

平岡 将史 *1　河原 吉伸 1,2　鷲尾 隆 1
Masashi Hiraoka[1]　Yoshinobu Kawahara[1,2]　Takashi Washio[1]

[1]大阪大学 産業科学研究所
[1]The Institute of Scientific and Industrial Research, Osaka University

[2]理化学研究所 革新知能統合研究センター
[2]Center for Advanced Intelligence Project, RIKEN

Sparsity-promoting dynamic mode decomposition (SP-DMD) is a data-driven method for estimating a modal representation of a nonlinear dynamical system, where the modes are selected via l_1-regularization depending on the tradeoff between the quality of the representation and the number of the modes. However, the way to statistically evaluate modes selected by SP-DMD is not established. If statistical evaluation is not performed, we may not specify issues caused by different reasons such as noise and overfitting. In this paper, we propose a method to statistically evaluate modes selected by SP-DMD. We develop the method based on the combination of bootstrap and SP-DMD.

1. はじめに

近年，データ駆動型の解析アルゴリズムが注目を集めている．高次元データ収集の容易化とコンピュータの進化により，データ駆動型のアルゴリズムにより複雑なダイナミクスの時間，空間的特徴を取り出し構造推定や未来予測を行うことができるようになった．動的モード分解 (Dynamic Mode Decomposition,DMD) は，行列の特異値分解，固有値分解を用いて時系列データを空間的な情報を持つ動的モードと各動的モードの減衰 (増幅) 率，各動的モードの振幅に分解する．DMD は流体解析の分野で提案されてから様々な分野に応用されており，またその拡張としてパラメータの事前分布を導入したベイズ的動的モード分解 (Bayesian Dynamic Mode Decomposition)[1] やスパースなモデルの推定を行うスパース動的モード分解 (Sparsity-promoting Dynamic Mode Decomposition,SP-DMD)[2] がある．SP-DMD では，DMD のアルゴリズムに $L1$ 正則化項を加えることによって，DMD で求めた動的モードからデータへの寄与度が高い動的モードを選択し，ダイナミクスのモデルを推定する．

しかし SP-DMD では，ダイナミクスをよりスパースに推定するアルゴリズムは示されているが，推定したモデルの信頼性に関する考察はない．モデル推定においては推定したモデルにどの程度の信頼性があるのかを統計的に評価することは不可欠である．もしそうした評価が行われなければ，観測ノイズの影響や過学習といった問題を発見することができない．

そこで本研究では，データの定常性を仮定しサブシーケンスを用いたブートストラップ法と SP-DMD を組み合わせることで SP-DMD により推定したモデルの統計的評価を行う手法を提案する．サブシーケンスに対してブートストラップ法における繰り返しごとに SP-DMD による解析を行うのではなく，動的モードの選択によるモデル推定の部分のみを繰り返す手法によって全データから推定したモデルの不確かさを統計的に評価する．

連絡先: 平岡将史，大阪大学産業科学研究所，
〒 567-0047 大阪府茨木市美穂ヶ丘 8-1
m.hiraoka@ar.sanken.osaka-u.ac.jp

本稿の構成は以下の通りである．2 章では，DMD とその拡張である SP-DMD のアルゴリズムを示す．3 章では，3.1 節で一般的なブートストラップ法について述べる．3.2 節で SP-DMD にブートストラップ法が適用できること，ブートストラップ標本としてサブシーケンスを使用することが妥当であることを示す．3.3 節で提案手法について述べる．4 章で SP-DMD によるモード選択に提案手法によって一定の示唆が得られたことを示し，5 章でまとめと課題について述べる．

2. スパース動的モード分解

DMD では時系列データを空間的な情報を持つ動的モードと各動的モードの減衰 (増幅) 率，各動的モードの振幅に分解する．本章では DMD とその拡張である SP-DMD のアルゴリズムについて説明する [2]．DMD では，時系列データ $\Psi = \{\psi_0 \quad \psi_1 \quad \cdots \quad \psi_N\}$ から次のデータ行列を生成する．

$$\Psi_0 = \{\psi_0 \quad \psi_1 \quad \cdots \quad \psi_{N-1}\} \in \mathbb{C}^{M\times N} \tag{1}$$

$$\Psi_1 = \{\psi_1 \quad \psi_2 \quad \cdots \quad \psi_N\} \in \mathbb{C}^{M\times N} \tag{2}$$

$\Psi_1 = A\Psi_0$ を満たすような行列 $A \in \mathbb{C}^{M\times M}$ を考え，Ψ_0 の特異値分解を計算する．

$$\Psi_0 = U\Sigma V^* \tag{3}$$

ただし，$\Sigma \in \mathbb{C}^{r\times r}$ は特異値を対角成分に持つ対角行列，$U \in \mathbb{C}^{M\times r}, V \in \mathbb{C}^{r\times N}$ である．

$$A \approx UF_{dmd}U^* \tag{4}$$

を満たす $F_{dmd} \in \mathbb{C}^{r\times r}$ を考えることで，次元削減した線形空間で A を考えることができる．F_{dmd} は

$$\min_A \|\Psi_1 - A\Psi_0\|_F^2 \tag{5}$$

に $\Psi_0 = U\Sigma V^*$ と $A = UF_{dmd}U^*$ を代入することによって求められる．

$$F_{dmd} = U^*\Psi_1 V\Sigma^{-1} \tag{6}$$

U の列ベクトルで張られる線形空間において，即ち $\psi_t \approx Ux_t$ となる線形空間においてデータの時間変化は

$$x_{t+1} = F_{dmd} x_t \tag{7}$$

と表される．以下の通り F_{dmd} の固有値分解を計算する．

$$F_{dmd} = \underbrace{\begin{bmatrix} y_1 & \cdots & y_r \end{bmatrix}}_{Y} \underbrace{\begin{bmatrix} \mu_1 & & \\ & \ddots & \\ & & \mu_r \end{bmatrix}}_{D_\mu} \underbrace{\begin{bmatrix} z_1^* \\ \vdots \\ z_r^* \end{bmatrix}}_{Z^*} \tag{8}$$

ただし，$\{y_1, \ldots, y_r\}$ は F_{dmd} の固有値 $\{\mu_1, \ldots, \mu_r\}$ に対応する固有ベクトル，$\{z_1, \ldots, z_r\}$ は F_{dmd}^* の固有値 $\{\overline{\mu}_1, \ldots, \overline{\mu}_r\}$ に対応する固有ベクトルである．(7)，(8) よりデータは初期値 x_0 を用いて

$$x_t = Y D_\mu^t Z^* x_0 = \sum_{i=1}^{r} y_i \mu_i^t z_i^* x_0 = \sum_{i=1}^{r} y_i \mu_i^t \alpha_i \tag{9}$$

と書くことができる．ただし，$\alpha_i = z_i^* x_0$．α はデータの初期値を反映した値であるが，各動的モードの振幅を表した値と解釈することもできる．U を左側からかけることにより，

$$\psi_t \approx Ux_t = \sum_{i=1}^{r} \phi_i \mu_i^t \alpha_i \tag{10}$$

ただし，$\phi_i = Uy_i$．この両辺のフロベニウスノルムの差の最小化問題を解いて最終的な α を決定する．即ち，上式を行列形式で表した

$$\begin{aligned}
\Psi_0 &= \Phi D_\alpha V_{and} \qquad (11)\\
\Phi &:= \begin{bmatrix} \phi_1 & \phi_2 & \cdots & \phi_r \end{bmatrix},\\
D_\alpha &:= \begin{bmatrix} \alpha_1 & & & \\ & \alpha_2 & & \\ & & \ddots & \\ & & & \alpha_r \end{bmatrix},\\
V_{and} &:= \begin{bmatrix} 1 & \mu_1 & \cdots & \mu_1^{N-1} \\ 1 & \mu_2 & \cdots & \mu_2^{N-1} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & \mu_r & \cdots & \mu_r^{N-1} \end{bmatrix}.
\end{aligned}$$

を用いて表した下式の最小化問題を解いて最終的な α を決定する．

$$\min_{\alpha} \quad \|\Psi_0 - \Phi D_\alpha V_{and}\|_F^2 \tag{12}$$

$\Psi_0 = U\Sigma V^*$ と $\phi_i = Uy_i$ を用いれば，この最小化問題は特異値分解による次元削減を利用した形に帰着できる．

$$\min_{\alpha} \quad J(\alpha) := \|\Sigma V^* - Y D_\alpha V_{and}\|_F^2 \tag{13}$$

この最小化問題の目的関数 $J(\alpha)$ は下式と等価である．詳細な証明については [2] を参照されたい．

$$\begin{aligned}
J(\alpha) &= \alpha^* P \alpha - q^* \alpha - \alpha^* q + s \qquad (14)\\
P &:= (Y^* Y) \circ (\overline{V_{and} V_{and}^*}),\\
q &:= \overline{diag\,(V_{and}\,(\Sigma V^*)^*\, Y)},\\
s &:= trace(\Sigma^* \Sigma)
\end{aligned}$$

ただし，$\circ$ は二つの行列の要素ごとの掛け算を表し，M^* は行列 (ベクトル)M を共役転置した行列 (ベクトル)，$\overline{M}$ は行列 (ベクトル)M の複素共役な行列 (ベクトル) を表す．また，ベクトル M に対して $diag(M)$ はベクトル M の要素を対角成分に並べた対角行列を表し，行列 M に対して $diag(M)$ は行列 M の対角成分を抜き出してできるベクトルを表す．

最終的に最小化問題の答え α_{dmd} は (14) 式を最小化する α で，

$$\alpha_{dmd} \quad = \quad P^{-1} q \tag{15}$$

となる．

DMD では動的モードは r 個計算されるが，全ての動的モードが同等にデータに寄与しているわけではない．そこでデータへの寄与が小さな動的モードを取り除き，スパースなモデル推定を行うために提案された拡張が SP-DMD である．DMD のアルゴリズムに $L1$ 正則化項を加えることにより，ダイナミクスのモデル選択をより簡単に行うことができる．具体的には動的モードの係数を決定する (13) 式に $L1$ 正則化項を加えた (16) 式を解いて α を決定する．

$$\min_{\alpha} \quad J(\alpha) + \gamma \sum_{i=1}^{r} |\alpha_i| \tag{16}$$

3. 提案手法

SP-DMD によって，ダイナミクスのモデル推定を容易に行うことが可能になった．しかしモデル推定に不可欠である，推定したモデルの統計的な評価を行う手法は考察されていない．そこで本研究では，サブシーケンスを用いたブートストラップ法により各動的モードの係数 α_i を調べ，SP-DMD によるモデル推定の統計的評価を行う手法を提案する．

3.1 ブートストラップ法

ブートストラップ法は，リサンプリング法と呼ばれる統計学の手法の一種である．複雑な理論を知らずとも，コンピュータによる反復計算によって統計量の偏りや分散，あるいは分布の推定を行うことができる．そのアルゴリズムは，観測データ

$$D = \{d_1, d_2, \cdots, d_N\} \tag{17}$$

に対して $\{1, 2, \cdots, n\}$ から等確率でランダムに整数を選ぶ．これを N 回繰り返して得られた整数列を $\{i_1, i_2, \cdots, i_N\}$ とする．ある整数が複数回選ばれてもよい．得られた整数列の要素を添え字とする要素を観測データから取り出してできるデータ集合 $\{d_{i_1}, d_{i_2}, \cdots, d_{i_N}\}$ を，

$$D^* = \{d_{i_1}, d_{i_2}, \cdots, d_{i_N}\} \tag{18}$$

とする．B 回繰り返して得られた B 個のデータを $\left\{D^{*1}, D^{*2}, \cdots, D^{*B}\right\}$ とする．B 個のデータからそれぞれ統計量を計算する．

ブートストラップ法の基本的なアイデアは，こうして得られた統計量のばらつきが，母集団から幾度もデータをサンプリングして統計量を計算した場合のばらつきと近いものになっているというものである．母集団の分布を仮定できない場合や複雑な統計量の分布の推定が必要な場合に，理論ではなくコンピュータによる反復計算によってそれらを近似できることがブートストラップ法の利点である．

一方でブートストラップ法はあらゆる問題に適用できるわけではない [3]．多くの統計的推測の問題は，未知の分布関数 F

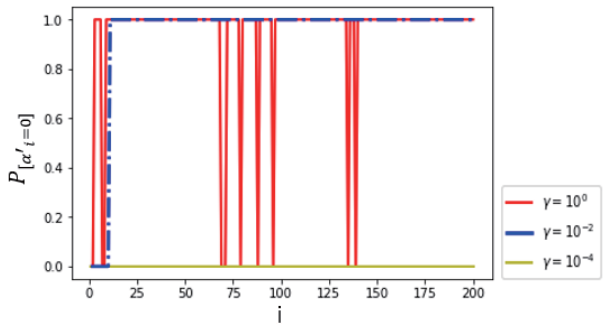


図 1: 全データに対して SP-DMD による解析を行った結果

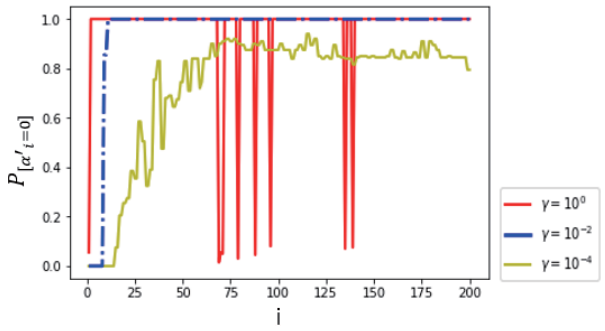


図 2: $s = 100$ の場合の提案手法の実行結果

に従う互いに独立な確率変数 $Y_1, \cdots, Y_n$ に基づいて，F に依存するパラメータ $\theta = \theta(F)$ を推測する問題として定式化できる．ここで，θ が F のみ，即ち未知の母集団のみに従うパラメータであることが重要な点である．例えば，測定誤差を伴う回帰係数の偏りなどはこれを満たさない．ブートストラップ法がうまく機能するための 1 つの十分条件は，パラメータ $\theta = \theta(F)$ が，F の連続的な変化に対して連続的に変動することである．すなわち F に近い分布関数 $F' = (1-\epsilon)F + \epsilon G$ を考えたとき，パラメータ $\theta(F')$ も $\theta(F)$ に近く，$\theta(F') = \theta(F) + o(\epsilon)$ が成り立つことである．ここで，$o(\epsilon)$ は，ϵ が 0 に近づくとき 0 に近づく量を表している．しかし，この条件は分散の推定の場合などには必ずしも必要でない．

いま $\theta = \theta(F)$ の推定量を $\hat{\theta} = \hat{\theta}(Y_1, \cdots, Y_n)$ とする．また F_n を，下式で定義される経験分布関数とする

$$F_n = \frac{1}{n}\sum_{j=1}^{n} \delta(Y_j \leq y) \tag{19}$$

実際のデータ解析においては，$\hat{\theta}$ は $\hat{\theta} = \theta(F_n)$ が使われることが多い．

さて，例えば推定量 $\hat{\theta}$ を用いて θ を推定する際には，推定量 $\hat{\theta}$ の良さを評価しなければならない．また θ に関する仮説を検証する必要もしばしば起こる．このような問題は適当な関数 $T(\hat{\theta}, F) = t(\hat{\theta}, \theta(F))$ に対して期待値

$$H(F) = E_F[T(\hat{\theta}(Y_1, \cdots, Y_n), F)] \tag{20}$$

を計算する問題に帰着できる．ただし，E_F は分布関数 F の下での期待値を表し，また関数 $T(\cdot, \cdot)$ は問題に応じて決められるものである．

ブートストラップ法は，与えられた問題が (20) によって定式化できる場合，この $H(F)$ を推定するための一般的な手法である．

また，通常経験分布関数 F_n が真の分布関数 F の良い近似となっているためにブートストラップ法が多くの局面で機能することも補足として付け加える．これは即ち，ある程度大きな標本数が必要であることを意味する．

3.2 本研究におけるブートストラップ法

3.1 節でブートストラップ法が適用可能な問題について議論したが，本節では SP-DMD に対してブートストラップ法が適用可能か議論する．

動的モードの振幅 α がダイナミクスのみに依存することは明らかである．また多くの一般的な場合，ダイナミクスの連続的な変化に対して α の変化も連続的であることが予想される．また，本研究は定性的な試みに留まっているために定式化できないが，α の推定量の良さを評価するものであるから (20) 式の形に帰着することは明らかと言ってもよいであろう．

また，ブートストラップ標本は通常時系列データの連続性を保存しない．本研究では時系列データの連続性を保存する為，ブートストラップ標本としてデータのサブシーケンスを用いる．サブシーケンスとは時系列データの一部分を抜き出したものであり，本研究ではサブシーケンスの長さはハイパーパラメータである．

ブートストラップ標本としてサブシーケンスを用いることの妥当性について補足する．時系列全データ $\{\psi_0 \quad \psi_1 \quad \cdots \quad \psi_N\}$ の元であるダイナミクスが定常状態であると仮定すれば，一定以上の長さのサブシーケンスの元であるダイナミクスはすべて一意な組み合わせのモードによって構成されている．各サブシーケンスの初期値の違いを調整することでサブシーケンス一つ一つをダイナミクスの特徴を反映したブートストラップ標本として用いることができる．

3.3 提案手法

本研究における提案手法ではまず，時系列データ

$$\Psi = \{\psi_0, \psi_1, \cdots, \psi_N\} \tag{21}$$

に対して SP-DMD を適用して解析を行う．x をサブシーケンスの長さ，t' を $0 \leq t' \leq N - x$ を満たすランダムな整数とする．x, t' を用いて作成したサブシーケンス

$$\Psi_x = \{\psi_{t'} \quad \psi_{t'+1} \quad \cdots \quad \psi_{t'+x}\} \tag{22}$$

を用いて，SP-DMD の動的モードの選択部分だけを実行し，各動的モードの係数 α を求める．即ち

$$\min_{\alpha} \quad \|\Psi_x - \Phi D_\alpha V'_{and}\|_F^2 + \gamma \sum_{i=1}^{r} |\alpha_i| \tag{23}$$

によって各動的モードの係数を決定する．ただし，V'_{and} は V_{and} を左から x 列取り出したものである．(23) 式の第一項

$$\|\Psi_x - \Phi D_\alpha V'_{and}\|_F^2 \tag{24}$$

は左から U^* をかけることで通常の DMD と同様に次元削減を利用した形に帰着できる．

$$J'(\alpha) := \|U^*\Psi_x - Y D_\alpha V'_{and}\|_F^2 \tag{25}$$

とすると，全データの場合と同様に $J'(\alpha)$ は

$$\begin{aligned} J'(\alpha) &= \alpha^* P' \alpha - q'^* \alpha - \alpha^* q' + s' \qquad (26) \\ P &:= (Y^* Y) \circ (\overline{V_{and} V_{and}^*}), \\ q &:= \overline{diag\,(V_{and}\,(U^* \Psi_x)^*\, Y)}, \\ s &:= trace(\overline{U^* \Psi_x (U^* \Psi_x)^*}) \end{aligned}$$

と表すことができ，最小化問題の答え α' は (25) 式を最小化する α で，

$$\alpha' = P'^{-1} q' \qquad (27)$$

となる．(22) 式から (26) 式を B 回繰り返し (t' は繰り返しごとにランダムに選ぶ)，各回において各動的モードの係数 α'_i が 0 であるかどうか調べる．

α'_i が 0 である回数が多ければ多いほどその動的モードが含まれるモデルの不確かさは大きい．例えば，B 回の繰り返し全てにおいて $\alpha'_1 = 0$ であれば，データの元となったダイナミクスが ϕ_1 を含んだモデルであるという結論には大きな不確かさが伴う．

4. 実験結果

実験データは [4] により生成された人工データに $[(-5) \times 10^{-5}, 5 \times 10^{-5}]$ の一様分布乱数をノイズとして加えたデータを用いた．

実験結果の評価指標として，各動的モードの係数 α'_i が 0 であるかどうか B 回調べたうち α'_i が 0 であった回数を $B_{[\alpha'_i=0]}$ とした時，$P_{[\alpha'_i=0]} = B_{[\alpha'_i=0]}/B$ で定義される $P_{[\alpha'_i=0]}$ を調べる．$P_{[\alpha'_i=0]}$ が高いほど，サブシーケンスの中に i 番目の動的モードが含まれる確率が低いことを示す．

図 1 は全データに対して SP-DMD を実行した結果である．横軸は各動的モードの添え字であり，DMD によって r 個求めたうちのどの動的モードであるかを表している．縦軸は $P_{[\alpha'_i=0]}$ である．$L1$ 正則化項の係数の大きさによって異なる折れ線が引かれている．全データを解析した結果は $P_{[\alpha'_i=0]} = 0$ もしくは $P_{[\alpha'_i=0]} = 1$ であり，$L1$ 正則化項の係数の大きさによって異なるモデルが選択されている ($P_{[\alpha'_i=0]} = 0$ を満たす動的モードによってダイナミクスが構築されていると推定している) ことがわかる．図 2 は $x = 100$ の場合の提案手法の実行結果である．図 1 と図 2 を比較すると，同じ $L1$ 正則化項の係数であっても，全データに SP-DMD を用いて求めたある動的モードがあらゆるサブシーケンスの中に存在するわけではないこと，また存在する確率がわかる．

5. むすび

提案手法により，SP-DMD のモデル選択の評価を単一データから行った．SP-DMD のモデル選択について，各動的モードがサブシーケンス中に存在する確率という形で一定の指標を与えた．サブシーケンス中に存在する確率が低い動的モードを用いたモデルの推定には大きな不確かさが伴うと言える．一方で，各動的モードがサブシーケンス中に存在するかどうかという定性的な評価に留まった為，各動的モードの振幅の信頼区間を求めるなど定量的な評価を行うことが今後の課題である．

参考文献

[1] T. Takeishi, Y. Kawahara, Y. Tabei, T. Yairi. *Bayesian dynamic mode decomposition.* Proc. of the 26th Int'l Joint Conf. on Artificial Intelligence (IJCAI'17), pp.2814-2821, 2017.

[2] Mihailo R. Jonanović, Peter J. Schmid, Joseph W. Nichols. *Sparsity-promoting dynamic mode decomposition.* Phisics of Fludis 26, 024103.2014.

[3] 汪金芳， 田栗正章， 手塚集， 樺島祥介， 上田修功. 計算統計 I:確率計算の新しい手法．岩波書店．2003.

[4] J. Nathan Kutz, Steven L. Brunton, Bingni W. Brunton, Joshua L.Proctor. *Dynamic Mode Decomposition: Data-Driven Modeling of Complex Systems.* Society for Industrial and Applied Mathematics.2016. pp151, ALGORITHM9.6.getSparseData.m.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

系列生成器の訓練のための エキスパート系列に基づく報酬関数の学習方法の提案

Expert-based reward function training: the novel method to train sequence generators

冨山　翔司 *1　　岩澤　有祐 *1　　松尾　豊 *1
Joji Toyama　　Yusuke Iwasawa　　Yutaka Matsuo

*1東京大学松尾研究室
Matsuo lab, The University of Tokyo

The training methods of sequence generator with a combination of GAN and policy gradient has shown good performance. In this paper, we propose expert-based reward function training: the novel method to train sequence generator. Different from previous studies of sequence generation, expert-based reward function training does not utilize GAN's framework. Still, our model outperforms SeqGAN and a strong baseline, RankGAN.

1. Introduction

Generating sequential data is one of the main areas of research in machine learning. Recently, sequence generator training with a combination of generative adversarial nets (GANs) (Goodfellow et al., 2014) and policy gradient (Sutton et al., 2000) has shown good performances, such as Yu et al. (2017); Lin et al. (2017); Guo et al. (2018). Those studies employ a discriminator which is trained to discriminate between a true sequence and a generated sequence, and a generator is trained with policy gradient by treating the discriminator as the reward function.

In this study, we propose expert-based reward function training. In expert-based reward function training, we train the reward function without the generator's samples. Instead, we prepare a proposal distribution which produces a negative sequence given an expert (or true) sequence. The reward function is trained to discriminate between an expert sequence and a sequence from a proposal distribution. Unlike previous studies (Lin et al., 2017; Guo et al., 2018; Yu et al., 2017), expert-based reward function is not a kind of GAN frameworks. Although GAN framework has an advantage that a reward function is simultaneously trained with a generator's performance, the training of the generator frequently fails because of an instability of the GAN framework. Expert-based reward function training prioritizes executing stable training of the generator over taking an advantage of GAN framework.

We conducted experiments based on synthetic data to investigate the effectiveness of expert-based reward function training. As an evaluation method, we employ oracle negative log likelihood (NLL) in synthetic data. We show that our model outperform SeqGAN. We also show that our model outperforms a strong baseline, RankGAN.

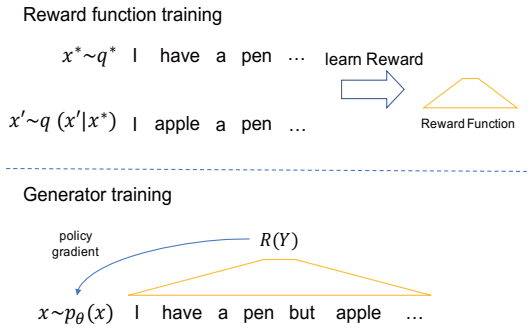


図 1: Proposed training method. A reward function is trained to discriminate between a sequence from real data and a sequence from a proposal distribution. Then, a generator is trained with policy gradient.

2. Expert-based reward function training

SeqGAN employs a GAN framework. Although GAN has shown great success, it has also been reported that its training is difficult (Arjovsky & Bottou, 2017). In expert-based reward function training, reward functions are trained by discriminating between expert data and negative data produced from the proposal distribution. Expert-based reward function training does not use the generator's samples at all; therefore, it is not a kind of GAN frameworks. Figure 1 shows the overall proposed training method.

First, we need to prepare the proposal distribution. In this study, we determine the proposal distribution as

$$q(x|x^*) = \frac{1}{Z}\exp(\frac{r'(x,x^*)}{\tau}) \quad (1)$$

where $r'(x,x^*)$ is a prior reward function. Specifically, we chose negative hamming distance from real data as $r'(x,x^*)$. In this setting, sampling from $q(x|x^*)$ can be easily done

連絡先: 冨山翔司，東京大学松尾研究室，toyama@weblab.t.u-tokyo.ac.jp

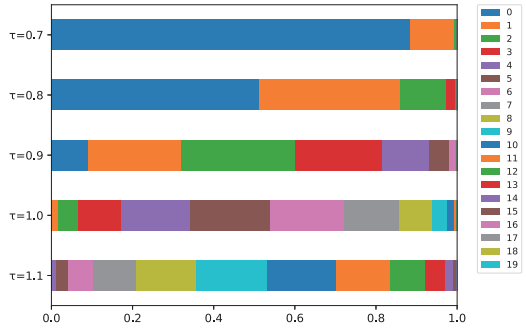


図 2: Fraction of different number of hamming distance applied to a sequence of length 20 and 5,000 vocabulary for different τ. As τ increases, a proposal distribution produces samples that are farther from experts.

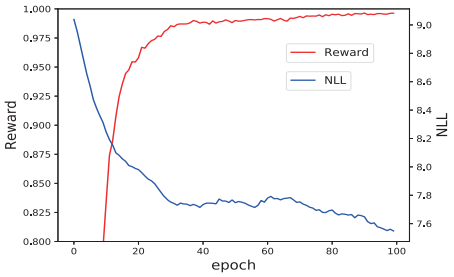


図 3: Plots of reward and NLL during the generator's training. We can see that the generator is properly optimized w.r.t. the reward function, and as the returned reward increases, oracle NLL decreases.

as Norouzi et al. (2016) has shown. τ serves as a hyperparameter that controls a smoothness of a proposal distribution around the experts. Figure 2 shows the fraction of different numbers of negative hamming distance applied to a sequence of length 20 and 5,000 vocabulary for different values of τ.

Then, we train a reward function $r(x)$ by discriminating between a positive sequence from real data distribution $x^* \sim q^*$ and a sequence from proposal distribution $x' \sim q(x'|x^*)$. $r(x)$ maximizes the following objective

$$L_D = E[\log r(x^*)]_{x^* \sim q^*} + E[\log(1 - r(x'))]_{x' \sim q(x'|x^*)}. \quad (2)$$

After a training converges, we train a sequence generator with policy gradient to maximize the obtained reward function $r(x)$.

In expert-based reward function training, a reward function is trained to discriminate between a sequence from $q^*(x)$ and $q(x)$. It suggests that the density ratio of $q^*(x)$ and $q(x)$ is estimated, and used as a reward. If $q(x)$ is too close to $q^*(x)$, the density ratio is estimated on the samples which are very close to the experts. If $q(x)$ is far different from $q^*(x)$, however, the density ratio around experts are not well estimated. Therefore, it is important to make $q(x)$ produce the samples that are at a proper distance from the experts so that p_θ can get the good reward signals. The choice of eq.(1) with a negative hamming distance as $r'(x, x^*)$ is suitable in this sense, because we can control a smoothness around an expert by changing τ as shown in figure 2.

3. Related work

Sequence generative models trained with a combination of a GAN framework and a policy gradient have shown good performance. SeqGAN firstly proposed this training framework(Yu et al., 2017). Some variants of SeqGAN are proposed recently. Lin et al. (2017) proposed RankGAN, in which an original binary classifier discriminator is replaced with a ranking model by taking a softmax over the expected cosine distances from the generated sequences to the real data. Guo et al. (2018) proposed LeakGAN. In LeakGAN utilizes the techniques of hierarchical reinforcement leaning. A discriminator extracts information of uncompleted sentence, and given its information, a manager provides sub-goal to a worker. Different from those methods, expert-based reward function training is not a kind of GAN frameworks.

Norouzi et al. (2016) proposed reward augmented maximum likelihood (RAML). Norouzi et al. (2016) use a sample from eq.(1) as a target sequence of MLE training. Expert-based reward function training is inspired by this study. We use eq.(1) as the proposal distribution from which a negative sequence is sampled, and a reward function is learned by discriminating those negative samples and the true samples.

4. Experiments

We examine the effect of expert-based reward function training in synthetic data. For synthetic data experiments, we conduct the oracle test, which was also conducted in Yu et al. (2017); Lin et al. (2017); Guo et al. (2018). In oracle test, we prepare the RNN with fixed parameters, called oracle RNN. We use the sequences of length 20 and 5,000 vocabulary from oracle RNN as training data, and we evaluate the performance of a generator by measuring the NLL of generated sequence with oracle RNN. A reward function is composed by CNN of Kim (2014), which is same as SeqGAN's discriminator. Other than the training method, our model is same as SeqGAN.

Table 1 presents the result of the oracle test. Note that the top is the model trained with only maximum likelihood estimation (MLE). Our model outperforms SeqGAN, indicating that expert-based reward function training is effective. This experimental result shows that the instability of adversarial training causes serious damage to the training of the generator. Our model also outperforms a strong baseline, RankGAN.

In expert-based reward training, the reward function is fixed during the training of the generator, so we can visualize a return of the reward function to see if the policy

表 1: The result of oracle test. PG denotes if the model is trained with policy gradient or not. The top is the model trained with MLE. The score in parentheses is originally reported score in Yu et al. (2017). $\tau = 1.0$ gave the best score in our model.

Model Name	PG	Adversarial or Expert-based	Oracle NLL
MLE	N	-	9.03
RAML	N	-	9.00
SeqGAN	Y	Adversarial	8.61 (8.73)
RankGAN	Y	Adversarial	8.25
LeakGAN	Y	Adversarial	7.04
Our model	Y	Expert-based	7.55

gradient successfully works. As we can see in figure 3, the generator is properly optimized w.r.t. the reward function, and NLL decreases as a returned reward increases, indicating that the learned reward function is proper and easy to optimize for the generator. It is also noteworthy that $\tau = 1.0$ in eq.(1) gave the best score in our model, in which the proposal distribution provides negative samples that are at proper distance from experts, as shown in figure 2.

参考文献

Martin Arjovsky and Léon Bottou. Towards principled methods for training generative adversarial networks. In *Proceedings of the 5th international conference on Learning representations*, 2017.

Ian Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, and Yoshua Bengio. Generative adversarial nets. In *Advances in Neural Information Processing Systems*, pp. 2672–2680, 2014.

Jiaxian Guo, Sidi Lu, Han Cai, Weinan Zhang, Yong Yu, and Jun Wang. Long text generation via adversarial training with leaked information. In *In Proceedings of association for the advancement of artificial intelligence*, 2018.

Yoon Kim. Convolutional neural networks for sentence classification. *arXiv preprint arXiv:1408.5882*, 2014.

Kevin Lin, Dianqi Li, Xiaodong He, Ming-ting Sun, and Zhengyou Zhang. Adversarial ranking for language generation. In *Advances in Neural Information Processing Systems*, pp. 3158–3168, 2017.

Mohammad Norouzi, Samy Bengio, Navdeep Jaitly, Mike Schuster, Yonghui Wu, Dale Schuurmans, et al. Reward augmented maximum likelihood for neural structured prediction. In *Advances In Neural Information Processing Systems*, pp. 1723–1731, 2016.

Richard S Sutton, David A McAllester, Satinder P Singh, and Yishay Mansour. Policy gradient methods for reinforcement learning with function approximation. In *Advances in Neural Information Processing Systems*, pp. 1057–1063, 2000.

Lantao Yu, Weinan Zhang, Jun Wang, and Yong Yu. Seqgan: Sequence generative adversarial nets with policy gradient. In *Proceedings of association for the advancement of artificial intelligence*, pp. 2852–2858, 2017.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

教師あり主成分分析を用いた動的モード分解

Dynamic mode decomposition using supervised principal component analysis

尾藤 岳仁 *1　河原 吉伸 *1*2　鷲尾 隆 *1
Bito Takehito　Kawahara Yoshinobu　Washio Takashi

*1大阪大学　産業科学研究所
The Institute of Scientific and Industrial Research, Osaka University

*2理化学研究所 革新知能統合研究センター
Center for Advanced Intelligence Project, RIKEN

Dynamic mode decomposition(DMD) is a data-driven method for representing high-dimensional, nonlinear dynamical systems. DMD extracts key low-rank spatiotemporal features of the high-dimensional systems. However, since DMD is an unsupervised method and, thus, cannot incorporate label information into it even when such information is available. In this paper, we propose a framework to incorporate supervised information into DMD analyses. Experimental results show the effectiveness of performing classification tasks using modes obtained by the proposed method.

1. はじめに

何らかの基準に基づいてデータを複数のモードに分解することは，複雑なシステムを解析するために用いられる標準的な手法の一つである．動的モード分解 (Dynamic Mode Decomposition,DMD) は，多次元時系列データを周波数と増減率の情報をもった複数のモードに分解する．このアルゴリズムは時間および空間上の次元削減手法としても知られ，高次元動的システムの重要な低ランクの時間と空間上の特徴を抽出する．それにより，データの空間上の構造およびそれに関連する時間軸上の物理的な解釈を可能にする．DMD に対応する確率モデルを開発しベイズ的に拡張した手法 [1] やモードをスパースにし，ダイナミクスに関わるモードを選択する手法 [2] など DMD は，幅広く応用され注目を集めている．

一方で，DMD は教師なし学習である．したがって，ラベル情報があるようなデータの場合でも，その情報を有効にできないため，ラベル情報に関連した特に興味のあるモードを導くことができない可能性がある．一般の DMD アルゴリズムでは特異値分解により分散最大方向へデータを射影し，ダイナミクスを表す行列の固有値分解を行いモード分解をしていた．この特異値分解による射影では，目的変数については何も考慮していない．しかし，教師情報がある場合，目的変数との依存関係を考慮した方向へデータを射影しモード分解をすることが好ましい．分類問題を想定すると，分類に最も影響を及ぼすモードを用いて分類問題を解くことで精度の向上が期待できる．このような目的のモードは分散最大方向の射影によって導かれるとは限らない．

そこで本研究では，説明変数と目的変数の依存性を最大とする空間へデータを射影する教師あり PCA[3] を取り入れることで，目的変数と最も関連したモードを導くことができるように改良した．そして教師情報を考慮した DMD によって導かれたモードによるデータの類似性を可視化することにより，提案手法の有効性を示す．

連絡先: 大阪大学産業科学研究所 知能推論研究分野
〒 567-0047 大阪府茨木市美穂ヶ丘 8-1
E-mail: bito@ar.sanken.osaka-u.ac.jp

本稿は以下のように構成されている．2. 節では，DMD とそのアルゴリズムについて示す．3. 節では，教師情報を取り入れた DMD の提案手法を述べ，3.1 節において説明変数と目的変数の依存性を最大とする射影を求める教師あり主成分分析（教師あり PCA）を示す．3.2 節では，教師あり PCA によって求めた射影を用いた DMD アルゴリズムを示す．4. 節で提案手法の有用性を時系列データの類似性の可視化によって示し，5. 節で本稿の内容をまとめ，結論を述べる．

2. 動的モード分解

DMD では動的システムから得られる多次元時系列データを時間軸上では周波数と増減率を持つ波に，空間上ではその波に対する各属性の寄与率を持つ複数のモードに分解する．時系列データ

$$X = \begin{bmatrix} | & | & & | \\ \boldsymbol{x}_1 & \boldsymbol{x}_2 & \cdots & \boldsymbol{x}_m \\ | & | & & | \end{bmatrix} \tag{1}$$

から，次のような 2 つのデータ行列を生成する．

$$X_1 = \begin{bmatrix} | & | & & | \\ \boldsymbol{x}_1 & \boldsymbol{x}_2 & \cdots & \boldsymbol{x}_{m-1} \\ | & | & & | \end{bmatrix} \tag{2}$$

$$X_2 = \begin{bmatrix} | & | & & | \\ \boldsymbol{x}_2 & \boldsymbol{x}_3 & \cdots & \boldsymbol{x}_m \\ | & | & & | \end{bmatrix} \tag{3}$$

ここで $\boldsymbol{x}_k \in \mathbb{R}^p$ は時刻 k における動的システムから得られる観測量であり，p は観測点（属性）の数を表す．X_2 は X_1 に対して 1 ステップ後の状態を表しており，DMD では $X_2 \approx AX_1$ つまり，

$$A = X_2 X_1^{\dagger} \tag{4}$$

として線形作用素の有限データによる近似 A の固有値分解を求める．ただし † は Moore-Penrose の疑似逆行列を表す．A の固有値が時間軸上の周波数および増減率を示し，固有ベクトルが特定の固有値に対する空間上の寄与率を示している．その固有ベクトルは DMD モードと呼ばれており，各波に対する各属性の寄与率を示しているため空間上の構造を表している．DMD アルゴリズムを Algorithm1 に示す [4].

Algorithm 1 DMD アルゴリズム

1: 特異値分解

$$X_1 \approx U\Sigma V^* \tag{5}$$

ただし，$*$ は複素共役転置を表し，$U \in \mathbb{C}^{p\times r}$，$\Sigma \in \mathbb{C}^{r\times r}$，$V \in \mathbb{C}^{m-1\times r}$．$r$ は X_1 に対する特異値分解によって次元削減された次元である．U と V の列は直交であるため，$U^*U = I, V^*V = I$ となる．

2: $\tilde{A}$ を求める．

$$\tilde{A} = U^*AU = U^*X_2V\Sigma^{-1} \tag{6}$$

3: $\tilde{A}$ の固有値分解

$$\tilde{A}W = W\Lambda \tag{7}$$

ここで，W の列は $\tilde{A}$ の固有ベクトルであり，Λ は対角成分に対応する固有値を持つ対角行列である．

4: DMD モードの計算
A の固有値は Λ に対応し，DMD モードは以下で与えられる [4].

$$\Phi = X_2V\Sigma^{-1}W\Lambda^{-1} \tag{8}$$

3. 提案手法

DMD の第二ステップ (6) 式では，特異値分解によりノイズの影響を抑える空間にデータを射影していた．しかし，クラス分類問題のように教師情報のある問題では，分類に適したモードを導くことで分類精度の向上が期待できる．したがって，本稿では DMD の第二ステップにおいて，特異値分解によって求まる U による射影の代わりに，教師情報を取り入れ説明変数と目的変数の依存性が最大となる空間に射影する教師あり PCA によってモードを導くことを提案する．また，DMD モードはモード分解したときの各波に対するそれぞれの属性の寄与率を表しており，空間上のコヒーレントを示している．つまり，DMD モードにより分類を行うことで，動的システムのダイナミクスを反映した分類を考えることができる．3.1 節で教師あり PCA の概要を説明し，3.2 節で教師あり PCA を用いて教師情報を考慮した DMD アルゴリズムを示す．

3.1 教師あり PCA

教師あり PCA[3] では，説明変数を目的変数との依存性が最大となる空間へ射影する U_s を求める．説明変数 $\mathcal{X}$ と目的変数 $\mathcal{Y}$ の依存度をを測るために Hilbert-Schmidt independence criterion(HSIC)[5] を導入した．HSIC では $\mathcal{X}, \mathcal{Y}$ のぞれぞれの再生核ヒルベルト空間 $\mathcal{F}, \mathcal{G}$ に関連した相互共分散オペレータの Hilbert-Schmidt ノルムを計算し依存度を測っている．観測データ $\mathcal{Z} := \{(\boldsymbol{x}_1, \boldsymbol{y}_1), ..., (\boldsymbol{x}_N, \boldsymbol{y}_N)\} \subseteq \mathcal{X} \times \mathcal{Y}$ について，HSIC の推定値は

$$HSIC(\mathcal{Z}, \mathcal{F}, \mathcal{G}) = (N-1)^2\mathrm{tr}(HKHL) \tag{9}$$

で与えられる．ただし，$H, K, L \in \mathbb{R}^{N\times N}, K_{ij} = k(\boldsymbol{x}_i, \boldsymbol{x}_j)$, $L_{ij} = l(\boldsymbol{y}_i, \boldsymbol{y}_j), H_{ij} = I - N^{-1}\boldsymbol{e}\boldsymbol{e}^\top$ であり，k, l はそれぞれ $\mathcal{F}, \mathcal{G}$ のカーネル関数である ($\boldsymbol{e}$ はすべての要素が 1 である N 次元ベクトル)．

観測データ行列 $X = [\boldsymbol{x}_1 \ \cdots \ \boldsymbol{x}_N]$，$Y = [\boldsymbol{y}_1 \ \cdots \ \boldsymbol{y}_N]$ とする．教師あり PCA は射影されたデータ $U^\top X$ と結果 Y の依存性が高い部分空間を求めるため HSIC，$\mathrm{tr}(KHLH)$ の最大化をする．ここで，K は $U^\top X$ のカーネル (e.g. $X^\top UU^\top X$) であり，L は Y のカーネル (e.g.$Y^\top Y$) である．クラス分類問題を考える場合は Y のカーネルとして，デルタカーネル $l(y_i, y_j) = \delta(y_i, y_j)$ を用いる．以上より，目的関数は

$$\begin{aligned}\mathrm{tr}(HKHL) &= \mathrm{tr}(HX^\top UU^\top XHL) \\ &= \mathrm{tr}(U^\top XHLHX^\top U)\end{aligned} \tag{10}$$

と変形できる．ここで各データは属性が相関していない空間に射影されるため，U は直交射影とする．したがって，最適化問題は以下となる．

$$\begin{aligned}&\arg\max_U && \mathrm{tr}(U^\top XHLHX^\top U) \\ &\textit{subgect to} && U^\top U = I\end{aligned} \tag{11}$$

対称行列 $Q = XHLHX^\top$ としたときの固有値 $\lambda_1 \leq \cdots \leq \lambda_p$, 対応する固有ベクトルを $\boldsymbol{v}_1, ..., \boldsymbol{v}_p$ とすると，制約を満たす目的関数の最大値は $\lambda_p + \lambda_{p-1} + \cdots + \lambda_{p-d+1}$ であり，最適解は $U = [\boldsymbol{v}_p \ \boldsymbol{v}_{p-1} \cdots \boldsymbol{v}_{p-d+1}]$ である [6]．ただし，d は出力空間の次元である．

教師あり PCA のアルゴリズムを Algorithm 2 に示す．

Algorithm 2 教師あり PCA アルゴリズム

Input: X, Y, L, d
Output: U

1: $H \leftarrow I - n^{-1}\boldsymbol{e}\boldsymbol{e}^\top$
2: $Q \leftarrow XHLHX^\top$
3: $U \leftarrow Q$ の上位 d 個の固有値に対応する固有ベクトル

3.2 DMD への適用

本稿では，ラベル付き多次元時系列データへの DMD の適用を考えるため，N 個の時系列 $\{X^{(i)}, y^{(i)}\}_{i=1}^N$ について，各時系列 $X^{(i)}$ は (1) で示すような p 次元時系列を表す行列であり，$y^{(i)}$ はその時系列のクラスとする．提案手法では 2 つのステップにより教師情報を反映した DMD モードを求める．第一ステップは 3.1 節で示した教師あり PCA によりデータを教師情報を反映した空間に射影する U_s を求める．ここで時系列データに対し教師あり PCA を実行するために，時系列は定常性を仮定する．つまり，時刻によってダイナミクスは変化せず，どの時刻においても各属性とラベルの依存関係は変化しないと仮定する．そして，全時刻に共通な U_s を求める．第二ステップでは，各時系列を共通な U_s により射影し，2. 節で示した DMD により DMD モードを求める．

まず第一ステップでは，教師あり PCA のために以下のようなデータ行列 X_s を生成する．

$$X_s := \left[X_1^{(1)} \ X_1^{(2)} \ \cdots \ X_1^{(N)}\right] \tag{12}$$

$X_1^{(i)}$ は $X^{(i)}$ に関して (2) のような時刻 1 から m-1 の時系列を表す行列である．これを用いて最適化問題 (11) は以下となる．

$$\begin{aligned} \arg\max_{U_s} \quad & \mathrm{tr}(U_s^\top X_s H L_s H X_s^\top U_s) \\ subject\ to \quad & U_s^\top U_s = I \end{aligned} \tag{13}$$

ただし，X_s は時系列データとして拡張してあるため，L_s は以下のように定義する．

$$L_s = \begin{bmatrix} l_{11} & \dots & l_{1N} \\ \vdots & \ddots & \vdots \\ l_{N1} & \dots & l_{NN} \end{bmatrix}. \tag{14}$$

l_{ij} は $y_i = y_j$ のとき $1^{(m-1\times m-1)}$(すべての要素が 1 の $m-1$ 行 $m-1$ 列の行列)，$y_i \neq y_j$ のとき $0^{(m-1\times m-1)}$ とする．以上の最適化問題から最適化問題 (11) と同様に固有値分解により U_s を求める．

第二ステップでは各観測データに対して DMD を実行する．Algorithm1 に則り教師ありに拡張した手続きを示していく．ここで，提案手法では教師情報を考慮するため，共通な U_s を用いてデータを射影し DMD の計算を行っている．各時系列の特異値分解で得られる $U^{(i)}$ と教師情報を考慮した空間へ射影する U_s が異なることに注意されたい．

1. 特異値分解：$X_1^{(i)} \approx U^{(i)}\Sigma^{(i)}V^{(i)*}$
2. 教師情報を取り入れた空間へ射影：
   $\tilde{A}_s^{(i)} = U_s^\top A^{(i)} U_s = U_s^\top X_2^{(i)} V^{(i)}\Sigma^{(i)}U^{(i)*}U_s$
3. $\tilde{A}^{(i)}$ の固有値分解：$\tilde{A}^{(i)}W^{(i)} = W^{(i)}\Lambda^{(i)}$
4. DMD モード $\Phi^{(i)}$：
   $\Phi^{(i)} = A^{(i)}U_s W^{(i)}\Lambda^{(i)-1}$
   $= X_2^{(i)}V^{(i)}\Sigma^{(i)}U^{(i)*}U_s W^{(i)}\Lambda^{(i)-1}$

また，各観測データにおいて教師あり PCA の射影による $\boldsymbol{x}_{k+1}$ と $\boldsymbol{x}_k$ の関係についても議論する．時刻 k における観測データ $\boldsymbol{x}_k$ を教師情報を考慮した U_s により射影し $\tilde{A}_s$ をかけると，

$$\begin{aligned} \tilde{A}_s U_s^\top \boldsymbol{x}_k &= \tilde{A}_s \tilde{\boldsymbol{x}}_k \\ &= U_s^\top A U_s \tilde{\boldsymbol{x}}_k \\ &= U_s^\top X_2 V \Sigma^{-1} U^\top U_s (U_s^\top \boldsymbol{x}_k) \\ &= U_s^\top X_2 V \Sigma^{-1} U^\top \boldsymbol{x}_k \\ &= U_s^\top \boldsymbol{x}_{k+1} \end{aligned} \tag{15}$$

となり，$\tilde{A}_s$ が U_s によって次元削減された空間におけるダイナミクスを表していることが確かめられる．

以上をまとめて提案手法のアルゴリズムを Algorithm3 に示す．

Algorithm 3 提案手法

Input: $\{X^{(i)}, y^{(i)}\}_{i=1}^N, L_s, d, r$
Output: $\{\Phi^{(i)}\}_{i=1}^N$

```
H ← I − n^{-1} e e^⊤
X_s ← [X_1^(1) X_1^(2) ⋯ X_1^(N)]
Q_s ← X_s H L_s H X_s^⊤
U_s ← Q_s の上位 d 個の固有値に対応する固有ベクトル
for i = 1 to N do
    U^(i), Σ^(i), V^(i) ← X_1^(i) の特異値分解 (X_1^(i) ≈ U^(i) Σ^(i) V^(i)*)
    Ã_s^(i) ← U_s^⊤ X_2^(i) V^(i) Σ^(i) U^(i)* U_s
    W^(i) ← Ã_s^(i) の固有値分解 (Ã_s^(i) W^(i) = W^(i) Λ^(i))
    Φ^(i) ← X_2^(i) V^(i) Σ^(i) U^(i)* U_s W^(i) Λ^(i)−1
end for
```

4. 実験

教師情報を取り入れ，DMD モードによるクラス分類が効果的であることを示すために多次元尺度構成法 (MDS) によりデータの類似性の可視化を行った．使用したデータは CMU Graphics Lab Capture Database[7] の Subject 64(golf) である．DMD モードの順序に影響を受けず類似性を測るために，DMD モードの線型結合によって定義される空間の距離を kernel principal angle[8] を用いて定義した．DMD モード $\Phi^{(i)}, \Phi^{(j)}$ の QR 分解を $\Phi^{(i)} = Q_i R_i, \Phi^{(j)} = Q_j R_j$ とすると，$\Phi^{(i)}$ と $\Phi^{(j)}$ の principal angle の cos は $Q_i^\top Q_j$ の特異値 $\delta_1, \ldots \delta_k$ によって与えられる．したがって，部分空間 Q_i を点と見なすことができるグラスマン多様体上のグラスマンベクトルを $\boldsymbol{\Psi}(Q_i)$ として，Q_i, Q_j 間の距離 D_{ij} を以下のように定義した．

$$\begin{aligned} D_{ij} &= ||\boldsymbol{\Psi}(Q_i) - \boldsymbol{\Psi}(Q_j)||^2 \\ &= ||\boldsymbol{\Psi}(Q_i)||^2 + ||\boldsymbol{\Psi}(Q_j)||^2 - 2\boldsymbol{\Psi}(Q_i)^\top \boldsymbol{\Psi}(Q_j) \\ &= 2(1 - \prod_{i=1}^{k} \sigma_i) \end{aligned} \tag{16}$$

上式の距離行列 D を入力として MDS を実行した際の DMD のみの出力を図 1，教師情報を取り入れた提案手法の出力を図 2 に示す．

DMD では'swing' データはまとまっているが，'placing tee'，'placing ball'，'placing up ball' のモーションは分離できているとは言えない．しかし，提案手法による可視化では，DMD で分離できなかった 3 つのモーションが分けられている．また，DMD に見られた'putt' の外れ値も修正されており，教師情報を取り入れ DMD による分類が効果的であることが示せた．

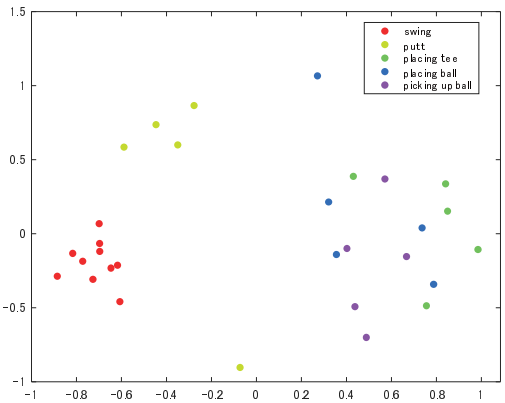


図 1: DMD による類似性の可視化

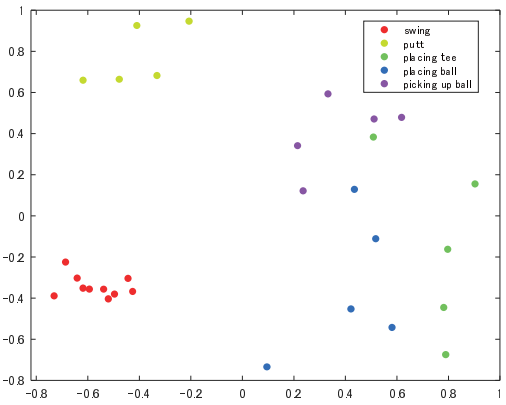


図 2: 提案手法による類似性の可視化

5. むすび

本稿では，DMD が教師なし学習であることから分類に適した DMD モードが抽出できない可能性があることに言及し，教師情報を取り入れるために教師あり PCA によってデータを射影し DMD を実行する手法の提案をした．また，実験を通して教師情報を用いることで DMD では分離できなかったデータをクラスごとに分離することができ，提案手法の有用性が示せた．

今後の課題は分類問題を解くことにより定量的な評価をすることやデータから直接類似性を測り分類する手法などその他の手法との比較が必要である．また，教師あり PCA[3] および DMD[9] はカーネル化された方法や，それに伴う非線形ダイナミクスの比較手法 [10] も提案されているため，提案手法もカーネル化することによりさらに高精度な結果が期待できる．

参考文献

[1] N. Takeishi, Y. Kawahara, Y. Tabei, T. Yairi: Bayesian Dynamic Mode Decomposition, in *Proc. of the 26th Int'l Joint Conf. on Artificial Intelligence (IJCAI'17)*, pp. 2814–2821 (2017)

[2] M. R. Jovanović, P. J. Schmid, J. W. Nicholas: Sparsity-promoting dynamic mode decomposition, *Physics of Fluids*, vol.26, 024103 (2014)

[3] E. Barshasn, A. Ghodsi, Z. Azimifar, M.Z. Jahromi: Supervised principal component analysis: Visualization, classification and regression on subspaces and submanifolds, *Pattern Recognition*, Vol. 44, pp. 1357–1371 (2011)

[4] Jonathan H. Tu, Clarence W. Rowley, Dirk M. Luchtenburg, Steven L. Brunton, J. Nathan Kutz: On dynamic mode decomposition: theory and applications, *Journal of Computational Dynamics*, Vol. 1, No. 2, pp. 391–421 (2007)

[5] A. Gretton, O. Bousquet, A.J. Smola, B. Schölkopf: Measuring statistical dependence with Hilbert-Schmidt norms, in *Proceedings Algorithmic Learning Theory(ALT)*, Vol. 3734, pp. 63–77 (2005)

[6] H. Lutkepohl, Handbook of Matrices, John Wiley and Sons (1997)

[7] CMU Graphics Lab Motion Capture Database: `http://mocap.cs.cmu.edu/`

[8] L. Wolf, A. Shashua: Learning over sets using kernel principal angles, *Journal of Machine Learning Research*, Vol. 4, pp. 913–931 (2003)

[9] Y. Kawahara: Dynamic Mode Decomposition with Reproducing Kernels for Koopman Spectral Analysis, *Advances in Neural Information Processing Systems*, vol. 29, pp. 911–919 (2016)

[10] K. Fujii, Y. Inaba, Y. Kawahara: Koopman spectral kernels for comparing complex dynamics with application to multiagent in sports, in *Proc. of the 2017 European Conf. on Machine Learning and Principles and Practice of Knowledge Discovery in Databases (ECML-PKDD'17)*, pp. 127–139 (2017)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

ハイパーネットによる 識別モデルのベイズ推定とモデル平均化

Bayesian Estimation and Model Averaging of CNN by Hypernet

鵜飼 健矢 *1 Kenya Ukai　松原 崇 *1 Takashi Matsubara　上原 邦昭 *1 Kuniaki Uehara

*1神戸大学 大学院システム情報学研究科
Graduate School of System Infomatics, Kobe University

Neural networks have rich ability to learn complex representations. However, due to the limited number of training samples, overfitting is likely to occur. Hence, it is essential to regularize the learning process of neural networks. In this paper, we propose a regularization method which estimates CNN's parameters as probabilistic distributions by using hypernet. Then, to make it applicable to a large model such as WideResNet, we used likelihood as loss function. Experimental results demonstrate the regularization of our method.

1. はじめに

ニューラルネットワークには高い表現力があり，実世界での複雑なタスクを学習することができる．しかし，学習に利用できるデータは限られているため，過学習を起こしやすいという問題がある．過学習を防止することは，ニューラルネットワークの利用において最も重要な課題の 1 つである [Murphy 12]．過学習を防ぐための基本的な正則化手法として， L2 正則化や Dropout [Srivastava 14] がある．これらはヒューリスティックな手法であるが，ベイズ的な解釈もできる．例えば，L2 正則化はパラメータを確率分布として事前分布に独立正規分布を置き，MAP 推定をすることに相当し，Dropout はガウス過程の変分推論に相当することがわかっている [Gal 16]．このように，ニューラルネットワークの正則化手法とベイズ的手法には深い関係がある．また，ベイズ的手法を用いてニューラルネットワークを学習する手法も研究されており，ネットワークのパラメータの事後分布を推定するモデルはベイジアンニューラルネットワークと呼ばれている．

一方，ニューラルネットワークの一種にハイパーネット [Ha 16] と呼ばれるネットワークがある．ハイパーネットはニューラルネットワークのパラメータを出力するネットワークであり，大規模なネットワークのパラメータ削減 [Ha 16] や，補助情報を利用した動的なパラメータの生成 [Kang 17] などの手法が提案されている．また，ハイパーネットは複雑な確率分布を近似する手段としても注目されており，ハイパーネットを利用したベイジアンニューラルネットワークの研究も行われている．しかし，ネットワークの制約等の問題から，ハイパーネットを利用したベイズ的手法は，小規模なニューラルネットワークにとどまっている．

これらの研究を踏まえ，本稿では，ハイパーネットを用いた大規模なニューラルネットワークの正則化手法を提案する．提案手法では，確率分布からのサンプルを入力とするハイパーネットを使用し，ニューラルネットのパラメータを生成する．この操作により，ハイパーネットによって生成されるパラメータは暗黙的な分布を持ち，学習を正則化することが期待される．また，重みの分布が学習されることから，モデル平均化により識別精度の向上が期待される．実験では，WideResNet [Zagoruyko 16] を対象に，提案手法による学習と推論について検討する．さらに，提案手法は一定の正則化効果を持つことを示す．

連絡先: 鵜飼健矢，神戸大学 大学院システム情報学研究科，ukai@ai.cs.kobe-u.ac.jp

2. 関連研究

2.1 ハイパーネット

ハイパーネット [Ha 16] はニューラルネットワークのパラメータを出力するネットワークの総称である．ハイパーネットに出力されるパラメータと，ニューラルネットの関係を図 1 に示す．ハイパーネットを用いるモデルでは，ネットワークのパラメータ w を学習する代わりに，ハイパーネットのパラメータ θ を学習する．Ha らはハイパーネットに低次元なパラメータを入力して，WideResNet [Zagoruyko 16] のパラメータを削減している．

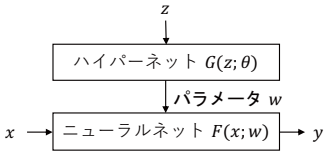


図 1: Structure of neural network using hypernet.

2.2 ハイパーネットを用いたニューラルネットワークのベイズ的学習

ニューラルネットのパラメータの事後分布を推定する基本的な研究に，Blundell らの研究がある．Blundell らは，パラメータの事後分布を，事前分布との KL 情報量を近づけるように変分推論してベイズ推定を行っている [Blundell 15]．Blundell らの研究では，計算を簡単にするため，確率分布として各次元が独立な正規分布を用いており，表現力の不足が指摘されている．この制約を緩和する手法として，正規分布の代わりに，ハイパーネットを用いることが提案されている．Krueger らは，事後分布の近似関数にハイパーネットを用いて，より複雑な事後分布の表現を可能にしている [Krueger 17]．また，Deutsch はハイパーネットの出力の多様性に着目して，出力の多様性を促すように損失関数を設計し，変分推論との関係を議論している [Deutsch 18]．このように，ハイパーネットを用いてニューラルネットをベイズ的に学習する研究は盛んに行われている

が，その適用は小規模なニューラルネットワークにとどまっている．

3. 提案手法

3.1 概要

上記の関連研究を踏まえ，本稿では，ハイパーネットを用いた大規模なニューラルネットワークの正則化手法を提案する．提案手法の概要を図 2 に示す．本研究でも，Krueger らの研究と同様に，ハイパーネットに連続確率分布からのサンプルを入力する．この操作により，ハイパーネットによって生成されるパラメータは暗黙的な分布を持ち，学習を正則化することが期待できる．一方，Krueger らの研究とは異なり，本稿では，損失関数に KL 情報量を用いず，モデルの尤度を用いる．この変更により，事前分布を明示的に使用することはできなくなるが，ハイパーネットの構造に関する制約がなくなり，パラメータ数の多いモデルを容易に扱うことができる．また，重みの分布が学習されることから，モデル平均化を行うことができる．

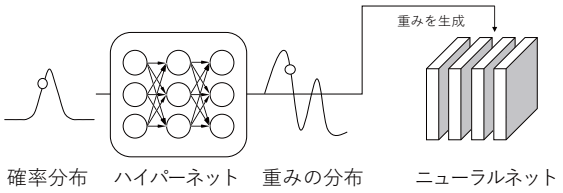


図 2: Concept of proposed method.

3.2 ハイパーネットによるニューラルネットの重み生成

一般的な画像識別のニューラルネットの学習では，入力画像を X，画像のクラスを Y，パラメータを W として，損失関数 $\mathrm{loss(x, y, w)}$ を定義し，w の値を学習する．一方，ハイパーネットを用いたモデルでは，ハイパーネットを関数 $G(z;\theta) : Z \times \Theta \to W$ として，w の代わりに θ を学習する．提案手法では，z として確率分布からのサンプル，損失関数としてモデルの尤度 $p(y|x,\theta)$ を用いる．z として確率分布からのサンプルを用いるため，ハイパーネットは分布から分布への写像となり，w は確率分布となる．

確率分布の表現には，正規分布など既知の分布を仮定して，そのパラメータをハイパーネットで生成する方法と，ハイパーネットの出力そのものを分布からのサンプルとする方法がある．本研究では，より複雑な分布の表現を可能にするため，ハイパーネットの出力そのものを分布からのサンプルとする．なお，既知の分布を仮定しないために，w の事後分布は，密度関数が明示的な式として定義できず，サンプルのみが可能な暗黙的分布となる．しかし，本手法では目的関数をモデルの尤度 $p(y|x,\theta)$ とするため，密度関数が定義できないことは問題とはならない．

ハイパーネットでネットワークのパラメータを生成することは，生成対象のネットワークのパラメータ間に関連性を持たせ，自由度に制約を加えていると解釈できる．そのため，ハイパーネットの構成によってパラメータの制約が変わる．ハイパーネットの構成として，複数のハイパーネットを用意して，各層ごとに独立にパラメータを生成する構成や，一つのハイパーネットを複数回使用し，各層のパラメータを生成する構成が考えられる．一つのハイパーネットを複数回使用する方法は，ネットワーク全体のパラメータを削減できる利点があるが，Ha らの研究 [Ha 16] を踏まえた予備実験から，精度が低下することがわかっている．このため，本稿では，複数のハイパーネットを用意して層ごとにパラメータを生成する．また，ネットワーク構造を簡単にするため，パラメータの生成対象は畳み込み層に限定する．

中間層 1 層のネットワークのパラメータを生成する場合の，ハイパーネットを含むネットワーク全体のグラフィカルモデルを図 3 に示す．黒塗りの四角は決定論的に求められる変数を，三角は固定の確率分布からのサンプルを表している．z_i は，ハイパーネットに入力する α_i をパラメータとする確率分布からのサンプルであり，θ_i をパラメータとするハイパーネットによって w_i に変換される．なお，w_i は通常のニューラルネットのパラメータである．

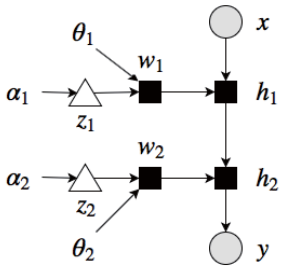


図 3: A diagram of proposed model with one hidden layer.

3.3 モデル平均化

ハイパーネットで生成するパラメータは確率分布を持つため，モデル平均化することができる．学習の結果，得られた分布が識別に対して多様性を持つならば，モデル平均化により，アンサンブルと同様の効果で精度向上が期待できる．多様性に関しては考察で詳しく議論する．

提案手法では，平均化を各層で行う．具体的には，本研究で扱うのは CNN であるため，ハイパーネットの入力を変えて複数のフィルタを生成し，各層でのチャネル数を増加させる．例えば，ハイパーネットの出力するパラメータの次元を $(c_{out}, c_{in}, kernel\ size, kernel\ size)$ とすると，ハイパーネットへの入力を変えてパラメータを $n \times n$ 組生成し，組み合わせて $(c_{out} \times n, c_{in} \times n, kernel\ size, kernel\ size)$ のフィルタとして使用する．この操作により，各層のチャネル数が n 倍されたネットワークが構成できる．これは，パラメータの事後分布を周辺化する際の積分を，サンプリングで近似していることに相当する．

3.4 推論時の Batch Normalization のファインチューニング

パラメータ生成の対象とする WideResNet には， Batch Normalization [Ioffe 15] が用いられる．Batch Normalization では，学習時はバッチ内で平均と分散を計算し，推論時には学習データの平均，分散の重み付き平均を用いるが，本研究で用いるモデルは，ネットワークの重みが確率的に変化するため，評価ごとに各層の出力分布が変化する．この変化に対応するため，推論時にはハイパーネットから出力された重みに合わせて，平均，分散の再計算を行う．具体的には，ハイパーネットで対象ネットワークのパラメータを出力したのち，そのパラメータを用いて Batch Normalization の平均，分散のみ 1 エポックの学習を行う．また，モデル平均化の際には， Batch Normalization のアフィン変換のパラメータも考慮する必要があるが，拡大部分のアフィン変換のパラメータは，拡大前のものを共有する．

4. 評価実験

提案手法の正則化効果を確かめるため，比較実験を行う．最尤推定，L2 正則化による MAP 推定，提案手法とそのモデル平均の精度を比較する．また，提案手法で学習されるモデルの特徴を分析するために，ハイパーネットによって生成されたネットワークの多様性をダブルフォルト尺度で評価する．さらに，生成される重みのヒストグラムの分析を行う．

学習用データには CIFAR-10 [Krizhevsky 09] データセットを使用する．CIFAR-10 は訓練用データ 50000 枚，評価用データ 10000 枚で構成される中規模のデータセットである．識別精度をあげるため，[Zagoruyko 16] と同様に，画像は学習データの平均と分散を用いて白色化し，学習時にはランダムな切り抜きと反転を適用する．ランダムな切り抜きは，周囲 4 ピクセル のゼロパディングした画像から 32×32 のサイズを切り抜く．これらは CIFAR-10 の学習では標準的な data augmentation である [Zagoruyko 16].

実験で使用するネットワークについて説明する．まず，ハイパーネットで重みを生成する対象のネットワークには WideResNet28-4 [Zagoruyko 16] を用いる．WideResNet 部分のネットワーク構造は基本的に原論文で示されているものに従っている．ただし，本実験ではハイパーネットで CNN のフィルタのみを生成するため，モデル平均化時には，最後の畳み込み直後に平均を取り，全結合の入力数を一定にする処理を行っている．

次に，ハイパーネットの構造を説明する．ハイパーネットは，各畳み込み層に対して，中間層 1 層の全結合ニューラルネットワーク 1 つずつを用いる．入力次元と中間層の次元は 32 次元とし，$\mathcal{U}(0,1)$ からのサンプルを入力する．活性化関数には ReLU を使用する．また，予備実験の結果から，確率成分を含むベクトルの消失を防ぐため，ハイパーネットの全結合には，バイアス項を使用しないこととする．

さらに，ハイパーネットの初期化方法を説明する．中間層の初期化には He uniform [He 15] を用いる．出力層の初期化は，学習を安定化させるために，He uniform の範囲を 1/10 した一様分布で行っている．最後に，WideResNet は通常，過剰適合を防ぐために L2 正則化による MAP 推定を行うが，ハイパーネットを使用する際は，ハイパーネットが出力するパラメータ以外に L2 正則化を適用する．その他の学習方法は WideResNet に従っている．

5. 結果と考察

5.1 ハイパーネットによる学習の正則化効果

CIFAR10 データセットでの，学習方法ごとの精度の比較実験の結果を表 1 に示す．Method はパラメータの推論方法を表している．MAP は L2 正則化であり，WideResNet で一般的に用いられる推論方法である．Widening rate は提案手法のモデル拡大率であり，16 倍はチャネル数が学習時の 16 倍になるようにモデル平均化したものである．誤差率の値は，MLE は 1 回の学習の結果，MAP と提案手法は 3 回の学習結果の中央値を用いている．提案手法では，評価ごとに識別精度が変化するため，それぞれの学習での誤差率は，学習したモデルを，ハイパーネットへの入力を変えて 5 回評価し，その中央値を使用している．なお，表には 200 エポックと 800 エポックでの汎化誤差を示しているが，WideResNet では学習率を全エポック数に応じて多段スケジューリングするため，それぞれの学習は独立して行ったものである．Zagoruyko らの研究 [Zagoruyko 16] では 200 エポックで実験を行っているため，200 エポックの結果と，より長い学習の結果として 800 エポックの結果を示している．

Method	Widening rate	200 epoch	800 epoch
MLE		6.49	6.05
MAP		**4.53**	4.23
Hypernet(ours)	× 1	4.60	4.25
	× 16	4.68	**4.15**

表 1: Test error rates on CIFAR-10 for WideResNet28-4 with different regularization methods.

まず，モデル平均化を行わない ×1 の 200 エポックを見ると，提案手法はエラー率 4.60% と，MLE の 6.49% を大きく改善している．このことから，ハイパーネットによる学習には正則化効果があることが言える．一方，MAP 推定の 4.53% と比較すると提案手法の精度はわずかに劣っている．800 エポックまで学習を行うと，×1 は 200 エポックと傾向が変わらないが，モデル平均化でチャネル幅を 16 倍にした ×16 では MAP 推定を上回る精度となっている．このことから，モデル平均化が有効であることがわかる．

5.2 ハイパーネットに生成されるネットワークの多様性

次に，ハイパーネットによって生成されるネットワークの分析結果を示す．分析には，ダブルフォルト尺度 [Zhi-Hua Zhou 17] を用いている．ダブルフォルト尺度は多様性を表現する指標であり，2 つのモデルで同じデータの識別を行い，共に誤識別をしたデータの割合と定義される．この値が小さいほど，2 つのモデルが誤識別するデータが異なることを示している．すなわち，2 つのモデルが異なる特徴量で識別を行なっていることを示唆する．このようなモデルは，アンサンブルによって識別精度の向上が期待できる．逆に，ダブルフォルト尺度の値が大きい場合，2 つのモデルは類似する特徴量で識別をすることが示唆され，アンサンブルの効果が小さいことが想定できる．

本稿では，学習した 1 つのハイパーネットを用い，ハイパーネットの入力を変えて生成されるネットワーク間で，共に誤識別をしたデータ数を評価している．これによって，ハイパーネットから生成されるネットワークの多様性を数値的に評価することができる．実験では，モデル間での差異をより詳細に捉えるため，2 つではなく，4 つのモデル（分布からの 4 つのサンプル）で共に誤識別をした割合を計算することとしている．比較対象には，通常の WideResNet を用いている．WideResNet はアンサンブルによって精度が大きく向上することが知られている．なお，表 1 の結果から Hypernet と MAP では汎化誤差がほとんど同じため，値の大きさを比較すれば，ダブルフォルト尺度を比較することができる．結果を表 2 に示す．表の数値は割合ではなく，誤識別した枚数として示している．1times は，4 つのモデルのうち，1 つだけが誤識別した画像の枚数である．

Method	4 times	3 times	2 times	1 time
Hypernet	383	36	47	59
MAP	196	123	173	314

表 2: Double faults ($\times 10^4$) on CIFAR-10 for WideResNet28-4 generated by hypernet and learned by MAP estimation.

まず，4time の値を見ると，MAP の 196 に対し，Hypernet では 383 と倍程度になっている．1time の値は逆に MAP が

314 で，Hypernet の 5 倍以上も大きい．これは，ハイパーネットから生成されるネットワークの多様性が小さいことを示している．そのため，ハイパーネットで学習したモデルのモデル平均化は，初期値を変えて学習したモデルのアンサンブルより効果が小さいことが示唆される．これは，ハイパーネットが持つ確率的要素が多様性を持たせる方向に機能していないということであり，多様性を持たせるための改良ができれば，モデル平均化によるさらなる精度の改善が望める．ハイパーネットの出力の多様性に関しては，[Deutsch 18] で議論されているが，Deutsch の手法を用いた予備実験では精度の低下が見られたため，さらなる検討が必要である．

5.3 ハイパーネットに生成される重み

最後に，ハイパーネットから生成された重みの値のヒストグラムを見る．ヒストグラムを図 4 に示す．MAP，MLE はそれぞれ MAP 推定，最尤推定で学習された重み，Hypernet は学習したハイパーネットから生成した重みを表している．ハイパーネットの入力によって生成される重みは，ハイパーネットへの入力によって変化するが，実験の結果，値のヒストグラムには大きな差が見られなかったため，1 回のサンプル結果を示している．なお，WideResNet では Batch Normalization を用いており，畳み込み演算後に中間表現のスケールが正規化されるため，重みの値は分散が 1 となるように正規化して示している．平均は学習の結果 0 付近となっていたためそのまま用いている．グラフを見ると，どれも 0 を中心として末広がりの正規分布のような形をしているが，提案手法は MAP 推定よりも値の大きい重みが少なくなっていることがわかる．このことから，ハイパーネットを用いた学習は，L2 正則化による MAP 推定とは異なる正則化効果があることが示唆される．

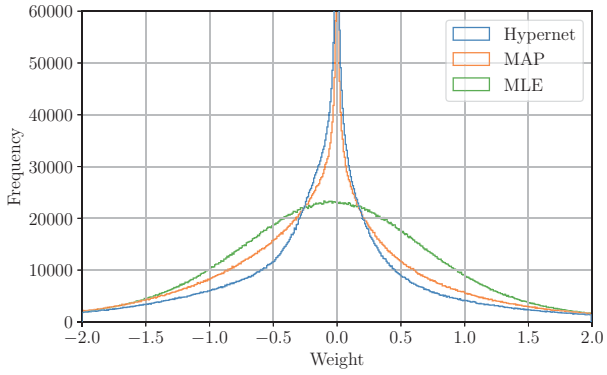


図 4: Histgrams of WideResNet28-4's weights generated by hypernet, learned by MLE and MAP estimation.

6. おわりに

本稿では，ハイパーネットを用いた大規模なニューラルネットの正則化手法を提案した．画像識別で高い性能を示す，比較的規模の大きな CNN である WideResNet の学習を行い，提案手法に正則化効果があること，モデル平均化により精度が改善することを示した．一方，既存の手法に対して精度の大幅な向上は見られなかった．分析の結果から，これはハイパーネットが生成するネットワークに多様性が乏しいことが一因であることがわかった．今後の課題は，この点を改良し，さらなる精度向上を目指すことである．また，より単純なモデルを用いてハイパーネットを用いた既存のベイズ的手法と比較することも今後の課題である．

本研究は科研費 (16K12487) の支援，総務省 SCOPE(受付番号 172107101) の委託を受けて行われた．

参考文献

[Blundell 15] Blundell, C., Cornebise, J., Kavukcuoglu, K., and Wierstra, D.: Weight Uncertainty in Neural Network, in *Proc. of the 32nd International Conference on Machine Learning*, pp. 1613–1622 (2015)

[Deutsch 18] Deutsch, L.: Generating Neural Networks with Neural Networks, *arXiv preprint 1801.01952* (2018)

[Gal 16] Gal, Y. and Ghahramani, Z.: Dropout as a Bayesian Approximation: Representing Model Uncertainty in Deep Learning, in *Proc. of the 33nd International Conference on Machine Learning*, pp. 1050–1059 (2016)

[Ha 16] Ha, D., Dai, A. M., and Le, Q. V.: HyperNetworks, *arXiv preprint 1609.09106* (2016)

[He 15] He, K., Zhang, X., Ren, S., and Sun, J.: Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification, in *Proc. of the IEEE International Conference on Computer Vision*, pp. 1026–1034 (2015)

[Ioffe 15] Ioffe, S. and Szegedy, C.: Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, in *Proc. of the 32nd International Conference on Machine Learning*, pp. 448–456 (2015)

[Kang 17] Kang, D., Dhar, D., and Chan, A. B.: Incorporating Side Information by Adaptive Convolution, in *Advances in Neural Information Processing Systems 30*, pp. 3870–3880 (2017)

[Krizhevsky 09] Krizhevsky, A. and Hinton, G.: Learning multiple layers of features from tiny images, Master's thesis, Dept. of Comp. Sci., University of Toronto (2009)

[Krueger 17] Krueger, D., Huang, C., Islam, R., Turner, R., Lacoste, A., and Courville, A. C.: Bayesian Hypernetworks, *arXiv preprint 1710.04759* (2017)

[Murphy 12] Murphy, K. P.: *Machine learning - a probabilistic perspective*, Adaptive computation and machine learning series, MIT Press (2012)

[Srivastava 14] Srivastava, N., Hinton, G. E., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R.: Dropout: a simple way to prevent neural networks from overfitting, *Journal of Machine Learning Research*, Vol. 15, No. 1, pp. 1929–1958 (2014)

[Zagoruyko 16] Zagoruyko, S. and Komodakis, N.: Wide Residual Networks, in Richard C. Wilson, E. R. H. and Smith, W. A. P. eds., *Proc. of the British Machine Vision Conference*, pp. 87.1–87.12 (2016)

[Zhi-Hua Zhou 17] Zhi-Hua Zhou (宮岡悦良, 下川朝有) アンサンブル法による機械学習：基礎とアルゴリズム, 近代科学社 (2017)

[1Z2] [General Session] 2. Machine Learning

座長:竹内 孝（NTT）

Tue. Jun 5, 2018 3:20 PM - 5:00 PM Room Z (3F Matsu Take)

[1Z2-01] Robustness verification of CMA-ES optimization for neural networks

○Hiroki Shimizu[1], Junpei Komiyama[2], Masashi Toyoda[2] （1. The University of Tokyo, 2. Institute of Industrial Science, the University of Tokyo）

3:20 PM - 3:40 PM

[1Z2-02] Learning to Bipedal Walking on Simulation with SUNA

○Yuta Inoue[1], Danilo Vasconcellos Vargas[1] （1. Kyushu University）

3:40 PM - 4:00 PM

[1Z2-03] The Study on Stochastic Variational Inference for Topic Modeling with Word Embeddings

○Kana Ozaki[1], Ichiro Kobayashi[1] （1. Ochanomizu University）

4:00 PM - 4:20 PM

[1Z2-04] Kernel median embedding as a functional parameter of the data distribution

○Matthew J Holland[1] （1. Osaka University）

4:20 PM - 4:40 PM

[1Z2-05] On Incomplete Noisy Sorting

○Junpei Komiyama[1] （1. The University of Tokyo）

4:40 PM - 5:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

CMA-ESを用いたニューラルネットワークの重み行列の最適化における頑健性の検証

Robustness verification of CMA-ES optimization for neural networks

清水 洸希 *1　小宮山 純平 *2　豊田 正史 *2
Shimizu Hiroki　Komiyama Junpei　Toyoda Masashi

*1東京大学大学院 情報理工学系研究科
Graduate School of Information Science and Technology, the University of Tokyo

*2東京大学 生産技術研究所
Institute of Industrial Science, the University of Tokyo

This paper aims to verify robustness of covariance matrix adaptation evolution strategy (CMA-ES) optimization for neural networks (NN). We added label noise to the training dataset. Unlike stochastic gradient descent (SGD), which is the state-of-the-art optimizer of NN, a CMA-ES based optimization was robust against label noise.

1. はじめに

ニューラルネットワーク (NN) は近年，画像認識や機械翻訳の分野において人間の精度を超える，あるいはそれに迫る性能を発揮しており [1][2]，今後，実世界のさまざまな分野での応用が期待されている．

NN のモデルの評価には，画像分類においては，MNIST や CIFAR-10 といったデータセットが一般的に用いられる．これらのデータは，学習データに対して正しく教師ラベルが付与されており，非常にラベルノイズの小さいデータセットであると言える．一方で，実世界における応用を考えた場合，誤った教師ラベルが付与されることが低くない確率で起きることが予想され，NN の最適化には強い頑健性が求められる．

NN の最適化には，確率的勾配降下法 (SGD) と呼ばれるアルゴリズムが性能や実行速度の観点から広く使われている．最適化の手法としては，SGD 以外にもいくつかのアルゴリズムが存在しており，清水らの研究 [3] により，2 層の非常に浅い NN においては，Covariance matrix adaptation evolution strategy (CMA-ES)[4] が SGD と同等の精度が得られることが報告されている．

CMA-ES は進化戦略と呼ばれるアルゴリズムの一種であり，多変量正規分布により複数の NN を生成し，評価値の高い NN の重み行列により多変量正規分布のパラメタを更新することで NN の最適化を行う．進化戦略による最適化の特徴として，一般に頑健性が高いと言われているが [5]，それについて検証が行われることは非常に少なく，特に NN の最適化にあたっては先行研究がない．

そこで，本稿では，学習データのラベルに対して人為的にノイズを付与し，それを用いた最適化を行うことで，CMA-ES による最適化の頑健性を検証し，SGD により最適化を行った場合との比較を行う．

2. 関連研究

ラベルノイズ下での NN の最適化の頑健性向上に関する研究は近年盛んに行われている．

損失関数に対して，ラベルノイズに関する正則化を与えることで，性能の向上を図った研究として，Patrini らによる研究 [6] と Ghoshr らによる研究 [7] が挙げられる．Patrini らは，ノイズ発生確率の情報を損失関数に与えることで，ラベルノイズ下での性能を向上させた．ノイズの発生確率が未知の場合でも，それを推定する手法を提案しているが，その場合はネットワークの構造に工夫をしなければノイズを過学習するという課題もある．Patrini らの手法は損失関数をクロスエントロピー関数に限定しているという課題があったが，Ghoshr らは平均二乗誤差や平均絶対誤差に対してもラベルノイズ化での最適化を可能とした．

Goldberger ら [8] は，NN の構造に対して，ラベルノイズに対する適応層を追加することで性能の向上を図った．

以上の研究は，損失関数や層に対しての提案であり，いずれも本稿の CMA-ES と組み合わせて用いることができる．一方で，CMA-ES と組み合わせることのできないような，最適化アルゴリズム自体への提案をする研究は知りうる限り存在せず，今後の研究が期待される．

本稿では，CMA-ES による最適化の頑強性を明確に検証するため，これらの既存研究との組み合わせは行わずに実験を行った．

3. CMA-ES

3.1 概要

CMA-ES は Hansen らが考案した最適化アルゴリズムである．SGD が 1 つの NN を定義し，その重み行列を更新していくのに対して，CMA-ES では N 個のネットワークを定義し，その重み行列を多変量正規分布を用いて生成し，評価値の高い NN の重み行列を用いて，多変量正規分布のパラメタを更新することによって NN を間接的に最適化する．SGD が最適化の過程で，目的関数や活性化関数の連続性や微分可能性を必要とするのに対して，CMA-ES はそれらを必要としないという特徴がある．CMA-ES における課題としては，各ステップで N 個のネットワークの重み行列のパラメタを保持する必要があるため，莫大なメモリを消費するという点が挙げられる．

3.2 CMA-ES の最適化ステップ

CMA-ES は多変量正規分布により NN の重み行列を生成するが，多変量正規分布 $N(m, C)$ はパラメタとして平均 m と分散共分散行列 C を持つ．ここで平均 m および分散共分散行列の次元数は NN の重み行列の要素数である．CMA-ES の最適

連絡先: {shimizu, jkomiyama, toyoda}@tkl.iis.u-tokyo.ac.jp

化ステップではまず，$N(m, C)$ から N 個の重み行列 $\{x_i\}_{i=1}^N$ をサンプリングする．これらの N 個の NN に対して，SGD と同様に学習データを順伝播させ，各 x に対してコストを計算する．そのコストに基づき，各 x に対して 1 から N までの順位をつけ，以下の式 (1)〜(5) よりパラメタ m 及び C の更新を行う．ここで t は最適化のステップ数，σ は収束に応じて値が大きくなる変数，r は閾値である．

コストの計算については，一般的な進化戦略においては，全ての学習データのコストを計算して順位をつけるが，Morse らの研究 [9] により，全てのデータではなく，ミニバッチに区切ったデータを用いた方が性能が向上することが報告されており，本稿においても，このミニバッチを採用した．

$$m^{t+1} = m^t + \eta_m \sum_{i=1}^{N} \tilde{w}_i (x_i - m^t) \quad (1)$$

$$C^{t+1} = C^t + \eta_c \sum_{i=1}^{N} \tilde{w}_i \left(\frac{(x_i - m^t)(x_i - m^t)^T}{\sigma^t} - C^t \right) \quad (2)$$

$$p_\sigma^{t+1} = p_\sigma^t + C^{t-\frac{1}{2}} \frac{m^{t+1} - m^t}{\sigma^t} \quad (3)$$

$$\sigma^{t+1} = \sigma^t \exp\left(\frac{\|p_\sigma\|}{E\|N(0, I)\|} - 1 \right) \quad (4)$$

$$\tilde{w}_i = \frac{1}{N} \mathbb{I}_{(rank(x_i) \geq r)} \quad (5)$$

4. 実験

実世界におけるデータにはラベルノイズが発生している可能性が高いと考えられるが，どの程度のノイズがあるかを知ることが難しいため，検証においては，ベンチマーク用のデータセットである MNIST を用いた．MNIST のデータを 49500 個の学習データと 5500 個のテストデータに分け，学習データのラベルを，一定の割合でランダムに書き換えることで，ラベルノイズを人為的に発生させた．発生させるノイズは 0%から 20%まで 5%刻みで変化させた．

検証には入力層と出力層が直結した 2 層の NN を用いた．非常に浅い NN であるが，CMA-ES のメモリ制約上の都合からこれを使用した．比較対象として，CMA-ES と SGD の他に，SGD の学習率を自動的に調整するアルゴリズムである ADAM[10] も用いた．各手法のパラメタ設定として，バッチサイズは全て 256 を用い，学習率は ADAM は初期設定値，SGD については 0.01 とした．評価には F 値を用いた．

実験の結果を表 1 及び図 1 に示した．表 1 を見ると，ノイズが 0%のときは ADAM 及び SGD が優れているが，ノイズが大きくなるに従って ADAM 及び SGD が大きく性能を下げたのに対して，CMA-ES は小さい下げ幅に止まった．ラベルノイズが 20%の場合においては，他の手法が F 値で 0.9 を下回ったのに対して，CMA-ES は 0.9 以上を維持しており，頑健性の高さを示した．

表 1: CMA-ES と SGD との F 値による比較 (MNIST)

ラベルノイズ [%]	CMA-ES	ADAM	SGD
0	0.918	0.924	0.922
5	0.918	0.915	0.913
10	0.918	0.910	0.910
15	0.917	0.906	0.903
20	0.916	0.899	0.900

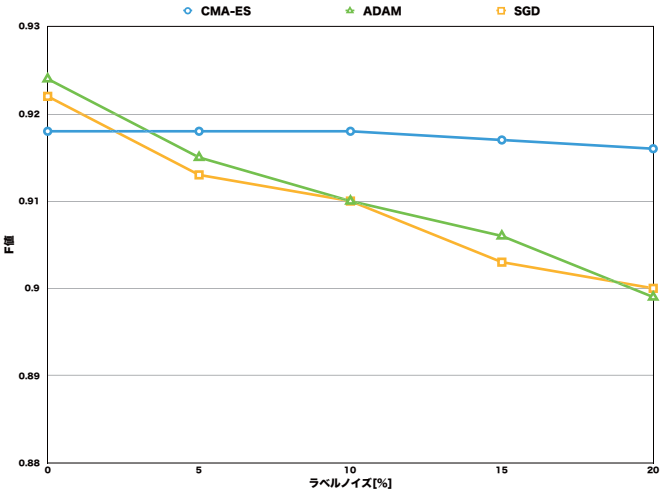


図 1: CMA-ES と SGD との比較 (MNIST)

5. 考察

SGD が，ラベルノイズの割合が上がるに連れて急激に性能が低下したことについて，SGD が各学習データのコストに対して勾配を計算し，重み行列の値を更新していることに原因があると考えられる．ミニバッチ学習法を用いることで，1 つの学習データが与える影響を小さくすることができるが，その影響が必ず勾配と重み行列の更新値へ直接及ぶからである．

一方で，CMA-ES においては，各学習データが更新に直接与える影響は，各 NN の順位を決定する際のコストの算出のみである．確率分布のパラメタの更新は，その順位に基づいて，各 NN の重み行列の値から行われるため，ラベルノイズを含んだ学習データが順位の上下に影響を与えない限りは，最適化への影響は生じないと言える．これにより，CMA-ES はラベルノイズが上昇しても F 値が大きく下がらなかったと考えられる．

6. 終わりに

本稿では，NN の最適化における CMA-ES の頑健性の高さを示した．一方で，検証実験において，メモリの制約上から 2 層という非常に浅い NN しか用いることができないという問題が生じた．

今後の課題としては，(1)MNIST 以外のデータセットでの検証，(2) より深い NN での検証，(3) 既存の損失関数や層への正則化手法との組み合わせの検証，が挙げられる．

謝辞

本研究は JSPS 科研費 16H02905, 17K12736 の助成を受けたものです．

参考文献

[1] Stanford Vision Lab. ImageNet, 2015.

[2] Yonghui Wu, Mike Schuster, Zhifeng Chen, Quoc V. Le, Mohammad Norouzi, Wolfgang Macherey, Maxim Krikun, Yuan Cao, Qin Gao, Klaus Macherey, Jeff

Klingner, Apurva Shah, Melvin Johnson, Xiaobing Liu, Łukasz Kaiser, Stephan Gouws, Yoshikiyo Kato, Taku Kudo, Hideto Kazawa, Keith Stevens, George Kurian, Nishant Patil, Wei Wang, Cliff Young, Jason Smith, Jason Riesa, Alex Rudnick, Oriol Vinyals, Greg Corrado, Macduff Hughes, and Jeffrey Dean. Google's Neural Machine Translation System: Bridging the Gap between Human and Machine Translation. pp. 1–23, 2016.

[3] 清水洸希, 小宮山純平, 豊田正史. 進化戦略を併用した neural network の重み最適化. 第 10 回データ工学と情報マネジメントに関するフォーラム (DEIM2018), 2018.

[4] Nikolaus Hansen. The CMA Evolution Strategy: A Tutorial. Vol. 102, No. 2006, pp. 75–102, 2016.

[5] Hitoshi Iba. 進化計算と深層学習. *Ohmsha*, 2017.

[6] Giorgio Patrini, Alessandro Rozza, Aditya Menon, Richard Nock, and Lizhen Qu. Making Deep Neural Networks Robust to Label Noise: a Loss Correction Approach. sep 2016.

[7] Aritra Ghosh, Himanshu Kumar, and P. S. Sastry. Robust Loss Functions under Label Noise for Deep Neural Networks. pp. 1919–1925, 2017.

[8] Jacob Goldberger and Ehud Ben-Reuven. Training Deep Neural Networks using a Noise Adaptation Layer. *Iclr 2017*, No. 2014, pp. 1–9, 2017.

[9] Gregory Morse and Kenneth O. Stanley. Simple Evolutionary Optimization Can Rival Stochastic Gradient Descent in Neural Networks. *Proceedings of the 2016 on Genetic and Evolutionary Computation Conference - GECCO '16*, No. Gecco, pp. 477–484, 2016.

[10] Diederik P. Kingma and Jimmy Ba. Adam: A Method for Stochastic Optimization. dec 2014.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

SUNA によるシミュレーション上での二足歩行動作学習

Learning to Bipedal Walking on Simulation with SUNA

井上　湧太　　ダニロ・ヴァスコンセロス・ヴァルガス
Yuta Inoue　　Danilo Vasconcellos Vargas

九州大学
Kyushu University

SUNA is currently one of the most adaptive neuroevolution methods which is able to tackle different problems efficiently. However, many questions remain unanswered. In this research, we applied SUNA to the bipedal-walking problem and evaluate it general learning properties. The results show that even without any modificiations SUNA is able to learn in this environment. Moreover, contrary to many other methods, it is continuously improving its average rewards showing a near open-ended learning.

1. はじめに

Spectrum-diverse Unified Neuroevolution Architecture (SUNA)[Vargas 17] は、異なる問題を同一の手法で効率的に学習するためのニューロエボリューションの手法である。しかしながらその性質についての多くは調べられておらず、汎用性や計算速度での優位性などの性質は明らかになっていない。本研究では SUNA の汎用性について調べるため、二足歩行シミュレーションを用いて SUNA による学習を行った。

SUNA は Unified Neural Model (UNM) と呼ばれる特殊な構造を用いて汎用性を実現しており、また効率性は UNM の各ニューロンの特徴にしたがって探索を行うことで実現されている。UNM では、同じニューロエボリューションの手法である NEAT[Stanley 02] で使用されるニューロンに改良を加えた拡張ニューロンが使用される。このニューロンでは NEAT で使用されるニューロンの持つ特徴に加え、それぞれ異なる時定数を持ち、異なる活性化関数を選択できるという特徴がある。異なる活性化関数を選択できることは、単一の活性化関数を持つニューロンのみで構成されるネットワークと比較して、ある小さなネットワークを 1 つのニューロンで表すことができる可能性があるため、構造を簡単にすることに貢献する。

また UNM では、多様な問題に対応できるように、状況に応じてネットワークの構造を変えるための制御ニューロンとニューロモジュレーションを導入している。制御ニューロンは入力に応じて、制御対象のニューロンごとに重み付けされた制御信号を出力する。各ニューロンは受け取った制御信号の総和が閾値以上であればそれぞれのニューロンの入力に従って出力を行い、そうでなければ出力を行わない。まだニューロモジュレーションはあるニューロンの内部状態に応じて結合強度を変化させることでネットワークの構造を変化させる。

以上で上げたように UNM は高い自由度を持つため、その探索空間は膨大なものになる。これを効率的に探索するため、Danilo & Murata[Vargas 17] ではネットワークの含むニューロンの特徴によって個体を種別し、それぞれの種の中で最も高い適応度を持つものを変異させたものについて探索を行った。その世代のすべての個体を Novelty Map を用いて含まれる個体同士の距離が最も大きくなるように選抜し、選抜された個体を中心として下位個体群とする。それぞれの下位個体群のうち最も適応度の高い個体と、それらを変異させた個体を次の世代として評価を行う。これを行うことで探索の方向を抽出した特徴量に応じて分散することができるため、効率的な探索が可能になると考えられる。

Contact: 井上 湧太、九州大学、福岡県福岡市西区周船寺 1 丁目 9 番地 19 パークホームズ周船寺 901 号、yi1306c12@gmail.com



図 1　OpenAI Gym[Brockman 16] の二足歩行シミュレーション（ BipedalWalker-v2）

2. 方法

学習環境には OpenAI Gym の 2 次元二足歩行シミュレーション環境である BipedalWalker-v2（ 図 1）を用いた [*1]。入力は、すべての入力を使用できる場合と、使用できる入力が制限される場合に分けて実験を行った。すべての入力が使用できる場合、使用可能な入力は胴体（ 図 1 中の紫色の多角形）の進行方向に対する速度、上下方向に対する速度、角度、角速度、両足の股関節、膝関節の角度、角速度、両足それぞれが地面と接しているかどうかなどの 24 つの入力を与えた。また入力は両足それぞれの股関節、膝関節の角度、それぞれの足が地面に付いているかどうかの計 6 つとした。出力は両足の股関節、膝関節の角速度の計 4 つであった。報酬はロボットの前進に応じて与えられた。また胴体の傾きや出力の大きさによって負の報酬が与えられた。到達地点まで達した場合 +300、ロボットの胴体（ 図 1 中の紫色の多角形）が地面（ 図 1 中の下部の緑色の部分）に接触した場合-100 の報酬を与え、試行を終了した。前述した条件で終了しなかった場合は、1 試行で最大 300 ステップを行った。各個体に対して 5 回の試行を行い、試行ごとの報酬の平均を適応度とした。SUNA のパラメータは Danilo & Murata

*1　https://gym.openai.com/envs/BipedalWalker-v2

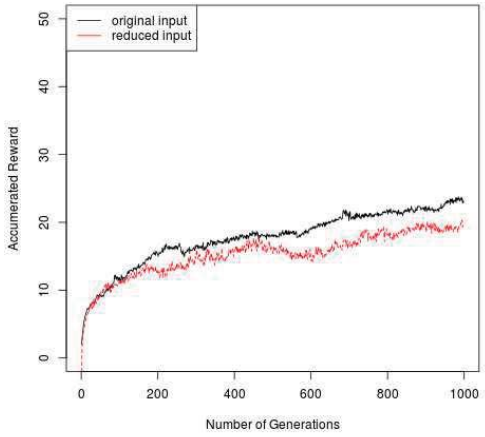


図 2　各世代で最も高かった適応度の、30 回の平均

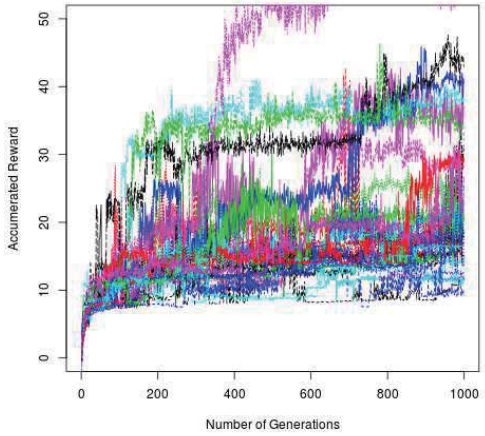


図 3　すべての入力を使用可能にした場合の各世代で最も高かった適応度の、実験 30 回のそれぞれの遷移

(2017)[Vargas 17] と同じものを使用した。1 世代あたりの個体数は 100 とし、1000 世代分の学習を行った。

3.　結果

実験を 30 回行った場合の、それぞれの学習において各世代での最も高い適応度の平均を図 2 に示す。また以下に 30 回行った実験それぞれでの、各世代での最も高い適応度の世代ごとの遷移を図 3 と図 4 に示す。

4.　考察

表 1 に、本実験の結果と同一の環境を用いて実験を行った [Zhang 17] の結果を示す。ただし SUNA の結果は 10^7 ステップの結果と合わせるため、100 世代目前後のものを使用している。ステップ数は正確に対応していないため直接の比較はできないが、SUNA の結果は NEAT と同程度であった。

入力数が 24 の場合と 6 の場合では、24 の場合のほうが良い結果を出している（ 図 2）。入力を限定した場合では実験ごとの

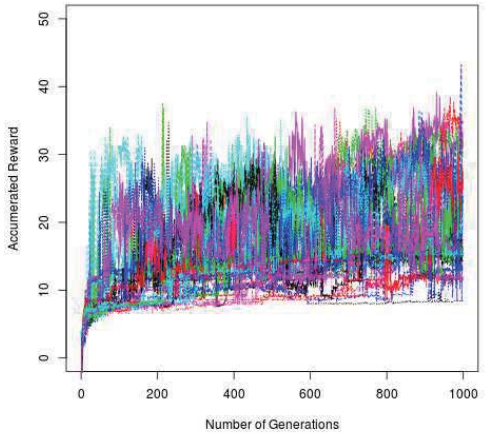


図 4　入力を制限した場合に各世代で最も高かった適応度の、実験 30 回のそれぞれの遷移

表 1　SUNA とその他の手法の結果の比較。Shangtong & Osmar（ 2017）[Zhang 17] の結果を使用した。ただしすべての値はグラフ（ Shangtong & Osmar（ 2017）,Figure. 2）から読み取った値である。

methods	SUNA	NEAT	NES	CMA	P3O
rewards	10	10	50	-100	300

適応度が世代数の増加とともに安定して上がらず（ 図 4）、入力数が多いほうが学習はスムーズであった（ 図 3）。SUNA では突然変異の際、ニューロン間の結合強度を変化させるかどうか決めてから、変化させるのであればそれぞれの結合強度を一様分布で得られた値を用いて変化させるという手段を取る。この方法では、これまでの進化で得られた有用なネットワークを保持しながら新しい構造を探索するようなことは難しいため、予め必要な情報が入力として用意されている場合のほうが学習に有利であると考える。

参考文献

[Brockman 16] Brockman, G., Cheung, V., Pettersson, L., Schneider, J., Schulman, J., Tang, J., and Zaremba, W.: OpenAI Gym, *CoRR*, Vol. abs/1606.01540, (2016)

[Stanley 02] Stanley, K. O. and Miikkulainen, R.: Evolving Neural Networks Through Augmenting Topologies, *Evol. Comput.*, Vol. 10, No. 2, pp. 99–127 (2002)

[Vargas 17] Vargas, D. V. and Murata, J.: Spectrum-Diverse Neuroevolution With Unified Neural Models, *IEEE Transactions on Neural Networks and Learning Systems*, pp. 1–15 (2017)

[Zhang 17] Zhang, S. and Zaiane, O. R.: Comparing Deep Reinforcement Learning and Evolutionary Methods in Continuous Control, *arXiv* (2017)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

分散表現を用いたトピック抽出における確率的変分推論法適用への取り組み

A Study on Stochastic Variational Inference for Topic Modeling with Word Embeddings

尾崎花奈 *1　小林 一郎 *2
Kana Ozaki　Ichiro Kobayashi

*1お茶の水女子大学理学部情報科学科　*2お茶の水女子大学基幹研究院自然科学系
Ochanomizu University　Ochanomizu University

Probabilistic topic models based on latent Dirichlet Allocation is widely used to extract latent topics from document collections. In recent years, a number of extended topic models have been proposed, especially Gaussain LDA(G-LDA) has attracted a lot of attention. G-LDA integrates topic modeling with word embeddings by replacing discrete topic distribution over word types with multivariate Gaussian distribution on the word embedding space. This can reflect semantic information into topics. In this paper, we use a G-LDA for our base topic model and apply Stochastic Variational Inference (SVI), an efficient inference algorithm, to estimate topics. This encourages the model to analyze massive document collections, including those arriving in a stream.

1. はじめに

トピックモデルは，文書の中に潜在的に存在するトピックを自動で抽出するためのモデルである．代表的な手法である LDA(Latent Dirichlet Allocation)[1] は，各文書に潜在トピックがあると仮定し，統計的に共起しやすい単語の集合が生成される要因を，潜在トピックという観測できない確率変数で定式化する．Das ら [2] によって提案された Gaussian LDA は，LDA の改良モデルであり、LDA に単語の分散表現 (Word embedding) を組み合わせている．従来の LDA ではトピックごとの単語分布をカテゴリ分布としていたのに対し，Gaussian LDA では embedding 空間上の多次元ガウス分布としている．単語の意味的関係性を事前知識として持つため，Gaussian LDA の方がトピックごとの自己相互情報量 (PMI) の値が高くなったと報告している．

Gaussian LDA における事後分布推定方法では，周辺化ギブスサンプリングを用いているが，本稿では SVI (Stochastic Variational Inference)[3][4] を用いることによって，計算時間の大幅な短縮を行い，大規模なコーパスに対しての効率的な処理を目指す．

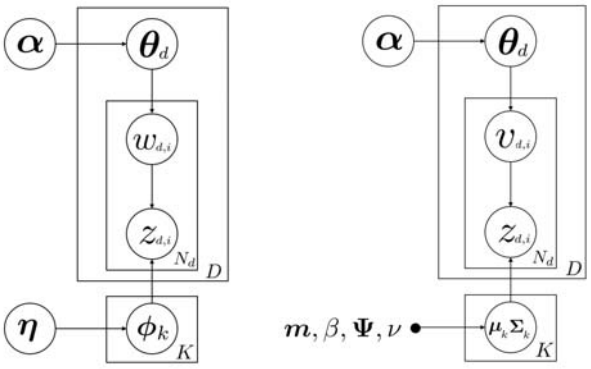
2. Gaussain LDA

まず，LDA におけるトピックを生成する分布を多次元ガウス分布にするモデルが Hu ら [5] によって提案された．このモデルに，単語の分散表現を組み合わせたものが Gaussian LDA [2] である．Embedding のツールとしては，word2vec [6] を用いている．連続空間に Embedding された単語ベクトルに対し，トピック k を同空間上での多次元ガウス分布としている．

単語の分散表現を用いることによって，トピック内の意味的結束性が向上し，実験結果として従来の LDA と比較して PMI が上昇することが確認されている．また，トピックの分布に連続分布を用いることによって，従来の LDA では対応できていなかった未知語に対しても，もう一度モデルでの推定を行うことなしに潜在トピックを割り当てることが可能になっている．

Gaussian LDA の生成モデルは以下のようになる．

連絡先: 尾崎花奈，お茶の水女子大学大学　情報科学科，〒 112-8610
東京都文京区大塚 2-1-1, g1420513@is.ocha.ac.jp



(a) LDA　(b) Gaussian LDA

図 1: LDA と Gaussian LDA のグラフィカルモデル

1. for $k = 1$ to K
   - **(a)** Draw topic covariance $\boldsymbol{\Sigma}_k \sim \mathcal{W}^{-1}(\boldsymbol{\Psi}, \mu)$
   - **(b)** Draw topic mean $\boldsymbol{\mu}_k \sim \mathcal{N}(\boldsymbol{\mu}, \frac{1}{\beta}\boldsymbol{\Sigma}_k)$
2. for each document d in corpus D
   - **(a)** Draw topic distribution $\boldsymbol{\theta}_d \sim \mathrm{Dir}(\boldsymbol{\alpha})$
   - **(b)** for each word index n from 1 to N_d
     (a) Draw a topic $z_n \sim \mathrm{Categorical}(\boldsymbol{\theta}_\mathrm{d})$
     (b) Draw $\boldsymbol{v}_{d,n} \sim \mathcal{N}(\boldsymbol{\mu}_{z_n}, \boldsymbol{\Sigma}_{z_n})$

ここで $\boldsymbol{\theta}_d$ は従来の LDA と同じく文書 d のトピック分布を表すが，$\boldsymbol{\mu}_k$,$\boldsymbol{\Sigma}_k$ はそれぞれトピック k における多次元ガウス分布の平均と分散を表している．また，$\boldsymbol{v}_{d,n}$ は単語ベクトルを表す．

LDA のグラフィカルモデルを図 1(a) に，Gaussian LDA のグラフィカルモデルを図 1(b) に示す．

3. SVI を用いたトピック推定

Gaussian LDA において，事後分布の推定には周辺化ギブスサンンプリングを用いていた．しかし，ギブスサンプリングは実装が簡潔である利点はあるが，計算時間が非常にかかる．

そこで本稿では, 確率的変分近似法 (SVI : Stochastic Variational Inference) [4] を用いることによって，計算時間の大幅な減少を実現し，大規模なデータに対して効率的にトピック解析することを目指す．

変分ベイズにおいては，真の事後分布に対してより簡単な近似分布 $q(\boldsymbol{z}, \boldsymbol{\theta}, \boldsymbol{\mu}, \boldsymbol{\Sigma})$ を考え，対数周辺尤度 $p(\boldsymbol{v}|\boldsymbol{\alpha}, \boldsymbol{\zeta})$ の変分下限を最大にする $q(\boldsymbol{z}, \boldsymbol{\theta}, \boldsymbol{\mu}, \boldsymbol{\Sigma})$ を求める．

$$\begin{aligned}\log p(\boldsymbol{v}|\boldsymbol{\alpha}, \boldsymbol{\zeta}) &\geq L(\boldsymbol{v}, \boldsymbol{\phi}, \boldsymbol{\gamma}, \boldsymbol{\zeta}) \\ &\triangleq \mathbb{E}_q[\log p(\boldsymbol{v}, \boldsymbol{z}, \boldsymbol{\theta}, \boldsymbol{\mu}, \boldsymbol{\Sigma}|\boldsymbol{\alpha}, \boldsymbol{\zeta})] \\ &\quad - \mathbb{E}_q[\log q(\boldsymbol{z}, \boldsymbol{\theta}, \boldsymbol{\mu}, \boldsymbol{\Sigma})].\end{aligned} \tag{1}$$

平均場近似に基づいて，近似分布 q に対して次のように各確率変数に独立性の仮定をおく．

$$q(\boldsymbol{z}, \boldsymbol{\theta}, \boldsymbol{\mu}, \boldsymbol{\Sigma}) = q(\boldsymbol{z})q(\boldsymbol{\theta})q(\boldsymbol{\mu}, \boldsymbol{\Sigma}). \tag{2}$$

単語ごとのトピック割り当て z のパラメータを ϕ, 文書ごとのトピック分布 θ のパラメータを γ，トピックごとの単語分布の平均と分散 $\boldsymbol{\mu}, \boldsymbol{\Sigma}$ のパラメータを $\boldsymbol{\zeta} = (\boldsymbol{m}, \beta, \boldsymbol{\Psi}, \nu)$ とすると，近似分布 q はそれぞれ以下のように表される．

$$\begin{aligned}q(z_{di} = k) &= \phi_{dw_{di}k}; \qquad q(\theta_d) = \mathrm{Dir}(\theta_\mathrm{d}|\gamma_\mathrm{d}), \\ q(\boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) &= NIW(\boldsymbol{\mu}, \boldsymbol{\Sigma}|\boldsymbol{m}, \beta, \boldsymbol{\Psi}, \nu).\end{aligned} \tag{3}$$

また，パラメータ $\boldsymbol{\phi}, \boldsymbol{\gamma}$ は以下のように定義される．

$$\begin{aligned}\phi_{dwk} &\propto \exp\{\mathbb{E}_q[\log \theta_{dk}] + \mathbb{E}_q[\log N(\boldsymbol{v}_{dw}|\boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)]\}, \\ \gamma_{dk} &= \alpha + \sum_w n_{dw}\phi_{dwk}.\end{aligned} \tag{4}$$

従来の変分近似法における LDA の学習では，文書データ全体に対して繰り返し学習が必要であったが，SVI は文書を逐次的に学習する．$q(\boldsymbol{z}_d), q(\boldsymbol{\theta}_d)$ は各文書ごとに学習される近似事後分布であるので逐次学習を行う必要はなく，逐次学習の対象となるのは $q(\boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)$ である．よって，パラメータ $\boldsymbol{\zeta} = (\boldsymbol{m}, \beta, \boldsymbol{\Psi}, \nu)$ の更新において, 確率的自然勾配法を用いた最適化を行う．

n_d 個の単語を含む d 番目の文書において，$\boldsymbol{\zeta}$ は固定して ϕ_d と γ_d の最適化を行う．次に，$\boldsymbol{\zeta}$ の中間パラメータ $\boldsymbol{\zeta}^* = (\boldsymbol{m}^*, \beta^*, \boldsymbol{\Psi}^*, \nu^*)$ を以下の式で求める．

$$\begin{aligned}{\beta_k}^* &= \beta + D\sum_w n_{dw}\phi_{dwk}; \qquad \nu_k^* = \nu + D\sum_w n_{dw}\phi_{dwk}, \\ \boldsymbol{m}_k^* &= \frac{\beta\boldsymbol{m} + D\sum_w n_{dw}\phi_{dwk}\bar{\boldsymbol{v}}_k}{\beta_k^*}, \\ \boldsymbol{\Psi}_k^* &= \boldsymbol{\psi} + \boldsymbol{C}_k + \frac{\beta D\sum_w n_{dw}\phi_{dwk}}{\beta_k^*}(\bar{\boldsymbol{v}}_k - \boldsymbol{m})(\bar{\boldsymbol{v}}_k - \boldsymbol{m})^\mathrm{T}.\end{aligned} \tag{5}$$

ここで,

$$\begin{aligned}\bar{\boldsymbol{v}}_k &= \frac{\sum_w n_{dw}\phi_{dwk}\boldsymbol{v}_{dw}}{\sum_w n_{dw}\phi_{dwk}}, \\ \boldsymbol{C}_k &= D\sum_w n_{dw}\phi_{dwk}(\boldsymbol{v}_{dw} - \bar{\boldsymbol{v}}_k)(\boldsymbol{v}_{dw} - \bar{\boldsymbol{v}}_k)^\mathrm{T}.\end{aligned} \tag{6}$$

D はコーパスの数を表しており，$\boldsymbol{\zeta}$ の計算を文書 d の複製 D 個に対して適用することを意味している．この操作によって，パラメータ $\boldsymbol{\phi}, \boldsymbol{\gamma}, \boldsymbol{\zeta}$ を更新する各イテレーションにおいてコーパス全体を必要とすることがなくなり，大規模なデータに対して逐次的な計算が可能になる．次のイテレーションに用いる $\boldsymbol{\zeta}$ は，$\rho_d \triangleq (\tau_0 + d)^{-\kappa}$，$\kappa \in (0.5, 1]$ で与えられるステップサイズによって，前回のイテレーションの $\boldsymbol{\zeta}$ と更新された $\boldsymbol{\zeta}^*$ に対して重みをかけることによって以下の式で求められる．

$$\boldsymbol{\zeta} = (1 - \rho_d)\boldsymbol{\zeta} + \rho_d\boldsymbol{\zeta}^*. \tag{7}$$

アルゴリズムは以下のようになる．

Algorithm 1 SVI for Gaussian LDA

Define $\rho_d \triangleq (\tau_0 + d)^{-\kappa}$
Initialize $\boldsymbol{m}, \beta, \boldsymbol{\Psi}, \nu$ randomly.
for $d = 0$ to ∞ **do**
  Estep:
  initialize $\gamma_{dk} = 1$ (The constant 1 is arbitrary.)
  repeat
    Set $\phi_{dwk} \propto \exp\{\mathbb{E}_q[\log \theta_{dk}] + \mathbb{E}_q[\log N(\boldsymbol{v}_{dw}|\boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)]\}$
    Set $\gamma_{dk} = \alpha + \sum_w n_{dw}\phi_{dwk}$
  until $\frac{1}{K}\sum_k |change\ in\ \gamma_{dk}| < 0.00001$
  Mstep:
  Compute $\boldsymbol{\zeta}_k^*$ with Eq.(5)
  Set $\boldsymbol{\zeta} = (1 - \rho_d)\boldsymbol{\zeta} + \rho_t\boldsymbol{\zeta}^*$
end for

4. まとめと今後の課題

本研究では，単語の分散表現を取り入れたトピックモデルにおいて，大規模テキストに対応できる効率の良い計算方法を導入する提案を行なった．今後は，実験を通じて提案手法の正当性を検証していく．

参考文献

[1] David M. Blei, Andrew Y. Ng, and Michael I. Jordan. (2003) Latent dirichlet allocation, J. Mach. Learn. Res., 3:993-1022, March.

[2] Rajarshi Das, Manzil Zaheer, and Chris Dyer. (2015) Gaussian LDA for topic models with word embeddings. In Proceedings of the 53nd Annual Meeting of the Association for Computational Linguistics.

[3] Matthew D. Hoffman, David M. Blei, Francis Bach. (2010) Online Learning for Latent Dirichlet Allocation. In Advances in Neural Information Processing Systems.

[4] Matthew D. Hoffman, David M. Blei, Chong Wang, John Paisley. (2013) Stochastic variational inference. The Journal of Machine Learning Reseach, 14(1):1303-1347.

[5] Pengfei Hu, Wenju Liu, Wei Jiang, and Zhanlei Yang. (2012) Latent topic model based on Gaussian-LDA for audio retrieval. In Pattern Recognition, volume 321 of CCIS, pages 556-563. Springer.

[6] Tomas Mikolov, Wen-tau Yih, and Geoffrey Zweig. (2013) Linguistic regularities in continuous space word representations. In Proceedings of the 2013 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, pages 746-751, Atlanta, Georgia, June.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

データ分布の関数パラメータとしてのカーネル中央値

Kernel median embedding as a functional parameter of the data distribution

マシュー ホーランド *1
Matthew J. Holland

*1大阪大学 データビリティフロンティア機構
Osaka University, Institute for Datability Science

In both supervised and unsupervised learning tasks, embedding the underlying data into a function space using a "kernel mean" has been well-studied, and is known to be an efficient means of characterizing even complex distributions. Here we consider a broad generalization of this notion to countless "functional parameters" of the underlying distribution, and as a concrete example explore what may naturally be called the "kernel median" of the data. In this short paper, we formulate the new parameter class, provide a procedure for obtaining an important special case, with basic convergence guarantees and expressions useful for practical implementation.

1. はじめに

機械学習の研究者の多くがニューラルネットワークに着目するなか，強力な理論的保証と長い歴史を持つカーネル法も忘れてはならない．本稿では，kernel mean をデータ分布から再生核ヒルベルト空間への写像と見なして，データ分布の特徴を簡潔に求める新しい手法を提案する．

古典的な統計学では，所与とした標本 $\boldsymbol{z}_1, \dots, \boldsymbol{z}_n \in \mathcal{Z}$ の確率分布が $\boldsymbol{z} \sim \mu$ であるとして，その分布 μ をある程度 (場合によっては完全に) 特徴づけるような有限個のパラメータを推定することが代表的な問題である．しかし，現代の機械学習の応用問題を見据えて，有限の長さを持つ実数値パラメータベクトルだけで，コンパクトに複雑な分布を符号化することは難しい．そこで，計算コストと表現力なるパフォーマンスの釣り合った方法として，入力空間上のカーネル関数 $k : \mathcal{Z} \times \mathcal{Z} \to \mathbb{R}$ を介して，その分布 μ を再生核ヒルベルト空間別の関数空間 $(\mathcal{H}, \langle \cdot, \cdot \rangle_{\mathcal{H}})$ へと写像していく "kernel mean" にまつわる手法が注目されている [Muandet et al., 2016]．その定義をまず述べておくと，k と $\mathcal{H}$ を固定し，

$$\mathbf{E}_\mu \, k(\boldsymbol{z}, \cdot) := \int_{\mathcal{Z}} k(\boldsymbol{z}, \cdot) \, d\mu(\boldsymbol{z}) \in \mathcal{H} \tag{1}$$

を確率分布 μ の**カーネル平均** (kernel mean) と呼ぶ．カーネル平均さえ知っていれば十分とい問題・手法が多々ある [Muandet et al., 2014]．そのため，この理論上の関数 $\mathbf{E}_\mu \, k(\boldsymbol{z}, \cdot)$ を効率的に近似できるのであれば，密度推定を介さずとも多様な問題が解けるようになるという大きな潜在的なメリットを持つ．従来の近似方法として，μ を経験分布に置き換えて，

$$\bar{\pi} := \arg\min_{f \in \mathcal{H}} \frac{1}{n} \sum_{i=1}^{n} d(\Phi_{\boldsymbol{z}_i}, f) \tag{2}$$

を使うことが多い．文献の上では，この推定量は調べ尽くされている [Tsybakov, 2009]．また，カーネル関数を $\Phi_{\boldsymbol{z}}(\cdot) := k(\boldsymbol{z}, \cdot)$，ノルムを $\|f\|_{\mathcal{H}} := \sqrt{\langle f, f \rangle_{\mathcal{H}}}$ で表記すると，

$$\mathbf{E}_\mu \, k(\boldsymbol{z}, \cdot) \in \arg\min_{f \in \mathcal{H}} \mathbf{E}_\mu \, \|\Phi_{\boldsymbol{z}} - f\|_{\mathcal{H}}^2 \tag{3}$$

が成り立つことは容易に確認できる．学習理論から見ると，これは空間 $\mathcal{H}$ 上の自乗誤差を使っての経験期待損失最小化 (empirical risk minimization; ERM) の解にほかならず，その脆弱性がここ数年では大いに注目されている [Minsker, 2016, Lugosi and Mendelson, 2016].

これらの事実を踏まえて，次の疑問点を挙げる．

1. 学習効率の観点から，$\bar{\pi} \approx \mathbf{E}_\mu \, k(\boldsymbol{z}, \cdot)$ で良いか．
2. 自乗誤差以外の距離を使うメリットがあるか．

次節以降では後者に焦点を当て，カーネル平均の概念を拡げ，特に「カーネル中央値」とでもいうべき新たな符号化方法の効率的なアルゴリズムを提案する．

2. 提案手法

本研究の基となる発想は至って単純である．実数線上の確率変数 x を考えると，その期待値 $\mathbf{E}\, x$ が，$\mathbf{E}(x-u)^2$ を u の関数として最小にするのである．一方，絶対誤差にすると，$\mathbf{E}\,|x-u|$ を u について最小にするのは，x の中央値である．先ほどの式 (3) を念頭において類推すると，

$$\mathrm{med}_k(\mu) := \arg\min_{f \in \mathcal{H}} \mathbf{E}_\mu \, \|\Phi_{\boldsymbol{z}} - f\|_{\mathcal{H}}, \tag{4}$$

連絡先: Matthew J. Holland
大阪大学データビリティフロンティア機構
大阪府吹田市山田丘 2-8
matthew-h@ids.osaka-u.ac.jp

をカーネル中央値 (kernel median) と呼ぶことが自然であろう．同様に考えることで分布 μ の多様なパラメータのクラスを新たに提案することができて，たとえば，適当な距離関数 $d : \mathcal{H} \times \mathcal{H} \to \mathbb{R}_+$ を取って，

$$\pi(\mu; d) := \arg\min_{f \in \mathcal{H}} \mathbf{E}_\mu \, d(\Phi_{\boldsymbol{z}}, f) \tag{5}$$

のような関数パラメータ族が考えられる．自乗誤差と同様，$d(\Phi_{\boldsymbol{z}}, f)$ の分布の如何によっては，その推定しやすさと，μ の代替的表現としての性質が大きく変わり得る．紙幅の制約もあるため，経験分布の下，カーネル中央値を推定するアルゴリズムについて考察していく．

観測データ $S_n := \{\boldsymbol{z}_1, \ldots, \boldsymbol{z}_n\} \subset \mathcal{Z}$ を与えられ，$\mathrm{med}_k(\mu)$ の不偏推定量として，

$$\mathrm{med}_k \, S_n := \arg\min_{f \in \mathcal{H}} \frac{1}{n} \sum_{i=1}^{n} \|\Phi_{\boldsymbol{z}_i} - f\|_{\mathcal{H}} \tag{6}$$

を考える．この**経験カーネル中央値** (empirical kernel median) を求める計算方法を Algorithm 1 として一覧化する．

導出方法について簡単に解説していく．

$$C(h) := \sum_{i=1}^{n} \|h - h_i\|$$

という目的関数を考えると，基本的には単なる $C(\cdot)$ の最急降下法に近い．もし任意の $i = 1, \ldots, n$ に対して $f \neq \Phi_{\boldsymbol{z}_i}$ なのであれば，

$$\sum_{i=1}^{n} \frac{\Phi_{\boldsymbol{z}_i} - f}{\|\Phi_{\boldsymbol{z}_i} - f\|_{\mathcal{H}}} = 0$$

を満たすことが最小値の一階条件である．整理すると

$$f \leftarrow \left(\sum_{i=1}^{n} \|\Phi_{\boldsymbol{z}_i} - f\|_{\mathcal{H}}^{-1} \right)^{-1} \sum_{i=1}^{n} \|\Phi_{\boldsymbol{z}_i} - f\|_{\mathcal{H}}^{-1} \Phi_{\boldsymbol{z}_i} \tag{7}$$

という反復更新則がそのまま出てくる．これは Algorithm 1 にある Weiszfeld のスペシャルケースである [*1]．ここで問題となるのは，更新則 (7) は $f \notin \{\Phi_{\boldsymbol{z}_i}\}_{i=1}^n$ を前提としていることである．しかし，更新後の結果が $\{\Phi_{\boldsymbol{z}_i}\}_{i=1}^n$ の要素と一致しない保証はない．一致しないなら $A_{(t)}$ のみ非零となって Weiszfeld を実行することになるが，一致してしまった場合は $B_{(t)}$ も非零となって，最適解でない限り $\{\Phi_{\boldsymbol{z}_i}\}_{i=1}^n$ から候補 $\boldsymbol{u}_{(t)}$ を動かすのである．$B_{(t)}$ の具体的な形式は，$C(\cdot)$ を局所的に近似する関数 $\widehat{C}(\cdot)$ に対して，確実な改善 $\widehat{C}(\boldsymbol{u}_{(t+1)}) < \widehat{C}(\boldsymbol{u}_{(t)})$ を保証する条件として導出できる (詳細は省略)．

*1 ユークリッド空間の場合，この更新則は古く，遅くても [Weiszfeld, 1937] が提案している．

Algorithm 1 経験カーネル中央値の算出

function Weiszfeld($\boldsymbol{u}; S = \{\boldsymbol{v}_1, \boldsymbol{v}_2, \ldots\}$)

return $\left(\sum_{i \in [|S|]} \|\boldsymbol{v}_i - \boldsymbol{u}\|^{-1} \right)^{-1} \sum_{i \in [|S|]} \|\boldsymbol{v}_i - \boldsymbol{u}\|^{-1} \boldsymbol{v}_i$

end function

inputs: $\epsilon > 0$, $\boldsymbol{\Phi} = \{\Phi_{\boldsymbol{z}_1}, \ldots, \Phi_{\boldsymbol{z}_n}\}$, $\widetilde{T}(\boldsymbol{u}) := \mathrm{Weiszfeld}(\boldsymbol{u}; \boldsymbol{\Phi})$

initialize: $\boldsymbol{u}_{(0)} = \frac{1}{n} \sum_{i=1}^{n} \Phi_{\boldsymbol{z}_i}$, $\epsilon_{(0)} > \epsilon$, $t = 0$

while $\epsilon_{(t)} > \epsilon$ **do**

$\mathcal{I}_{(t)} \leftarrow \{i : \Phi_{\boldsymbol{z}_i} \neq \boldsymbol{u}_{(t)}\}$

$\boldsymbol{g}_{(t)} \leftarrow \sum_{i \in \mathcal{I}_{(t)}} \frac{\Phi_{\boldsymbol{z}_i} - \boldsymbol{u}_{(t)}}{\|\Phi_{\boldsymbol{z}_i} - \boldsymbol{u}_{(t)}\|}$

$A_{(t)} \leftarrow \left(1 - \frac{|\mathcal{I}_{(t)}^c|}{\|\boldsymbol{g}_{(t)}\|}\right)_+ \widetilde{T}(\boldsymbol{u}_{(t)})$

$B_{(t)} \leftarrow \min\left(1, \frac{|\mathcal{I}_{(t)}^c|}{\|\boldsymbol{g}_{(t)}\|}\right) \boldsymbol{u}_{(t)}$

$\boldsymbol{u}_{(t+1)} \leftarrow A_{(t)} + B_{(t)}$

$\epsilon_{(t+1)} \leftarrow \|\boldsymbol{u}_{(t+1)} - \boldsymbol{u}_{(t)}\|$

$t \leftarrow t + 1$

end while

return $\boldsymbol{u}_{(t)}$

3. 学習則の基本的な性質

まず，証明できる重要な理論上の性質を端的に紹介する．軽微な正則条件の下，解は必ず存在する．その上で $\{\Phi_{\boldsymbol{z}_i}\}_{i=1}^n$ がすべて同一線上である場合とそうでない場合に分ける．前者は，それらの重みづけの中央値を取ることで解がすぐに求まる．後者は反復していくしかないが，Algorithm 1 の更新則で $\boldsymbol{u}_{(t)}$ が最適解でない限り，

$$C(\boldsymbol{u}_{(t+1)}) < C(\boldsymbol{u}_{(t)})$$

と単調的な改善は保証できる．そのため，有限回の更新で最適解に到達することも証明できる．

上記の性質のほか，計算機でこのアルゴリズムを実装するにあたって，$\boldsymbol{u}_{(t)}$ が関数であることを踏まえて，効率的にどのように表現すべきかは一見して，自明ではない．幸い，初期値 $\boldsymbol{u}_{(0)}$ が $\{\Phi_{\boldsymbol{z}_i}\}_{i=1}^n$ の凸包に含まれているなら，更新則の性質上，$\boldsymbol{u}_{(t)}$ も同様に凸包に含まれる．つまり，下記のとおりに特徴量関数の凸結合と

して表せるのである．

$$\boldsymbol{u}_{(t)} = \sum_{i=1}^{n} w_i^{(t)} \Phi_{\boldsymbol{z}_i}$$

$$0 \leq w_i^{(t)} \leq 1, i \in [n], \quad \sum_{i=1}^{n} w_i^{(t)} = 1$$

よって，n 個の係数とデータ $\{\boldsymbol{z}_i\}_{i=1}^n$ さえ格納しておけば $\boldsymbol{u}_{(t)}$ は求められる．

実装上，計算する係数がいくつもあるので，ここで整理して表わすことにする．まず，更新 $\widetilde{T}(\cdot)$ は定義上，特徴量関数の凸結合であり，$\widetilde{T}(\boldsymbol{u}_{(t)}) = \sum_{i=1}^n \widetilde{w}_i^{(t)} \Phi_{\boldsymbol{z}_i}$ と表せる．これらの重み $\{\widetilde{w}_i^{(t)}\}_{i=1}^n$ は

$$\widetilde{w}_i^{(t)} = \left(\sum_{j=1}^{n} \| \Phi_{\boldsymbol{z}_j} - \boldsymbol{u}_{(t)} \|^{-1} \right)^{-1} \| \Phi_{\boldsymbol{z}_i} - \boldsymbol{u}_{(t)} \|^{-1}$$

という形を取るが，再生核ヒルベルト空間の基本的な性質を利用して，距離を次のように計算できる．内積は

$$\begin{aligned} \| \Phi_{\boldsymbol{z}_i} - \boldsymbol{u}_{(t)} \|^2 &= \| \Phi_{\boldsymbol{z}_i} \|^2 - 2 \langle \Phi_{\boldsymbol{z}_i}, \boldsymbol{u}_{(t)} \rangle + \| \boldsymbol{u}_{(t)} \|^2 \\ &:= A_i - 2B_i^{(t)} + C^{(t)} \end{aligned}$$

と分解できる（$A_i := \| \Phi_{\boldsymbol{z}_i} \|^2$，$B_i^{(t)} := \langle \Phi_{\boldsymbol{z}_i}, \boldsymbol{u}_{(t)} \rangle$，$C^{(t)} := \| \boldsymbol{u}_{(t)} \|^2$）．これらの要素は

$$A_i = k(\boldsymbol{z}_i, \boldsymbol{z}_i)$$

$$B_i^{(t)} = \sum_{j=1}^{n} w_j^{(t)} k(\boldsymbol{z}_i, \boldsymbol{z}_j)$$

$$C^{(t)} = \sum_{i=1}^{n} \left(w_i^{(t)} \right)^2 k(\boldsymbol{z}_i, \boldsymbol{z}_i) + 2 \sum_{i<j} w_i^{(t)} w_j^{(t)} k(\boldsymbol{z}_i, \boldsymbol{z}_j)$$

と容易に求めることができる．A_i は事前に計算しておくことができるが，$B_i^{(t)}$ と $C^{(t)}$ は更新するごとに値が変わる．$|\mathcal{I}_{(t)}^c|$ は各 $i \in [n]$ に対して $\| \Phi_{\boldsymbol{z}_i} - \boldsymbol{u}_{(t)} \|$ がわかれば十分なので，A_i，$B_i^{(t)}$，$C^{(t)}$ を入手すれば計算できる．最後は $\| \boldsymbol{g}_{(t)} \|$ だが，その自乗を取ると，次のように求まる：

$$\begin{aligned} \| \boldsymbol{g}_{(t)} \|^2 = & \\ & \sum_{i=1}^{n} \left(a_i^{(t)} \right)^2 \left(A_i - 2B_i^{(t)} + C^{(t)} \right) \\ & + 2 \sum_{i<j} a_i^{(t)} a_j^{(t)} \left(k(\boldsymbol{z}_i, \boldsymbol{z}_j) - B_i^{(t)} - B_j^{(t)} + C^{(t)} \right). \end{aligned}$$

可読性を高めるため，$a_i^{(t)} := \| \Phi_{\boldsymbol{z}_i} - \boldsymbol{u}_{(t)} \|^{-1}$ と表記している．

4. 関連研究との比較

本稿の第一節で先述の通り，分布を関数空間へと写像していくカーネル平均を生かした学習アルゴリズムが多数あり，実験・理論ともに解析の対象となっている [Muandet et al., 2016, Tolstikhin et al., 2016]．本研究の最大の特徴として，このカーネル平均の概念を一般的な関数パラメータへと拡張した上で，解釈しやすい計算可能な具体例としてカーネル中央値を提案している点が挙げられる．より技術的な貢献として，本稿では詳細を省いているが，Weiszfeld の解析を手がけた [Kuhn, 1973] の結果をユークリッド空間から任意のヒルベルト空間 (=完備内積空間) へ拡張している点，また [Vardi and Zhang, 2000] の手法を，$\{\Phi_{\boldsymbol{z}_i}\}_{i=1}^n$ 内の複数点が重複しても $C(\cdot)$ の単調減少が保証できるように改造している点が新しい．距離の和を最小にするアルゴリズムは一般に geometric median と呼ばれることが多く，学習アルゴリズムに導入したときの統計的なロバスト性は [Minsker et al., 2014, Minsker, 2015] などで調べられている．

5. おわりに

本稿では，データの分布をコンパクトに符号化する新しい手法として分布の関数パラメータに着目し，そのスペシャルケースとしてカーネル中央値を求める算法を取り上げた．このアルゴリズムの単調性と収束条件および計算機上の表現など，基本的な性質を明らかにした．この土台を踏まえて，次はカーネル平均が導入している統計的学習アルゴリズムに代替的に適用することによって，学習効率をめぐる定量的な性能保証がどう変わるか，それぞれの挙動が定性的にどう異なるかという点に着目しながら，学習課題に応じての優劣を明らかにして新たな方法論を目指していく．

参考文献

[Kuhn, 1973] Kuhn, H. W. (1973). A note on Fermat's problem. *Mathematical Programming*, 4(1):98–107.

[Lugosi and Mendelson, 2016] Lugosi, G. and Mendelson, S. (2016). Risk minimization by median-of-means tournaments. *arXiv preprint arXiv:1608.00757*.

[Minsker, 2015] Minsker, S. (2015). Geometric median and robust estimation in Banach spaces. *Bernoulli*, 21(4):2308–2335.

[Minsker, 2016] Minsker, S. (2016). Sub-Gaussian estimators of the mean of a random matrix with heavy-tailed entries. *arXiv preprint arXiv:1605.07129*.

[Minsker et al., 2014] Minsker, S., Srivastava, S., Lin, L., and Dunson, D. B. (2014). Robust and scalable Bayes via a median of subset posterior measures. *arXiv preprint arXiv:1403.2660*.

[Muandet et al., 2014] Muandet, K., Fukumizu, K., Sriperumbudur, B., Gretton, A., and Schölkopf,

B. (2014). Kernel mean estimation and Stein effect. In *JMLR W&CP: Proceedings of The International Conference on Machine Learning*, volume 32, pages 10–18.

[Muandet et al., 2016] Muandet, K., Sriperumbudur, B., Fukumizu, K., Gretton, A., and Schölkopf, B. (2016). Kernel mean shrinkage estimators. *Journal of Machine Learning Research*, 17(48):1–41.

[Tolstikhin et al., 2016] Tolstikhin, I., Sriperumbudur, B., and Muandet, K. (2016). Minimax estimation of kernel mean embeddings. *arXiv preprint arXiv:1602.04361*.

[Tsybakov, 2009] Tsybakov, A. B. (2009). *Introduction to Nonparametric Estimation*. Springer.

[Vardi and Zhang, 2000] Vardi, Y. and Zhang, C.-H. (2000). The multivariate L_1-median and associated data depth. *Proceedings of the National Academy of Sciences*, 97(4):1423–1426.

[Weiszfeld, 1937] Weiszfeld, E. (1937). Sur le point pour lequel la somme des distances de n points donnés est minimum. *Tohoku Mathematical Journal, First Series*, 43:355–386.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

順位相関係数を保証するノイズありソートアルゴリズム

On Incomplete Noisy Sorting

小宮山 純平 *1
Junpei Komiyama

*1東京大学生産技術研究所
The Institute of Industrial Science, the University of Tokyo.

This paper discusses the way to sort items by the noisy feedback of pairwise comparisons. An algorithm that partially sorts items are provided, and its empirical performance is shown.

1. はじめに

要素の良さに順序をつけたい場合は多い．経済学の 1 分野である社会選好理論 [Arr63] は個人の選好をまとめて統一する方法を研究する学問である．情報科学の分野でも、要素の順序付けは重要である．例えば、推薦システム、検索エンジン、オンライン広告などは、ユーザにどのような要素が好まれるかの選好の研究だと考えることができる．

要素に順序をつけるための最も簡単な方法は、ペア比較をくり返すことである．本研究では、動的に要素がクエリ可能な下での、ペア比較による要素の順序の決定を考える．つまり、順序付けのアルゴリズムが、順序を効率的に決定するために次に比較するペアを選べるというものである．これは、次のような応用を想定している．

- 推薦アルゴリズム、検索エンジンなどのエンジンの比較を、ユーザに複数の結果を見てもらうことにより比較する [CJRY12]
- 将棋や囲碁などのゲーム AI プログラムがいくつかあったときに、どのプログラムが強いかをプログラム同士の対戦の勝敗により決定する．

ペア数は要素数 K に対して $K(K-1)/2 = O(K^2)$ であり、K が大きい場合のランダムな比較はスケールしない．しかし、要素の間に順序関係を仮定し、効率の良い比較スケジュールを立てると、$O(K \log K)$ の比較で順序を決定することができる．ここで、ペア (i,j) の選好を $i \succ j$ と書いたときに、要素 i が要素 j より優れると呼び、この場合 $\mu_{i,j} > 1/2$ を要素 i の要素 j に対する勝率と言うことにする．

関連研究：本研究は、要素間の順序をつけるという意味でソートアルゴリズムの研究である．クイックソート、マージソートなどの通常のソートアルゴリズムは、ペアを比較するとその順序関係が得られる状況を仮定している．一方で、我々のケースはフィードバックがノイズを含むということを仮定している．つまり、ペア (i,j) を比較した場合、より優れたほうが 0.5 を超える勝率を持つものの、フィードバックは確率的な要素を伴う．このような確率的フィードバック下での順序付けは、ノイズありソーティング (noisy sorting) として 1980-90 年代に研究された [FRPU94]．ノイズありソーティングでは、ある定数 $\lambda \in (0, 0.5)$ が存在し、$\mu_{i,j} > 0.5 + \lambda$ を仮定し、この λ に応じた比較回数を抑えることが多い．一方、近年の機械学習では、ノイズありソーティングとやや離れた文脈で要素間の順序付けを行っている．比較バンディット問題 [YBKJ12, KHKN15] は、検索エンジンの比較をモチベーションとし、オンラインの設定で複数の要素の優劣を探す問題をモデル化している．関連して、オンライン順序決定（online rank elicitation) や PAC 順序決定（Probability-Approximately-Correct rank elicitation）と呼ばれる分野で、ノイズのあるソーティングと同じく要素間の順序付けが行われている [BSH14, SBPH15]．

これらの関連研究は、それぞれの仮定下で順序の完全な復元を可能とするアルゴリズムを提案している．しかし、要素数が多い場合、順序の完全な復元は $O(K \log K)$ で終わるとはいえども、現実的には非常に高コストである．これは、ペア (i,j) の勝率が 0.5 に近い場合、どちらが良いかの決定に本質的に大きな比較回数がかかるからである．つまり、大偏差原理 [CT06] により、ペア (i,j) の順序付けは $O(1/(\mu_{i,j}-0.5)^2)$ 回の比較回数が本質的に必要である．これは、例えば、非常に実力が拮抗した AI プログラム間の優劣をつけるためにはたくさんの対戦が必要だということから理解可能であろう．一方で、多くの応用では要素に対する大雑把な順序づけが十分であろう．例えば、テニスの試合で Top-100 の選手の勢力図を決めるためには、フェデラーやマレー、錦織などの Top-10 に入るであろうプレイヤー、Top-30 程度のプレイヤー、Top-50 以下のプレイヤー、ぐらいの大雑把な区分けは、多くの人にとって必要十分ではないだろうか．

このようなことを考慮に入れた上で、本研究は「大雑把な順序付け」を少ない比較回数、理論的な保証ありで行うことを目指す．節 2.で問題設定と「大雑把な順序付け」の基準であるケンドールの順位相関係数を行う．節 3.では順序づけのアルゴリズムを提案する．節 4.では数値実験により提案アルゴリズムの良さを評価する．おわりに，節 5.で本研究を総括する．

2. 問題設定

K 個のアイテム集合 $[K] := \{1, 2, \ldots, K\}$ をソートすることを考える．要素は全順序を持つと考える：つまり，アイテムのペア i, j に対し，$i \succ j$ ならペアを比較したときの i の勝率 $\mu_{i,j} \in (0,1)$ が $\mu_{i,j} > 1/2$ である．一般性を失うことなく，アイテムの順序は $1 \succ 2 \succ \cdots \succ K$ であるとする．もちろん，アルゴリズムはこの順序を知らず，ペアの比較を通じて順序を推定するのがアルゴリズムの目的となる．各時間ステップ $t = 1, 2, \ldots$ に，アルゴリズムはアイテムのペアを選び，どちらが好まれるかというフィードバックを受け取る．各時間ステップの終了時に，アルゴリズムは比較の終了を選び，

連絡先: 小宮山 純平, 東京大学生産技術研究所, 〒 153-8505 東京都目黒区駒場 4-6-1, junpei@komiyama.info

予測順位[*1] $\boldsymbol{r}(1), \boldsymbol{r}(2), \ldots, \boldsymbol{r}(K)$ を出力して良い．そうでないなら，次の時間ステップに進む．本研究では，任意の順序と勝率 $\{\mu_{i,j}\}$ に対して有限時間で確率 1 で終了するアルゴリズムのみを扱う．

2.1 ケンドールの順位相関係数

ケンドールの順位相関係数は，2 つの順序がどの程度近いかを測る指標の一つであり，一様ランダムにペアを選択したときに，2 つの順序間でペアの順序が一致する割合で定義される．本研究では真の順序 $(1, 2, \ldots, K)$ とアルゴリズムの予想した順序 $(\boldsymbol{r}(1), \boldsymbol{r}(2), \ldots, \boldsymbol{r}(K))$ の間の順位相関係数：

$$\frac{1}{K(K-1)/2} \sum_{i<j} 2(\mathbf{1}(\boldsymbol{r}(j) - \boldsymbol{r}(i)) - 0.5).$$

を考える．ここで，$\mathbf{1}(X)$ は $X > 0$ なら 1，そうでないなら 0 とする．順位相関係数は，真の順序と予想した順序が完全に一致している場合に 1 になり，完全に一致していない場合に 0 になる．所与の $\delta \in (0, 1), \tau \in [0, 1]$ に対し，$\boldsymbol{r}(1), \boldsymbol{r}(2), \ldots, \boldsymbol{r}(K)$ の順位相関係数が $\tau \in (0, 1)$ を超える確率が $1 - \delta$ 以上であるとき，アルゴリズムは δ-τ 調和であるという．本論文では，δ-τ 調和であるアルゴリズムのうち，終了までの平均時間ステップ（＝比較回数）が少ないものを探す．τ の値に関して制限は求めないが，実用的には 1 にある程度近い値を想定している．

3. アルゴリズム

本節では，最初に，境界通過確率に基づいた統計的優位性を持ったペアの比較を提案し，次にそれを利用した δ-τ 調和なソートアルゴリズムである Iterative Quick Sort (IQS) を提案する．

3.1 ペア順序の判定と統計検定

本小節は主に統計検定に親しい方に対して境界通過確率の導入について解説しているが，統計検定にそれほど興味がない読者は飛ばさしていただいても構わない．ペア (i, j) の順序の決定は統計検定と考えることができる．帰無仮説は

$$H_0 : \mu_{i,j} = 1/2$$

であり，対立仮説は

$$H_i : \mu_{i,j} > 1/2$$
$$H_j : \mu_{i,j} < 1/2$$

である．通常の仮設検定は，固定した回数の比較を行った後で帰無仮説を棄却することを目指すが，本研究の設定では動的に比較回数を増やすことが可能であり，このような場合は通常の仮設検定と異なる確率過程の考慮が必要となる．このことを考慮し，節 3.2では，境界通過確率に基づいた停止時刻を説明する．

3.2 境界通過確率

境界通過確率は，ランダムなサンプル系列が与えられたときに，その平均値[*2] がサンプル系列を通じて一貫して持つ性質である．今回の場合はあるペアの勝率が 0.5 より小さいのか大きいのかの決定が焦点になるが，各ラウンドでの平均勝率がどの程度であればこの決定ができるかは，まさに境界通過確率の一つの応用先である．ペア i, j に対し，$X_1, X_2, \ldots, X_n$ をペア間比較結果を示す確率変数とする．つまり，k 回目の比較でアイテム i が好まれた場合に $X_k = 1$，逆に j が好まれれば $X_k = 0$ である．また，$\hat{\mu}_{i,j} = (1/n) \sum_{k=1}^{n} X_k$ をその平均値とする．$\hat{\mu}_{i,j}$ が 0.5 より大幅に大きい場合は i のほうが良いアイテムだと想像できるが，これの厳密な境界を境界通過確率によって考えたい．つまり，$\hat{\mu}_{i,j} = \hat{\mu}_{i,j}(n)$ の関数としての停止時刻 τ で，誤って停止してしまう確率を δ 以下にするものを考えたい：

$$\mathbb{P}[\tau < +\infty | \mu_n = 1/2] \leq \delta \tag{1}$$

境界通過確率は，70 年代に Lai, Robbins, Siegmund らの著名な研究者によって調べられたが [Sie85]，彼らの手法は主に X_k が（今回と異なり）正規分布のときに正規分布を確率過程に埋め込む方向について研究されている．サンプル数が多い時に $\hat{\mu}_{i,j}$ は正規分布するものの，有限の値では今回の比較のような Bernoulli 分布の期待値を正規分布近似するのはリスクを伴う可能性がある．そのため，正規分布近似式の境界通過確率は今回扱わない．1990 年代において境界通過確率は一度研究が減速してしまったが，A/B テストやオンライン広告での応用 [JKPW17, Mai17] などを契機に近年再注目を浴びている概念である．本研究では，比較的使いやすい境界通過確率として以下のものを用いる．

$$\tau_{\mathrm{u}} = \tau_{\mathrm{u}}(\delta) = \min_{n \geq 10} \left\{ n d_{\mathrm{KL}}(\hat{\mu}_{i,j}(n), 1/2) \geq \log \left(\frac{n (\log n)^2 K^2}{4\delta} \right) \right\}.$$

Theorem 1. τ_{u} は境界通過確率の条件式 (1) を満たす．

証明は紙面の都合上省略する．

Algorithm 1 Iterative Quick Sort (IQS) algorithm.

順位相関係数 τ_0, 信頼度 δ, アイテム $[K]$.
初期ソート結果 $\boldsymbol{r}(1), \boldsymbol{r}(2), \ldots, \boldsymbol{r}(K)$.
for 各フェーズ $p = 1, 2, \ldots$ **do**
  $N_p \leftarrow 4^p$.
  $Q \leftarrow (\boldsymbol{r}(1), \boldsymbol{r}(2), \ldots, \boldsymbol{r}(K))$.
  while Q is not empty **do**
    Q の最初の要素 $(r_1, \ldots, r_l)$ を取り出す.
    中央要素をピボットにする：$p \leftarrow r_{(i+j)/2}$.
    ピボット以外の各要素 $k \in (r_1, \ldots, r_l) : k \neq p$ を p と比較する．このとき，このペアを $N_{k,p} := \min(N_p, \tau_{k,p}(\delta/(K(K-1)/2))$ 回比較する.
    $f_1, \ldots, f_{l_f} \leftarrow \{r_i : i \neq p, \hat{\mu}_{i,p} \geq 1/2\}$, $b_1, \ldots, b_{l_b} \leftarrow \{r_i : i \neq p, \hat{\mu}_{i,p} < 1/2\}$.
    ピボットとの比較で要素を並び替える：$(r_1, \ldots, r_l) \leftarrow (f_1, \ldots, f_{l_f}, r_p, b_1, \ldots, b_{l_b})$.
    $l_{\mathrm{fin}} \leftarrow |\{k \in \{f_1, \ldots, f_{l_f}\} : N_{k,p} = \tau_{k,p}\}|$.
    $r_{\mathrm{fin}} \leftarrow |\{k \in \{b_1, \ldots, b_{l_b}\} : N_{k,p} = \tau_{k,p}\}|$.
    $\hat{\tau}_{\mathrm{LB}} \leftarrow \hat{\tau}_{\mathrm{LB}} + \frac{(l_{\mathrm{fin}}+1)(r_{\mathrm{fin}}+1)-1}{(K(K-1)/2)}$.
    $\hat{\tau}_{\mathrm{LB}} \geq \tau_0$ ならば，すぐにアルゴリズムを終了させて予想順序 $(\boldsymbol{r}(1), \boldsymbol{r}(2), \ldots, \boldsymbol{r}(K))$ を出力する.
    If $l_f \geq 2$ then push $(f_1, \ldots, f_{l_f})$ at the end of Q.
    If $l_b \geq 2$ then push $(b_1, \ldots, b_{l_b})$ at the end of Q.
  end while
end for

3.3 IQS アルゴリズム

境界通過確率を利用したアルゴリズムである，IQS (Iterative Quick Sort）アルゴリズム（Algorithm 1) を提案する．IQS

*1 $[K]$ の置換である
*2 もしくは総和にしても等価である

は，大雑把に言うとフェーズごとに最大比較回数を増やしていく反復進化法とクイックソートを混ぜたアルゴリズムである．各フェーズごとにクイックソートが一度行われる．このクイックソートは幅優先探索（つまりキュー Q を利用）である．現在ソートしたい範囲の中央のアイテム r_p とそれ以外の要素との比較を行い，r_p より好まれるものを前に，r_p と比べ好まれないものを r_p より後にするということを再帰的に行う．IQS は境界通過確率に基づいた停止時刻を全フェーズで共有している：つまり，いったんペア (i,j) の比較回数が $\tau_{i,j}$ に達する（つまり，ペア間の順序が自信をもって確定される）と，以降のフェーズでもこの比較結果を活用し，無駄な追加比較はおこなわない．一方で，各フェーズ p で比較数の限界 $N_p := 4^p$ を設けており，停止時刻に達しない場合もこの回数までしか比較しない．停止時刻に達したペアのみ統計的有意性があるため，ピボット p より有意に好まれる要素数は l_{fin} 個，有意に好まれない要素数は r_{fin} 個であり，これらを利用し現在の順位相関係数の下界 $\hat{\tau}_{\mathrm{LB}}$ を構成する．$\hat{\tau}_{\mathrm{LB}}$ が所与の τ_0 に達したらアルゴリズムは現在の予想順序を出力し終了する．なぜこのようなフェーズごとのソートを行うのかというと，以下の理由がある：つまり，各ペアの比較がノイズを含むため，ペア間の比較を境界通過確率に基づいた停止時刻まで行わないとペアの統計的有意性を確保できない．一方，勝率が 0.5 に極めて近いペアを停止時刻まで評価してしまうと，そのペアの比較に大きな時間が食われてしまう．そのため，比較回数に上限を設けた幅優先でソートしやすそうな要素から比較し，そこから確定したペアで構成した順位相関係数の下界を持ち，勝率が 0.5 に近いペアの比較を確定させずに終わらせようというのが目的である．

以下，IQS の持つ理論的な性質を示す：これらの証明は省略する．まず最初に，IQS は順位相関係数に関する保証がある．

Theorem 2. IQS の順位相関係数に関する保証 *IQS (Algorithm 1)* は δ-τ-調和である．

次に気になるのは，IQS の比較回数と計算量である．簡単のため，以下の解析では線形効用モデルを仮定する．つまり，$\mu_{i,j} = 0.5 + O(|i-j|)$ とする．大雑把に言うと，順位が近いペアの勝率が 0.5 に線形に近づく．

Theorem 3. *(IQS の比較回数)* 任意の $\tau_0 < 1$ を考える．任意の δ-1-調和なアルゴリズム $\mathcal{A}$ の終了までの平均的な比較回数を $C_{\mathcal{A}}$ とする．*IQS (Algorithm 1)* アルゴリズムの終了までの比較回数を C_{IQS} とする．このとき，線形効用モデルを仮定すると，

$$\frac{C_{IQS}}{C_{\mathcal{A}}} \to 0$$

である．

つまり，完全にペアを並び替える任意のアルゴリズムに関して，「不完全な」比較アルゴリズムである IQS は，十分大きいアイテム数 K をソートすることを考えると，比較回数がいくらでも小さくなるというサンプル効率性がある．

次に，IQS の計算量について以下の定理を示す．

Theorem 4. *(IQS の計算量) IQS* の確定したペアのうち，最も比較回数が多かったものの比較数を N_c とする．*IQS (Algorithm 1)* は高々$O(K \log K N_c)$ 回の比較しか行わない．また，高々$O(K)$ 程度の空間計算量を持つ．

つまり，$O(K \log K)$ の計算量，$O(K)$ のメモリ消費量を持つ．これらの性質は，IQS が K が大きい場合にスケールするアルゴリズムであることを示している．

4. 実験

提案手法を他の順序付けアルゴリズムと比較するために，以下の実験を行った．提案手法である IQS アルゴリズムを，完全な順序を復元する MallowsMPR [BSW+14], PLPAC-AMPR [SBPH15], FPRU [FRPU94] と比較した．順位相関係数の τ_0 は 0.8, 信頼水準 $\delta = 0.05$ とした．

データセットとして，神嶌らによる 5,000 人規模の寿司の選好のデータセット [Kam03] から、代表的な 8 種の寿司ネタの間の選好 $\{\mu_{i,j}\}$ を作成した。各アルゴリズムの比較回数の一覧をテーブル 1に示す．提案手法は仮定を置かず順序を復元できるアルゴリズムである MallowsMPR と FPRU と比べ比較回数を 5 分の 1 以下に抑えることができた，同様の実験を将棋 AI などのデータセットでも行ったが、そちらでの結果は $K = 10$ 程度で IQS が MallowsMPR,FPRU に比べて 1 桁以上少ない比較回数で終了できることを示すものであった。

5. おわりに

要素間の順序付けを適応的に行う問題を扱った．完全な順序付けを行おうとすると，勝率が拮抗している場合に非常に大きな回数が必要になり，比較回数のほとんどをそれらのアイテムに使ってしまうことになる．実用的にはある程度不完全なソートができていれば良い場合も多い．これらの点を考慮し，所与の δ, τ に対し，確率 $1-\delta$ 以上で，順位相関係数を τ 以上にするアルゴリズムを提案した．完全なソートを行うアルゴリズムと比較し，比較回数を大きく減らすことができることを確かめた．

参考文献

[Arr63] Kenneth Joseph Arrow. *Social choice and individual values.* New York : Wiley, 2nd ed edition, 1963. Previous ed. (B51-9090), Chapman & Hall, 1951.

[BSH14] Róbert Busa-Fekete, Balázs Szörényi, and Eyke Hüllermeier. PAC rank elicitation through adaptive sampling of stochastic pairwise preferences. In *Proceedings of the Twenty-Eighth AAAI Conference on Artificial Intelligence, July 27 -31, 2014, Québec City, Québec, Canada.*, pages 1701–1707, 2014.

表 1: 各アルゴリズムの停止までに要した比較回数．100 回のシミュレーションの平均を取っている．PLPAC-AMPR は順序のみならず，勝率が Prakett-Luce モデルに従うという仮定を置いている．そのため，PLPAC-AMPR は一般の順序のみを仮定した選好に対して順序を復元できるという保証はなく、実際このデータセットでは正しい順序を復元できなかった。それ以外の各アルゴリズムは勝率の順序をケンドールの順位相関係数を 0.8 以上にするという意味で復元できた．

アルゴリズム	比較回数
MallowsMPR	1.2×10^6
PLPAC-AMPR	9.6×10^5
FPRU	8.4×10^6
IQS	2.1×10^5

[BSW+14] Róbert Busa-Fekete, Balázs Szörényi, Paul Weng, Weiwei Cheng, and Eyke Hüllermeier. Preference-based reinforcement learning: evolutionary direct policy search using a preference-based racing algorithm. *Machine Learning*, 97(3):327–351, 2014.

[CJRY12] Olivier Chapelle, Thorsten Joachims, Filip Radlinski, and Yisong Yue. Large-scale validation and analysis of interleaved search evaluation. *ACM Trans. Inf. Syst.*, 30(1):6:1–6:41, March 2012.

[CT06] Thomas M. Cover and Joy A. Thomas. *Elements of Information Theory 2nd Edition (Wiley Series in Telecommunications and Signal Processing)*. Wiley-Interscience, July 2006.

[FRPU94] Uriel Feige, Prabhakar Raghavan, David Peleg, and Eli Upfal. Computing with noisy information. *SIAM J. Comput.*, 23(5):1001–1018, 1994.

[JKPW17] Ramesh Johari, Pete Koomen, Leonid Pekelis, and David Walsh. Peeking at A/B tests: Why it matters, and what to do about it. In *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Halifax, NS, Canada, August 13 - 17, 2017*, pages 1517–1525, 2017.

[Kam03] Toshihiro Kamishima. Nantonac collaborative filtering: recommendation based on order responses. In *Proceedings of the Ninth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Washington, DC, USA, August 24 - 27, 2003*, pages 583–588, 2003.

[KHKN15] Junpei Komiyama, Junya Honda, Hisashi Kashima, and Hiroshi Nakagawa. Regret lower bound and optimal algorithm in dueling bandit problem. In *COLT*, pages 1141–1154, 2015.

[Mai17] Odalric-Ambrym Maillard. Boundary crossing for general exponential families. In *International Conference on Algorithmic Learning Theory, ALT 2017, 15-17 October 2017, Kyoto University, Kyoto, Japan*, pages 151–184, 2017.

[SBPH15] Balázs Szörényi, Róbert Busa-Fekete, Adil Paul, and Eyke Hüllermeier. Online rank elicitation for plackett-luce: A dueling bandits approach. In *Advances in Neural Information Processing Systems 28: Annual Conference on Neural Information Processing Systems 2015, December 7-12, 2015, Montreal, Quebec, Canada*, pages 604–612, 2015.

[Sie85] D. Siegmund. *Sequential Analysis: Tests and Confidence Intervals*. Springer Series in Statistics. Springer, 1985.

[YBKJ12] Yisong Yue, Josef Broder, Robert Kleinberg, and Thorsten Joachims. The k-armed dueling bandits problem. *J. Comput. Syst. Sci.*, 78(5):1538–1556, 2012.

[1Z3] [General Session] 2. Machine Learning

座長:石畠 正和（NTT）

Tue. Jun 5, 2018 5:20 PM - 7:00 PM Room Z (3F Matsu Take)

[1Z3-01] A Proposal of a loss function of GAN to generate various images

○Ryoji Kodama[1], Tsuyoshi Nakamura[1], Masayoshi Kanoh[2], Koji Yamada[3] （1. Nagoya Institute of Technology, 2. Chukyo University, 3. Institute of Advanced Media Arts and Sciences）

5:20 PM - 5:40 PM

[1Z3-02] Approximation of Value Function with Feature Representation Learning to Deal with Extendable Action Space

○Yu Kono[1], Ikki Tanaka[1], Jun Ernesto Okumura[1] （1. DeNA Co., Ltd.）

5:40 PM - 6:00 PM

[1Z3-03] Disentangled Representation Learning From Sequential Data

○Masanori Yamada[1], Heecheol Kim [3], Kosuke Miyoshi[3], Hroshi Yamakawa[2,3] （1. NTT Secure Platform Laboratories, 2. The Whole Brain Architecture Initiative, 3. Dwango Artificial Intelligence Laboratory）

6:00 PM - 6:20 PM

[1Z3-04] Autonomous optimal exploration through satisficing

Yu Kono[2], ○Tatsuji Takahashi[1] （1. Tokyo Denki University, 2. DeNA Co., Ltd.）

6:20 PM - 6:40 PM

[1Z3-05] Comparison of extraction of diffuse lung disease areas using CNN, FCN and U-Net

○Kanako Murakami[1], Noriaki Hashimoto[1], Shoji Kido[1], Yasushi Hirano[1], Shingo Mabu[1], Kenji Kondo[2,3], Jun Ozawa[2] （1. Graduate school of Sciences and Technology for Innovation, Yamaguchi University, 2. Advanced Industrial Science and Technology, 3. Panasonic Corporation）

6:40 PM - 7:00 PM

©The Japanese Society for Artificial Intelligence

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

GANにおける多様な画像生成のための損失関数の提案

A Proposal of a loss function of GAN to generate various images

児玉涼次 *1 Kodama Ryoji　中村剛士 *1 Tsuyoshi Nakamura　加納政芳 *2 Masayoshi Kanoh　山田晃嗣 *3 Koji Yamada

*1名古屋工業大学 Nagoya Institute of Technology　*2中京大学 Chukyo University　*3情報科学芸術大学院大学 Institute of Advanced Media Arts and Sciences

We propose a new loss function based on variance of generated images that we introduce to GAN(Generative Adversarial Networks). Recent image-generation methods adopt a neural-network based generative model. Auto-generators of illustrations can contribute to assist creative activities and entertainment. This paper focuses on supression of collapse and its benefit to GAN training. Using our new technique, we attempted to generate various images of illustrations.

1. はじめに

画像生成とは，コンピュータグラフィクス (CG) によって様々な画像の自動生成を行う技術である．特に，絵画やイラストなどの創作画像を生成する研究分野は，Non-Photorealistic Rendering(NPR) と呼ばれ，CG 研究において注目される分野である．画像生成という創作活動は，計算で表すことが容易でないが，Neural Network(NN) を用いた GAN の技術によって，その実現可能性が示されている [Goodfellow 14] ．GAN の発展形である Deep Convolutional GAN(DCGAN)[Radford 15] を用いた手法も存在する．

GAN の学習において collapse という現象 [Salimans 16] が確認されていて，パラメータに依らず類似した画像ばかりを生成する現象である．また文献 [Arora 17] では，GAN の生成データが学習データに比べて多様性に欠けると報告されている．これらの関連研究から示される課題は，GAN の学習過程において生成データの多様性が低下し得るということである．

そこで本研究は GAN にイラストを学習させ，生成画像における多様性を向上させることを目的として，分散を考慮した損失関数の導入を提案する．この提案により，コミックに描かれた絵柄を学習させた際にも，それに類似しつつ同一でない多様な絵柄の獲得が期待できる．

2. 損失関数に対する分散の導入

GAN における生成画像の多様性を向上させる為に，生成画像の分散に着目した手法を提案する．GAN によって生成される画像群が正規分布し，分散が生成データの多様性に関係していると仮定する．分散を大きくするため，生成画像の分散を GAN の損失関数に加えることを考える．

式 (1) では生成画像のリスト X を定義する．

$$X \stackrel{\text{def}}{=} [x_1, x_2, ..., x_n, ..., x_N] \tag{1}$$

生成画像の総数を N とし，そのうちの一つを x_n とする．x_n はカラー画像であるためサイズ $C \times H \times W$ の 3 階テンソルと捉え，C はカラーチャネル数，H と W は縦横の長さとする．N, C, H, W は 1 以上の整数とし，x_n の一画素を $x_{n_{c,h,w}}$ と表す．

連絡先: 児玉涼次，名古屋工業大学，kodama@ai.nitech.ac.jp

式 (2) では分散計算のために x_n のノルムを計算する．

$$\|x_n\| = \sqrt{\Sigma_{c,h,w}(x_{n_{c,h,w}})^2} \tag{2}$$

式 (3),(4) は生成画像における平均 μ_X と分散 Σ_X を示す．分散は平均とノルムの差 σ_n を定義し，その 2 乗和の平均として計算している．σ_n は後の正規化のために定義した．

$$\mu_X = \frac{1}{N}\sum_{n=1}^{N}\|x_n\|,\ \sigma_n \stackrel{\text{def}}{=} |\mu_X - \|x_n\|| \tag{3}$$

$$\Sigma_X = \frac{1}{N}\sum_{n=1}^{N}\sigma_n^2 \tag{4}$$

式 (5),(6) では分散の正規化を行う．まず σ_n を正規化した σ_n^{normal} を計算する．σ_{max}，σ_{min} は σ_n のうちそれぞれ最大，最小のものである．次に正規化した分散 Σ_X^{normal} を計算する．

$$\sigma_n^{normal} = \frac{\sigma_n - \sigma_{min}}{\sigma_{max} - \sigma_{min}} \tag{5}$$

$$\Sigma_X^{normal} = \frac{1}{N}\sum_{n=1}^{N}(\sigma_n^{normal})^2 \tag{6}$$

実際の学習においては，$\alpha(1 - \Sigma_X^{normal})$ を判別器の損失関数に加えた式 (式 (7)) とする．m はミニバッチサイズ，d はデータのミニバッチ，z はノイズのミニバッチである．D, G はそれぞれ判別器，生成器を表す．

$$L_{disc} = -\frac{1}{m}\sum_{i=0}^{m}\Big[\log D\Big(d^{(i)}\Big) + \log\Big(1 - D\Big(G\Big(z^{(i)}\Big)\Big)\Big)\Big] + \alpha(1 - \Sigma_X^{normal}) \tag{7}$$

3. 実験

我々は提案手法を導入した DCGAN にイラストを学習させ，分散の変化を観察した．実験では生成モデルとして DCGAN を利用し，NVIDIA GeForce GTX 980Ti を積んだ計算機で学習を行った．

学習データとして検索エンジン *1 から集めたイラストデータを使用する．3 人のイラスト作家を定めてイラストを収集し，学習を簡単にするための前処理として右目領域を切り抜いた．

*1　https://safebooru.org/

それを $3 \times 96 \times 96$ のサイズに変形し，三つのデータセットを構築した (表 1)．学習の際には 9 割を訓練データとし，1 割をテストデータとして使用する．データの順序はそれぞれの学習ごとにランダムである．

表 1: イラストデータセット

データ名	枚数 [枚]	前処理後 [枚]	学習時間 [h]
kantoku	1492	1427	34
muririn	360	297	8
tsunako	1146	811	20

パラメータ α に関して分散の値などを観察する．$\alpha = 0.0$, 0.1, 1.0, 10.0 の 4 パターンを設定し，訓練データを用いて DCGAN を 10000epoch 学習させた．α のパターン違いによる学習時間の変化はほとんど見られなかった．

4. 結果

提案手法による学習結果を観察し，パラメータ α に関して比較を行う．図 1 は学習過程での分散の推移を表しており，三つのグラフはデータセットそれぞれの結果を示す．グラフでは横軸が epoch，縦軸が分散の値で，すなわち学習進度に対する分散の変化を表している．実線は全 10000 点のうち 1000 点毎の平均の 10 点を結んだもので，破線は全体平均である．色の違いはパラメータ α の違いを表す．図 2 には生成画像からランダムに抽出したサンプルを示す．

kantoku データではパラメータを変化しても，結果はほぼ同じである．1000 点平均では $\alpha = 1.0$ の場合に分散の上昇が早く発生しているが，全体平均を見るとほぼ同じ分散値を取っていることがわかる．このデータの傾向として学習終盤に分散が上昇するという特徴が見られる．

muririn データではパラメータによる変化が見られる結果となった．1000 点平均では $\alpha = 1.0$ の場合に最大値を取り，全体平均でも最大となっている．このデータでは学習が進むほど分散が小さくなっていることがわかる．

tsunako データでもパラメータによる変化が見られる．1000 点平均では最大値の点は取らないものの，$\alpha = 1.0$ の場合に分散の値が落ち込みにくくなっていることがわかる．結果として全体平均では最大値となっている．このデータでも学習が進むにつれて分散が小さくなるが，$\alpha = 1.0$ では終盤において僅かに上昇していると確認できる．

今回のデータセットについては，分散を導入した損失関数によって，collapse を回避し多様な画像を生成することができた．また，$\alpha = 1.0$ の場合が各データセットに共通して分散上昇に有効だと思われる．

5. まとめ

我々は GAN に対して分散を考慮した損失関数を提案し，イラストデータ学習において多様性を向上させる可能性があることを確認した．GAN における collapse という課題を解決するために，生成画像の分散を組み込んだ学習を行った．分散の値の確認によって，提案手法の中でも最適なパラメータが存在する可能性がある．最適なパラメータがわかれば，それによって分散を上昇させ，多様性を持った生成画像を得られるのではないかと期待される．

課題として，分散計算の適切さと実験回数の不十分さが考えられる．今回の手法では生成画像のノルムとして単純な和を使用したが，これは分散を適切に計測できているのか，という懸念がある．また今回の実験回数は，提案手法の影響を分析するには不十分であると考えられる．

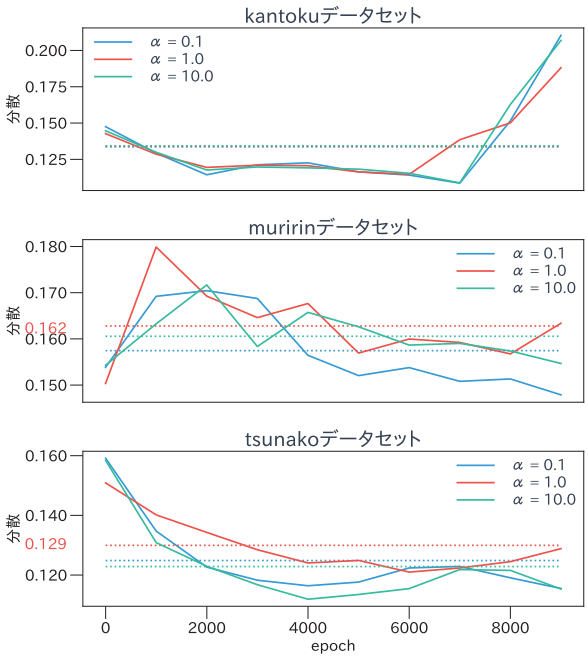
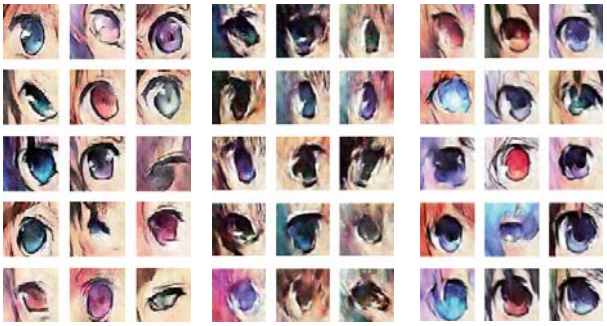


図 1: 分散の推移



kantoku データ　muririn データ　tsunako データ

図 2: 生成画像例 (6000epoch，$\alpha = 1.0$)

参考文献

[Goodfellow 14] Ian J. Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron C. Courville, Yoshua Bengio. Generative Adversarial Networks. Advances in Neural Information Processing Systems 27 (NIPS 2014), pp.2672–2680. 2014.

[Radford 15] Alec Radford, Luke Metz, Soumith Chintala. Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. ICLR 2016.

[Salimans 16] Tim Salimans, Ian Goodfellow, Wojciech Zaremba, Vicki Cheung, Alec Radford, Xi Chen. Improved Techniques for Training GANs. 2016.

[Arora 17] Sanjeev Arora, Yi Zhang. Do GANs actually learn the distribution? An empirical study. 2017.

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

拡張されうる行動空間での特徴の表現学習を伴う価値関数の近似 ～“逆転オセロニア” を例に～

Approximation of Value Function with Feature Representation Learning to Deal with Extendable Action Space: Taking “Gyakuten Othellonia” as an Example

甲野 佑 [*1] 田中 一樹 [*1] 奥村 エルネスト 純 [*1]
Yu Kono Ikki Tanaka Jun Ernesto Okumura

[*1]株式会社 ディー・エヌ・エー
DeNA Co., Ltd.

In a general decision-making task, the options of action are expanded indefinitely due to the change of environment or the discovery of new action by agent. In a situation that the number of options increase, it is necessary for an agent to acquire an abstracted expression of actions autonomously. Here we propose a learning framework that solve this issue. In the proposed method, value function is approximated with embedded behavioral representations, which generalize the expression of actions, using state-tradition trajectories. We confirmed the efficiency of the framework using the mobile game “Gyakuten Othellonia”. This game is a mixture of board game and trading card game and characters are added to the environment frequently, which is a good testbed to realize expandable action space. Finally, we show that, with the proposed framework, an agent can learn character’s representation and utilize it to learn optimal strategies in the game.

1. はじめに

近年, 非常に取りうる状態数が多く, 様々な戦略を相手取る囲碁などの対戦ゲームにおいて木探索, 深層学習, 強化学習の知見の融合により人間のプロプレーヤーに勝る行動選択が可能になった [Silver, 2017]. このようなゲーム課題は運動制御における各関節の調整などの低次の行動を扱った学習と異なり, 行動の選択肢が記号化されている前提での高次の意思決定を扱っている. 既存の深層学習, 強化学習における行動の学習手法の多くは, 人工ニューラルネットワーク (NN) 等による関数近似が用いられるが, 出力はあらかじめ固定の行動選択肢数で学習される. しかし現実の離散的な高次の行動選択肢の量と質は, ある種のプランニングや経験によって新たに発見・変更されるものであり, 前述した形式では無際限に増加・変更されゆくケースに対応できない. そもそも潜在的な行動種類数が膨大である場合も出力が肥大化して学習が困難になる. クラスタリングにより膨大な数の行動を抽象化する手法は存在するが, 行動そのものに特徴が付加されていなければ対処できない.

そこで本研究では, 行動選択肢を状態遷移軌跡から任意の表現をベクトルに埋め込む表現学習手法を提案する. 本提案手法で前述した膨大かつ拡張されうる行動選択肢数が表現ベクトルとして有限長の連続値に変換されることで, 評価関数の関数近似器の入力として扱えるようになり, クラスタリング無しで行動数の膨大さと無際限な拡張に対処できるようになる. しかし行動選択肢の発見等は本来, 行動学習 (例えば強化学習) 以外のシステムによって提供されるため, ATARI など従来課題との対応付けが難しい. そこで本研究は “逆転オセロニア” という行動選択肢となるキャラクター (コマ) 種類数が増大することを前提とした, カードゲームとボードゲームの要素を組み合わせた課題において, 提案手法の有効性を示す.

2. 拡張意思決定課題の想定

“逆転オセロニア” は株式会社ディー・エヌ・エーがサービスを提供するオンラインゲームである. オセロと同様の法則下で設置可能なマスが決まる 6×6 の盤面にそれぞれ効果の異なるコマを交互に置いて, コマの設置効果により発生するダメージで相手の体力を早くゼロにした方が勝利するというのが “逆転オセロニア” の基本ルールになる. プレイヤーは自身が保有するコマの中から 16 種の組み合わせによってデッキと呼ばれるコマの集合を作成し, ゲームを開始する. ゲーム開始時に両ユーザーには, 16 コマの中から “リーダー” と呼ばれる属性に予め選んでおいた 1 コマと, 残り 15 コマからランダムに選ばれた 3 コマの計 4 コマが与えられ, その後もコマを設置したら自身のターン開始時に新たなコマが 1 つデッキから与えられる. コマの種類は 1,000 キャラ以上存在し, 度々新たにリリースされる. ルールの詳細は参考サイト [Othellonia 16][Othellonia wiki] を参照のこと. ゲーム課題としては以下の特徴を有する.

1. 2 人零和不完全情報ゲーム (本研究では課題の簡略化のため完全情報に変更)
2. ターン制かつ 1 ターンにつき 1 回の行動選択
3. 可能な行動の集合が現在の手札, 場のコマ配置で決定
4. 潜在的な行動選択肢数はコマ種類数 × マス数 (6×6) であり, コマ種類数の増加によって増えていく可能性がある
5. コマが盤面に留まるため, 全てのコマを離散的に定義すると, 行動種類数 (コマ種) の増加に対して指数的に状態空間も拡張される
6. 手札としてのコマの出現順番が確率的かつ予測不能であるため, 木探索が有効ではない

本研究ではある時点の状態で可能な行動集合は “逆転オセロニア” のゲームルールを提供するシミュレータ (環境) から付与されるとし, 問題の範囲を制限させている. “逆転オセロニア” 自体の複雑性の影響は大きいものの, 本研究は飽くまで潜在的な行動種類数が膨大かつ増大しうる前提での非常に複雑な行動選択への対処を目的としている.

3. 行動種類数が可変な行動評価値の近似

本研究においてエージェントは現在実行可能な行動集合の中から, 学習により付加した各々の行動評価値を参照して行動選択する. そしてある行動選択肢の評価値は関数近似器による近似を前提とする. 関数近似器は状態特徴 s, 行動特徴 a

連絡先: 甲野 佑, 株式会社ディー・エヌ・エー, 150–8510, 東京都渋谷区渋谷 2–11–1 渋谷ヒカリエ, yu.kono@dena.com

を入力とし，スカラー値である評価 $f(s,a;\theta)$ を出力とする．それらの関数近似は近似対象である行動の評価関数 y の変更により，y の予測器 f のパラメータ θ の学習方法は，教師あり学習 (Supervised Learning, SL)，強化学習 (Reinforcement Learning, RL) の双方に対応できる．本研究では行動評価値の関数近似器 $f(s,a;\theta)$ に任意の多層 NN を用いる．

3.1 ユーザーログに対する教師あり学習

“逆転オセロニア” は対戦ログを用いて，実際にユーザーがどの局面 (状態 s) で手札中のどのコマを，設置可能なマス中のどの座標に設置したか意味する行動 a の選択について，ユーザーログを用いた教師あり学習ができる．しかし潜在的な行動種類数が膨大かつ，新コマのリリースで増大する可能性があり (ゲームの性質上，伴って状態空間も指数的に拡張される)，離散的に定義された全行動種類 A_{all} ($|A_{\mathrm{all}}|$ = コマ種類数 × マス数) に対する行動選択確率 $P_{\mathrm{all}}(a \in A_{\mathrm{all}}|s)$ は計算不可能である．

そこで本研究では，ある状態において選択可能な任意の行動が選ばれた (put) か否か $(\mathrm{not\ put})$ の可能性 $P_{\mathrm{put}}(y \in \{\mathrm{put},\ \mathrm{not\ put}\}|a,s)$ をユーザーの主観的な行動評価値として学習する．これは入力である状態特徴 s，行動特徴 a が実際にユーザーログ上で選ばれたか否かの 2 値分類タスクになるため，近似関数の出力 $y^{\mathrm{pred}} = f_{\mathrm{put}}(s,a;\theta)$ を棋譜上の教師信号 y^{user} に対する cross–entropy 損失関数で学習可能になる．また 2 値分類であるため，手札中の選択されなかったコマ，設置可能だが選択されなかったマスも学習データに用いる．

3.2 ゲームシミュレータに対する強化学習

本研究では “逆転オセロニア” のゲームシミュレータを用いて行動選択の強化学習も行った．近似関数器 $f(s,a;\theta)$ の近似対象として報酬 r_t の累積値である収益の予測値である行動価値関数 $Q(s,a)$ を学習する．行動価値関数の近似関数 $f_{\mathrm{Q}}(s,a;\theta)$ は Double Q–Learning [VanHasselt 15] を用いた TD 学習の更新則に従い，ある時刻 t に対する当該の状態行動対 (s_t,a_t) については以下の損失関数 (2) を最小化するよう Prioritized Experience Replay (PER)[Schaul 15] を用いて学習した．

$$a_{\mathrm{back}} \leftarrow \underset{a_i \in A_{t+1}}{\arg\max}\, f_{\mathrm{Q}}(s_{t+1},a_i;\theta) \tag{1}$$

$$\mathcal{L}_{\mathrm{Q}} \leftarrow \left(r_{t+1} + \gamma f_{\mathrm{Q}}(s_{t+1},a_{\mathrm{back}};\theta^-) - f_{\mathrm{Q}}(s_t,a_t;\theta)\right)^2 \tag{2}$$

ここで A_t, $r_t = \{0,1\}$ はそれぞれ時刻 t で実行可能な行動集合と得られた報酬を意味し，本課題で報酬はゲームの勝敗が決した時のみ与えられる (勝利時に $r_t = 1$, 敗北時に $r_t = 0$)．またターゲットパラメータ θ^- はそれ以前の近似関数 f_{Q} のパラメータ θ であり，一定間隔の間 θ^- を固定することで関数の更新を安定させる Target–net という手法である．DQN [Mnih 15] などの手法と異なり，近似関数 $f_{\mathrm{Q}}(s_t,a_t;\theta)$ の出力は常に一つのスカラー値であることに留意されたい．

3.3 行動特徴

本研究で近似関数 $f(s,a;\theta)$ に入力される行動特徴を定義する．多くのラジオゲームにおける行動は離散的に定義されたコントローラのスイッチ種類数に対応する on/off のバイナリベクトルで定義できる．“逆転オセロニア” 等のカードゲーム要素を持つ場合は潜在的に存在して選択されうるコマ (カード，コマンド) が離散的に定義された行動に該当し，コマ種類数の長さを有する one-hot ベクトルで行動特徴が定義される．“逆転オセロニア” の場合，盤面空間 6×6 の one-hot 行列，コマ毎が当該の座標に置くことで効果 (スキル・コンボ，詳細は参考サイト [Othellonia 16][Othellonia wiki] を参照のこと) が発動するかどうかの 2 値フラグ，そのコマの元々の攻撃力なども行動特徴に該当する．盤面座標，効果フラグや攻撃力は拡張される概念ではなく，それ自体が相対的な特徴量であるため，後述する表現学習の対象や表現ベクトルへの置換対象は，この中で非相対的な情報であるコマ種ベクトルに限る．

3.4 実ゲームにおける行動選択の方法

ゲームのプレイ時の行動はある時点での状態 s_t において実行可能な行動集合 A_t の要素を全て評価し，その中で最も評価値の高い行動選択肢 $(\arg\max_{a_i \in A_t} f(s_t,a_i;\theta))$ が選ばれる．それ以外にも行動選択には強化学習時の探索や，評価時に行動バリエーションのため $f(s,a;\theta)$ に基づく softmx 関数や，ϵ-greedy 手法などで確率性を与える場合もある．

4. 部分遷移要因の表現学習

本研究では自然言語処理技術を参考に，近似関数 $f(s,a;\theta)$ の入力であり，拡張されうる行動特徴 a を固定長の実数値ベクトルとして暗黙的に学習する手法を提案する．具体的には話者特徴を表現ベクトルとして埋め込むペルソナモデル [Le 16] を元に，状態行動対中の離散的な行動要素等，ある部分集合へ状態遷移の要因を表現ベクトルとして埋め込む形式に考案した．

4.1 学習方法

ある時点での状態 s_t とその次状態 s_{t+1} が与えられたとき，その状態遷移軌跡が状態行動対特徴 $X_t = (s_t,a_t)$ 中の任意の部分集合 x_t^{tar} とそれ以外の要素 x_t^- に引き起こされたと仮定する．この任意の要素 x_t^{tar} を本研究では部分遷移要因と呼ぶ．そして状態行動対 X_t から部分遷移要因 x_t^{tar} をマスクされた入力信号 X_t^- を定義する．議論の簡略化のため部分遷移要因をその時点での行動 $(x_t^{\mathrm{tar}} = a_t)$ だとした場合，いずれの要素であるか特定不明という意味の値 x^{u} でマスク $(a_t \leftarrow x^{\mathrm{u}})$ された入力信号は $X_t^- = (s_t, x^{\mathrm{u}})$ と表すことができる．このマスクされた入力信号 X_t^- を用いて次状態 s_{t+1} の予測を任意の予測器 f_{rep} で学習すると，部分遷移要因 x_t^{tar} に引き起こされる状態遷移の成分が行き場を失う．

そこで入力としてマスクされた入力信号 X_t^- の他に x_t^{tar} に対応するランダムに初期化されたユニークな特徴変数ベクトル c_t^{tar} を与えて，次状態 s_{t+1} の予測学習を行わせる．これを多くの状態行動対 X に対して行うことで同様，あるいは類似した幾つかのマスクされた入力 X_t^- に，それぞれ異なる結果 s_{t+1} が起きたとき，その差異の要因となる成分が特徴ベクトル c_t^{tar} に吸収されて，部分遷移要因 x_t^{tar} の状態遷移に寄与する表現が暗黙的に学習されていく．部分遷移要因が行動要素である場合は行動 a_t の入力表現 $a_t^{\mathrm{rep}} = c_t^{\mathrm{tar}}$ あるいはその要素の一部に関する表現ベクトルとして行動の学習に再利用される．

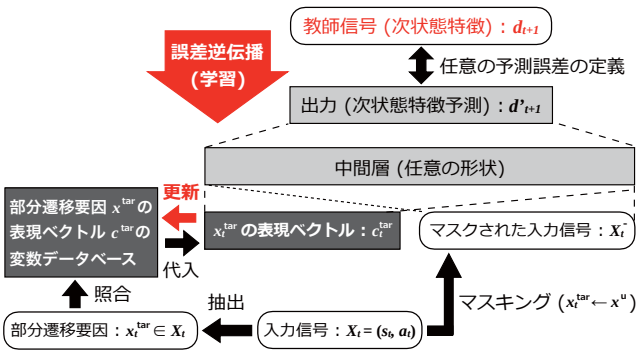


図 1: 部分遷移要因の表現学習アーキテクチャ

学習に用いる状態行動対 X_t と次状態 s_{t+1} の状態遷移軌跡は環境モデル上でありえる遷移であれば良い. しかし良い行動の評価関数を作るため, 実用上は一定のリテラシーを持ったエージェント, あるいはユーザーログから得た状態遷移軌跡が望ましいと考えられる.

4.2 次状態の代替えと損失関数

現実的には s_{t+1} の直接的な予測は困難である. 特に “逆転オセロニア” は行動特徴が手札や盤面上の情報として状態特徴にも現れるため, 長大で延長を前提としたコマ種の one-hot ベクトルを含む s_{t+1} の推定は不可能である. そこで十分に次状態 s_{t+1} の代替えとなりうる, 状態要素の部分集合や, 行動 a_t を実行した後に発生する観測可能な事象を教師信号とすることも想定する. 次状態信号そのもの, その代替信号も含めて本表現学習手法の教師信号を次状態特徴 d_{t+1} と呼ぶ. この次状態特徴とその損失関数の設計は次状態の予測の困難さや観測しうる特徴量等に依存するため, 損失関数であれば連続量は正規化して回帰, 排中律を有する離散事象の集合部のみ cross–entropy にするなど, ゲームドメイン毎に行う必要がある. しかしラジオゲーム (画像・動画から) の行動選択の学習に本手法を用いる場合, 次状態である画面の各ピクセルごとの各要素の発生確率の予測誤差を最小化するように学習することが想定される. 以上に記した表現学習器の基本的な構造は図 1 に示す.

4.3 利点

以下は表現ベクトルの事前学習による利点の推定である.

1. 種類数が潜在的に膨大, あるいは増大しうる行動要素表現の削減と固定長化
2. 利点 1 に伴うユニット数の節約と学習時間の削減
3. 表現空間上での類似行動の汎化による学習の効率化
4. 利点 3 に伴ってあまり選択されていない類似行動コマの使い方を習得可能
5. 行動の使い方のような概念＝表現ベクトルを事前学習できるため, 行動評価の関数近似時のハイパーパラメータ等の試行錯誤が比較的容易になる

根本的に扱えなかった行動概念に対処できる利点 1 が本研究の最大の効果である. 利点 2, 4 は仮説であり, 困難ではあるが実験により幾分か定量化できる. しかし利点 5 は実運用上の恩恵であり, 定量化はできない. 前述した通り, “逆転オセロニア” はコマの増加により状態空間が指数的に広がるため, 利点 2 の効果が大きいと思われる. また様々なコマを学習する都合上, 利点 4 は有益な性質であるが本研究では検証していない.

5. 実験

本研究では利点 2 の仮説について, それぞれ表現学習と教師あり学習, 強化学習による行動評価値の学習とを組み合わせた際の実験により定量評価を試みた.

5.1 逆転オセロニアでの行動学習の共有設定

後述する実験 1, 2 ともに行動特徴の中の “膨大かつ拡張されうる離散的要素” であるコマ特徴の表現ベクトルは共通のものを用いた. その表現学習には 2017 年 1 月に使用できた 916 コマ種 (+ キャラクタの付加されていない無地ゴマ 1 種) を対象に, ユーザーランク 76〜200 同士の対人戦データから得られる状態遷移軌跡を用いた. また実験 1 の教師あり学習, 実験 2 の強化学習には同様の中間層の構造を用いる. 各種学習器の構造やハイパーパラメータは表 1 を参照のこと.

表 1: 各種パラメータ

パラメータ名	表現学習	行動学習
学習率	1.0×10^{-3}	1.0×10^{-5}(SL, RL)
minibatch size	2^{10}	2^{10}(SL), 2^5(RL)
Dropout 率	0.0	0.0(SL), 0.0(RL)
L_2 正則化係数	1.0×10^{-8}	1.0×10^{-8}(SL), 0.0(RL)
入力 Unit 数	55663	実験毎に変わる
中間 Unit 数	(2^{12}, 2^{11}, 2^{10})	
出力 Unit 数	63	1
活性化関数	ELU (出力層以外)	
Optimizer	Adam	
表現ベクトル	キャラ数 : $916 + 1 \rightarrow$ ベクトル長 : 30	

5.1.1 入力特徴

各学習器の入力特徴は状態 s_t としてターン数や選択側の色 (白・黒), 自分・相手の残り体力, 手札, デッキ, 盤面などを, 行動 a_t には任意の選択可能なコマや設置可能なマス座標, スキルやコンボ等の特殊効果の発動の可否を用いた. 表現ベクトルを使用しない場合は one-hot ベクトルを手札, デッキ, 盤面のコマの表現として用い, コマの表現ベクトルを使用する場合は, その全てを上述したベクトル長 30 の表現ベクトルに置き換えた. そのため両実験とも比較対象である表現ベクトルを使うか否かで第一層のみ入力数とパラメータの数が異なる. ターン数を対数にした値など入力の特徴量エンジニアリングも行われているが, 入力特徴や表現学習時の教師信号, 損失関数は実サービスのゲームを用いている都合上, 詳細な言及は避ける.

5.1.2 勝率の定義

“逆転オセロニア” では非対人対戦イベント (クエスト等) や通信が切れた際の代打ちとして, ルールベース AI が実装されており, 強さが固定であることから本研究の勝率の定義にはルールベース AI との戦績を用いた. 実験 2 では勝率のベースラインとして学習エージェントと同デッキでの, ランダムな意思決定でルールベースと戦った場合, ルールベース同士で戦った場合の勝率を示す. 勝率は, 各試合で各々異なるシードでデッキのシャッフルと先攻後攻の決定した 1,000 試合中何勝したかで評価し, 試合時には学習された行動評価の近似関数の出力に対して greedy な行動選択が行われる.

5.2 実験 1: 教師あり学習と表現ベクトル

実験 1 では利点 2, 表現ベクトルを用いた場合とそうでない場合での学習効率の程度を示す. ここでいう効率とは計算時間に対する勝率の向上速度や, 最終的な到達勝率の高さを意味する. 勝率は様々なデッキの組み合わせによって測るべきだが, 現実的にあらゆるデッキの組み合わせで評価するのは困難であるため, ここでは代表として 2017 年 1 月の時点でよく使われていたデッキバリエーションである 4 種を用いた. 限定されたコマ種類数での勝率評価であるため, 表現ベクトルの有無で大きな差が現れないことが予想される. そのため学習回数に対する勝率以外に, 同条件で学習に掛かった経過時間を提示する.

5.2.1 実験設定

学習には 2017 年 1 月に集計されたユーザーランクが 76〜200 同士の対戦ログを使用した. 勝率評価に 4 種の内訳はデッキ内のコマの属性を, 竜 (攻撃力が高い), 神 (耐久値が高い), 魔 (トリッキーな戦術) で構成した 3 種とそのバランス的な組み合わせを用いた. 学習と評価に使用したデッキの構築はアソシエーション分析と階層的クラスタリング手法の一種であるウォード法と k–means 法を組み合わせたクラスタリングに

表 2: 表現ベクトル ＋ 教師あり学習の勝率推移と経過時間

	表現ベクトルあり		表現ベクトルなし	
Step 数	勝率 (%)	時間 (min)	勝率 (%)	時間 (min)
1×10	23.72	1	11.60	1
1×10^2	42.59	26	59.85	27
1×10^3	77.16	47	77.60	73
1×10^4	82.97	92	82.27	264
1×10^5	85.23	406	85.28	1,947
2×10^5	85.56	746	85.64	3,808
3×10^5	85.06	1,103	85.96	6,623
4×10^5	85.24	1,444	86.32	8,426
5×10^5	85.78	1,839	86.20	10,242

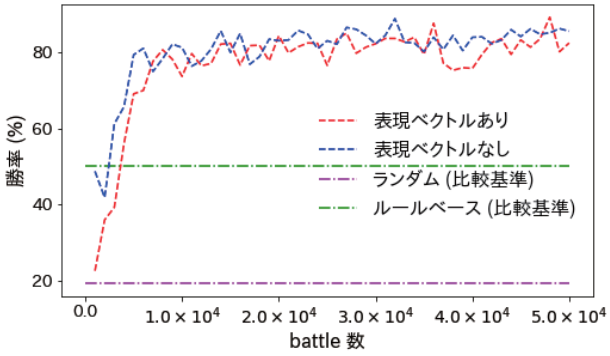


図 2: 表現ベクトル ＋ 強化学習モデルの勝率推移

より抽出した頻出するコマの組み合わせから, 任意の組み合わせによるデッキを自動生成した. 行動学習ネットワークの表現ベクトルを使用する場合の入力サイズは 5,649 になった. それに対して表現ベクトルを使用しない場合, 2017 年 1 月時点で使用されたコマ種類数 (916 種 ＋ 無地コマ 1 種) を直接扱えなければならないため 74,570 にもなり, 表現ベクトルを使用した場合の約 13 倍となった.

5.2.2 結果及び考察

表 2 に各 step （minibatch で学習した回数） での勝率と, 同条件の GPU で学習させた場合の経過時間を示す. 毎 step の勝率はほぼ等しいが, 50 万 step 時の経過時間が約 5.6 倍になった. これは 916 のコマ種類数を想定したものであり, 現在はさらにコマ種類数が増加しており, 学習コストはコマの増加に伴い更に大きくなる. 本研究では生成されたメジャーなデッキ構成を用いたため, マイナーなコマの学習などに影響を評価できていないものの, コマ表現ベクトルが計算的な時間削減に寄与し, 成績に影響を及ぼさない示唆が得られた.

5.3 実験 2: 強化学習と表現ベクトル

強化学習でも表現ベクトルの使用に対して成績に変化が表れるか実験を行なった. 教師あり学習と異なり, 自・敵デッキは単一デッキに固定して強化学習を行なった.

5.3.1 実験設定

デッキ構成は実験 1 と同じ手法で自動生成した. 対戦相手には初期 1,000 対戦はランダムで, その後 1,000 対戦毎に保存される過去の近似関数を対戦毎にランダムに読み込み, 対戦相手の行動選択に用いた. アーキテクチャには表現ベクトルのあり, なしをぞれぞれ学習し, 勝率を比較した. 実験 1 の教師あり学習と同じく, 916 コマ種 ＋ 無地駒 1 種について事前に学習したベクトル長 30 であるため表現ベクトルを使用する場合の近似関数の入力サイズは 5,649 になった. 対して表現ベクトルを使用しない場合, コマ 16 種 ＋ 無地駒 1 種で計 18 の長さの one-hot ベクトルを使い, 入力サイズは (16 種しか使用しないゆえに) 3964 になった . 学習は PER により抽出された minibatch を 1 学習として 2 対戦ごとに 32 回学習を繰り返し行った. この時に損失関数に用いる割引率 $\gamma = 1.0$ で Replay Buffer のサイズは 1 回の状態行動対を一つの単位として 2,000,000 とし, Target-net は 4,000 回の学習ごとに同期した.

5.3.2 結果及び考察

図 2 に battle 数に対する勝率の推移を示す. 毎 battle の勝率はほぼ等しく, 強化学習でも表現ベクトルの使用により, 成績に悪影響を及ぼさない示唆が得られた. ただし現時点では単一のデッキに対する結果でしかなく, 今後の大規模で多種なデッキに対する検証を必要とする.

6. 結論

コレクションカードゲームなど, 離散化された潜在的な行動選択肢がトランプの枚数とは比較にならない種類数で存在する意思決定課題に対処するためには, 行動概念の汎化が重要になる. 本研究では提案手法により事前に獲得した表現ベクトルを用いる事でクラスタリングなしで拡張されうる膨大な行動を扱える事を示した. 表現ベクトルを使用する際の他の利点に関する検証, 定量化や, 提案アーキテクチャ構造を前提とした学習の効率化は必要であるが, 本研究により複雑なゲームへの機械学習, 強化学習の応用範囲を広めることができたと言える. 今後, 過去の経験や知識に基づく低次の行動から高次行動の発見と汎化が前提となることが予想される. その場合, 本研究のように拡張されうる行動空間を扱えることが重要になると考えられる.

参考文献

[Othellonia 16] 株式会社ディー・エヌ・エー: 逆転オセロニア. https://www.othellonia.com/

[Othellonia wiki] 株式会社ディー・エヌ・エー: 逆転オセロニア最速攻略 wiki. https://オセロニア攻略.gamematome.jp/

[Mnih 15] Mnih, V., Kavukcuoglu, K., Silver, D., Hassabis, D., et al.: Human-level control through deep reinforcement learning. Nature, 518(7540), p.529-533. (2015).

[VanHasselt 15] Van Hasselt, H., Guez, A. and Silver, D.: Deep reinforcement learning with double q-learning. arXiv preprint arXiv:1509.06461. (2015).

[Schaul 15] Schaul, T., Quan, J., Antonoglou, I. and Silver, D.: Prioritized experience replay. arXiv preprint arXiv:1511.05952. (2015).

[Silver, 2017] Silver, D., Hassabis, D., et al.: Mastering the game of go without human knowledge. Nature 550(7676), pp.354–359. (2017).

[Le 16] Li, J., Galley, M. Brockett, C., Gao,J. and Dolan. B.: A persona-based neural conversation model. ACL2016. (2016).

[濱田 17] 濱田 晃一, 藤川 和樹, 小林 颯介, 菊池 悠太, 海野 裕也, 土田 正明: 対話返答生成における個性の追加反映, 研究報告自然言語処理（NL）, 2017-NL-232(12), p.1–7, 2188-8779 (2017)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

時系列データに対するDisentangleされた表現学習

Disentangled Representation Learning From Sequential Data

Kim Heecheol*1　山田 真徳 *2 Masanori Yamada　三好 康祐 *3 Kosuke Miyoshi　山川宏 *4 Hiroshi Yamakawa

*1*3*4ドワンゴ人工知能研究所 Dwango Artificial Intelligence Laboratory　*2NTT セキュアプラットフォーム研究所 NTT Secure Platform Laboratories

*4全脳アーキテクチャ・イニシアティブ The Whole Brain Architecture Initiative

We present a time convolutional variational ladder autoencoder (TCVLAE), which learns disentangled and interpretable representations from sequential data without supervision. For the simple 2d data set, the proposed model experimentally shows that it is possible to separate the meaning of time series data.

1. Introduction

強化学習は reward の情報を用いて $p(a|s)$ の最適化を行う. このとき state のパターンと action のパターンが多い場合は学習を困難にすることが知られている. state のパターンが多い代表的な例は画像である. 強化学習に画像データをそのまま state として利用すると良い性能を得られないが, 深層強化学習 (Convolutional Neural netowrk など) を用いて低次元化した state を利用することで深層強化学習はいくつかのタスクで成功を収めている [Mnih 15]. action のパターンが多い例はロボットの関節制御である. 複数の関節を同時に制御するような場合は各関節の制御の組み合わせとなるので全体として action は高次元になる. また時間方向に複数回 action を選択した後に報酬が手に入るようなスパースな報酬も擬似的に action のパターンが多い場合だとみなすことができる. 結果 1 つの action の自由度を N, 1 時刻に同時に選択する action 数を k, 報酬までの時間を t とすると, action のパターンは $\left(N^k\right)^t$ となり指数的に増加する. このように action のパターンが多いときに効率よく学習できないこと強化学習の大きな課題である.

Action のパターンの爆発を抑える先行研究としては, 毎時間 action の選択をせずに時間方向に action をまとめるモデル [Sharma 17, Durugkar 16, Vezhnevets 16] がある. 系列方向に action をまとめることで系列方向の無駄な action の選択の機会を減らし action のパターンを削減している. 一方で我々は近年目覚ましい発展を遂げている深層学習を用いた生成モデルを用いることで系列方向に抽象化するのではなく, action を低次元表現にまとめることで action のパターンの増加を防ぐことができると考えている 図 1:左下. これは人間がコップを持ち上げる場合を考えた時, 人間はコップを持ち上げるという抽象的な action を選択しているのであって各関節の動きを意識して動かしているわけではない, この抽象的な動作を潜在変数モデルの学習から獲得しようという戦略である.

深層学習を用いた生成モデルの代表的なものとして Variational autoencoder(VAE)[Kingma 14] と Generative adversarial network[Goodfellow 14] が存在する. 入力データ x, 潜在変数を z だとするとどちらも $p(x) = \int p(x|z)\,p(z)\,dz$ からサンプリングを出力する生成モデルである. 通常 VAE や GAN で学習した場合は, x の空間での意味を複数の z で表現する. 一方で $\beta-$VAE[Higgins 14, Higgins 17] や InfoGan[Chen 16] は x 空間の意味を 1 つの z で表現する学習 (Disentangle な表現学習と呼ぶ) である. Disentangle な表現学習の利点としては潜在変数 z が解釈可能であるという点と, 学習データに含まれていないデータに対して確率密度を比較的性能よく推定できるという点である. 強化学習では action の全てのパターンのサンプルを尽くすことができないので, 本研究では 解釈可能で学習データに入っていないデータに対しても柔軟に学習できる $\beta-$VAE を使い action の Disentangle な表現の獲得を目指す. action の意味は各 step ごとにあるというよりは系列データとして見た場合に意味を持つので今回は系列データに対する Disentangle 学習を提案する図 1:右下 (系列 Disentangle).

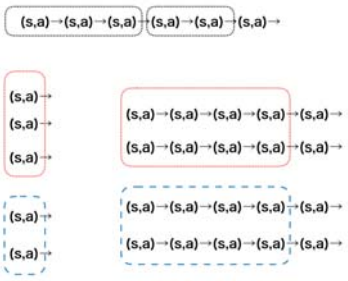


図 1: 上: 時間方向に action をまとめる方法. 左下: 静的 Disentangle(破線の中は同様の意味の action). 右下: 系列 Disentangle(破線の中は同様の意味の action).

論文の構成としては, 第 2 章は既存手法である非系列データに対する Disentangle な表現学習の説明を行う. 第 3 章で提案手法である系列データに対する Disentangle 学習の説明を行う. 4 章では実験結果を示し, 5 章でまとめと今後の研究課題について述べる.

2. Hierarhical representation learning

この章では非系列データから Disentangle な表現を獲得する学習モデルである $\beta-$VAE を説明する. 最初は $\beta-$VAE の元となっている VAE を説明し, 次に $\beta-$VAE を情報量の観点から説明する.

連絡先: masanori.yamada.cm@hco.ntt.co.jp

2.1 Variational Autoencoder(VAE)

データセット x のサンプルから x の確率密度を推定する方法として VAE[Kingma 14] は提案された．対数尤度を展開すると

$$\log p(x) = E_{q_\phi(z|x)}\left[\log p_\theta(x|z)\right] - D_{\mathrm{KL}}\left(q_\phi(z|x)\,||p(z)\right) + D_{\mathrm{KL}}\left(q_\phi(z|x)\,||p(z|x)\right) \quad (1)$$

$$\geq E_{q_\phi(z|x)}\left[\log p_\theta(x|z)\right] - D_{\mathrm{KL}}\left(q_\phi(z|x)\,||p(z)\right) \quad (2)$$

となる．ここで D_{KL} はカルバックライブラー情報量と呼ばれる確率分布間の距離のようなものである．VAE では ϕ, θ を用いて尤度関数の下限を最大化を行うことで $\log p(x)$ を推定する．ここでわざわざ下限を用いたのは $p(z|x)$ を推定することが困難なので, 下限を最大化することで $D_{\mathrm{KL}}\left(q_\phi(z|x)\,||p(z|x)\right)$ を小さくし $p(z|x)$ を $q_\phi(z|x)$ で近似するためである．VAE の学習を行うと $x \to z$ を encode する $q_\phi(z|x)$ と $z \to x$ を decode する $p_\theta(x|z)$ が得られる．本研究では具体的な x から抽象的な表現である z を獲得することで系列のデータの抽象化を行う．

2.2 $\beta-$VAE

VAE の隠れ層において獲得する表現を Disentangle 化できる $\beta-$VAE について説明する．$\beta-$VAE は $p(z) = \mathcal{N}(0, I)$ として VAE の正則化項の係数 $\beta \geq 0$ に拡張した学習手法である．

$$\mathcal{L} \equiv E_{q_\phi(z|x)}\left[\log q_\theta(x|z)\right] - \beta D_{\mathrm{KL}}\left(q_\phi(z|x)\,||p(z)\right) \quad (3)$$

ここで β はハイパーパラメータである．β が大きくなると潜在変数 $q_\phi(z|x_n)$ を平均 0 分散 1 の Gauss 分布に近づける効果を優先されるので各 z は 0 に近づこうとする．しかし全ての z が 0 になると入力データを再構成できないので必要最低限の z を残して $q_\phi(z|x_n) = \mathcal{N}(0, I)$ になる．結果として出力変数 x をできるだけ少ない z の組み合わせで表現しようとし Disentangle な表現を獲得することができる．

次に [Burgess 17] で提案されている $\beta-$VAE を安定させる重要な改善について説明する．$\beta-$VAE の loss 関数は $\beta \neq 1$ の場合 $\log p(x)$ の変分下限の最大化として理解することはできないが, Information bottleneck の考え方から理解できる [Achille 17]．今, 入力データ x を利用してタスク y を解くために最適な表現を z とした場合

$$\min I(x, z), \qquad s.t.\, H(y|x) = H(y|z) \quad (4)$$

の最適化から $\beta-$VAE を導出することができる．まず Eq. 4 の最初の式は x と z をできるだけ無関係にする最適化になっている．次に Eq. 4 の 2 つめの式は $x \to y$ を行うのに必要な情報を保存するという制約条件になっている つまり $x \to y$ を行うための情報を保ちながら z をできるだけ x と無関係に最適化するという問題になっている．Eq. 4 をラグランジュ未定乗数法で解くと

$$H(y|z) \simeq E_{x,y\sim p(x,y)}\left[E_{z\sim q(z|x)}\left[-\log p(y|z)\right]\right] \quad (5)$$

$$I(x, z) = E_{x\sim p(x)}\left[D_{\mathrm{KL}}\left(q(z|x)\,||p(z)\right)\right] \quad (6)$$

なので

$$\mathcal{L} = E_{q(z|x)}\left[\log p(y|z)\right] - \beta D_{\mathrm{KL}}\left(q(z|x)\,||p(z)\right)$$

となり出力の y を x とみなせば $\beta-$VAE を導出できた．ここで β はラグランジュ未定乗数法から来る定数である． これまでの導出により $\beta-$VAE は第一項目の再構成誤差 (y の場合は cross-entropy) の最大化問題に, 第二項目のカルバックライブラー情報量の正則加工をつけたものだと理解することができるので β はバランスを取る項になっていて,β が大きいと再構成より Disentangle が優先され再構成が上手く行かず (例えば画像であるとぼやける), 逆に β が小さいと再構成はうまくいくが disengangle がうまくいかないということが実験的にも知られている [Burgess 17]．そこで大きい β を使い再構成を行う方法として提案されたのが以下のように第二項目に線形シフトを入れるという方法である．

$$\mathcal{L} \equiv E_{q_\phi(z|x)}\left[\log q_\theta(x|z)\right] - \beta\left(D_{\mathrm{KL}}\left(q_\phi(z|x)\,||p(z)\right) - C\right) \quad (7)$$

シフトの効果により最適化問題は $I(x, z) = C$ となり C だけ情報を持つことが許されるため大きい β を用いてもきれいに再構成を行うことができる．

2.3 Variational Ladder Autoncoder

教師ありの深層学習は階層的に特徴を学習することで成功を収めている．一方で教師なしの生成モデルにおいても ladder 型の Variational Autoencoder を利用することで実現している研究がある [Zhao 17]．先行研究のポイントは階層化には 2 パターンの方法があり 1 つは stacked hierarchy と呼ばれるもので layer 方向に VAE を多層化したものである．もう 1 つは Architectural hierarchy と呼ばれるもので ladder 型のネットワーク構造になっており潜在変数 z が直接はつながっていないところがポイントである．先行研究では ladder 型の接続を用いると layer ごとに階層的な意味の分離ができることを実験的に示している．

3. Proposal model

この章では系列の意味を Disentangle できるモデルを提案する．系列の Disentangle 表現とは, 潜在変数 z から系列データ $x_1, x_2, \cdots, x_T$ の生成を以下のように行った際に

$$p(x_1, x_2, \cdots, x_T) = \int p(x_1, x_2, \cdots, x_T|z)\, p(z)\, dz \quad (8)$$

z ごとに情報が絡まらずに存在する状態のことを指す．提案手法はいずれも $p(z|x_1, \cdots, x_T)$ で encode した z 間の相互情報量を小さくすることで Disentangle な表現学習を実現している．

3.1 TCLVAE (Timeseries Convolutional VLAE)

系列を扱う主流な Neural network のモデルは Long Short-term Memory (LSTM)[Hochreiter 97] や Gated Recurrent Unit (GRU)[Chung 14] などいくつかあるが, VLAE は CNN による抽象化によって階層化をなしていると考えるとまずは系列方向に 1 次元の Convolution を加えるのがシンプルなアイディアである．提案手法である TCVLAE は Time Convolution を用いた VLAE に $\beta-$VAE 型の loss 関数を適応したものであり, ネットワークの詳細は 図 2 に示す．Ladder network の合流部は VLAE ではゲートを使っていたが今回は単純に和をとった．Time Convolution は filter size 3, stride 2, padding 1 を使い channel は常に入力の倍に増やすようにした．$\beta = 100$ と

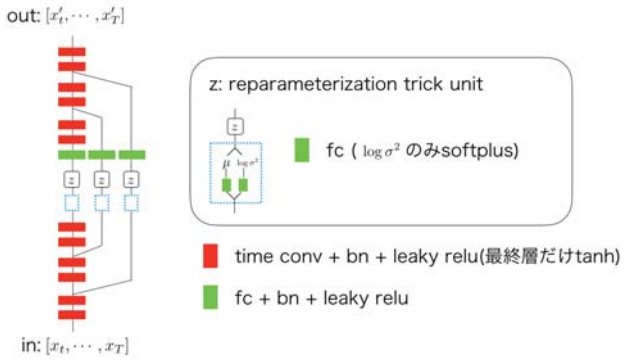


図 2: TCVLAE のネットワーク構造. 3 つある z それぞれが属するネットワークを右から ladder1, ladder2, ladder3 とした. 図中で各 ladder の z は 1 次元だが実際は高次元.

してカルバックライブラー情報量に対する C のシフトはスケジューリングして線形シフトさせるのではなく, 直近 50 epoch のカルバックライブラー情報量誤差 (kl loss) の平均で決定した. kl loss は各 ladder ごとに計算し, C のシフトも各 ladder ごとに計算した.

3.2 Seq2seq model

Convolution を用いるモデルにはいくつか問題点がある. 1 つは Convolution window size 以上の系列の関係を結果に反映させることができないという点である. この問題を解決した時間方向の Convolution を用いるモデルとして quasi-recurrent neural networks (QRNN) がある. このモデルは LSTM や GRU などと比較して学習が速く精度も LSTM と同程度であることが実験的に確認されている [Bradbury 17]. TCVLAE のもう一つの問題としては, 固定長の系列入力しか扱うことができない点である. これについては系列データを扱う際によく用いられている seq2seq model [Sutskever 14] を用いることで可変長なデータに対しても扱うことができるようにする. QRNN は seq2seq model を扱うことができる. seq2seq モデルでは潜在変数 z に encode する encoder $p(z|x_1, \cdots, x_T)$ と潜在変数 z から系列データを生成する decoder $p(x_t|z, x_{t-1})$ から成り立つ. Decoder での入力として z と x_{t-1} は和を取った.

Seq2Seq タイプのの TCVLAE では学習時の decoder の入力は decoder の出力を再帰的に入力するのではなく, 正解データを入力として与えた (decoder の最初の時刻の入力は 0 を用いた). 学習済みモデルでの生成時 ($z \to x$) では再帰的に 1 時刻前の decoder の出力を decoder の入力とした (decoder の最初の時刻の入力は 0 を用いた). action の低次元表現,

4. Experiment

4.1 setup

この章では TCVLAE と TCVLAE+seq2seq(QRNN) 2 つの結果について紹介する. 学習データは 2 次元上で階層的な運動を模擬した系列データを用いた. 2 次元座標 $(0, 0)$ から 2 つのターゲット $(-0.1, 1)$ と $(0.1, 1)$ に点が移動する系列データになっており, 2 つのターゲットへの軌道にはバリエーションがあるデータ 図 3 である. 今回 どちらの target に向かっているのかという抽象的な意味と, 外側に膨らむ軌道か内側に膨らむ軌道かという具体的な意味を系列データから分離することを目的とする.

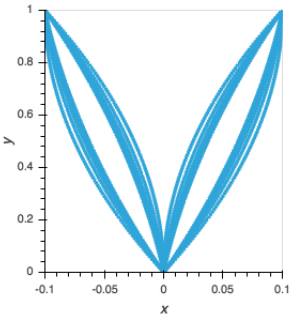


図 3: 2 つのターゲットに複数の軌道を描きながら点が飛んでいく系列データ

4.2 TCVLAE における階層性の効果の比較

学習済みの TCVLAE に対して z を入力して $x_1, x_2, \cdots, x_T$ を生成した結果を図 4 の上段に示す. どちらのターゲットを目指すかという抽象的な意味が抽出されており, 下の図の z には外側に膨らむか内側に膨らむ軌道を選ぶかという具体的な軌道の違いの意味が抽出されている. ladder は 3 つあり, 各 ladder の z の次元はそれぞれ [8,4,2] 次元である. 入出力に近い位置から分岐した ladder から順番に ladder1, ladder2, ladder3 とした. ladder3 内の 1 つの z にターゲット選択する意味が抽出され, ladder2 内の 1 つの z には具体的な軌道の膨らみの意味が抽出され, その他の z には意味は現れなかった (z を変化せても x に変化が現れなかった). 次に ladder の効果を確かめるために ladder なしの TCVLAE を図 4 の下段示す. ladder ありと比較すると ladder なしではターゲットの選択の意味は獲得できているが, 軌道の膨らみの意味を明確に獲得することができなかった. よって今回のデータセットに関しては ladder を入れたことで系列データの意味の分離に効果があることが実験的に確かめられた. ladder なしのネットワークは encode と decode 層にそれぞれ Time Convolution を 4 層使い z の次元は 4 次元を用いた (z の次元を増やしても結果は良くならなかったため).

4.3 TCVLAE + seq2seq

学習済みの TCVLAE+seq2seq に対して z を入力して再帰的に $x_1, x_2, \cdots, x_T$ を生成した結果を図 5 に示す. TCVLAE+seq2seq でも系列の意味の分離が可能であることがわかる. ただし外側への軌道の膨らみを綺麗に獲得することはできなかった. まだ seq2seq モデルでは ladder1 にすべての情報が集まり ladder の恩恵を得ることができなかった.

5. Conclusion and Future work

系列データにたいして Disentangle な表現の獲得を目指すモデルとして TCVLAE と TCVLAE+seq2seq を提案した. 単純なデータに対しては TCVLAE を用いることで系列データから Disentangle な表現の獲得が可能であることを実験的に示した. 今後はエキスパートデータか学習済みの強化学習モデルを用いて (s, a) をサンプリングして TCVLAE から Disentangle な表現として抽象的な action z を獲得して, $p(z_T|s_{t,\cdots,T})$ を学習する強化学習を作り, 既存手法である $p(a_T|s_{t,\cdots,T})$ と学習効率や抽象的な action を学習したことによる転移学習の性能を比較したい.

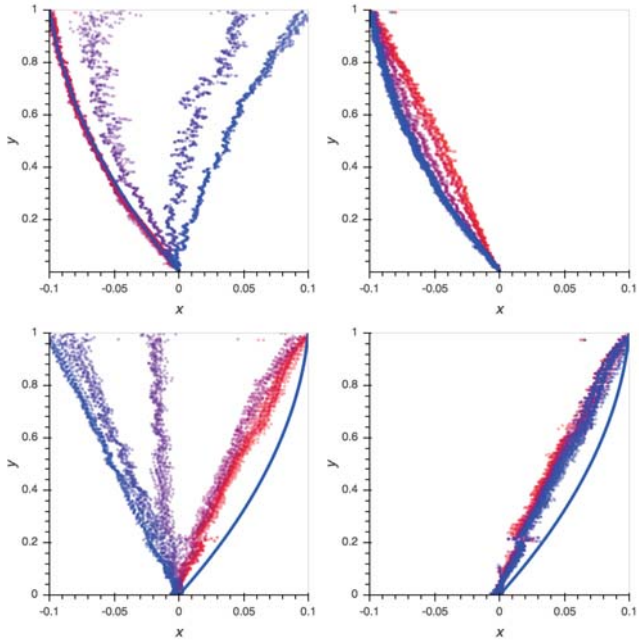


図 4: TCVLAE に対して, 青い実線でプロットされている系列データから encode された z を用いて, 各 z を変化させて decode した x_t をプロットした図. ただし z の値を変化させる時, 他の z の値は encode した値で固定している. 色の違いは z の値の違い. 上段は ladder ありの TCVLAE の結果で, 下段は ladder がない TCVLAE の結果. 左上:ladder 3 の z_1 を $[-2, 2]$ に変化させた時に生成された系列データ. 右上: ladder 2 の z_2 を $[-2, 2]$ に変化させた時に生成された系列データ. 左下: z_1 を $[-2, 2]$ に変化させた時に生成された系列データ. 右下:z_4 を $[-2, 2]$ に変化させた時に生成された系列データ.

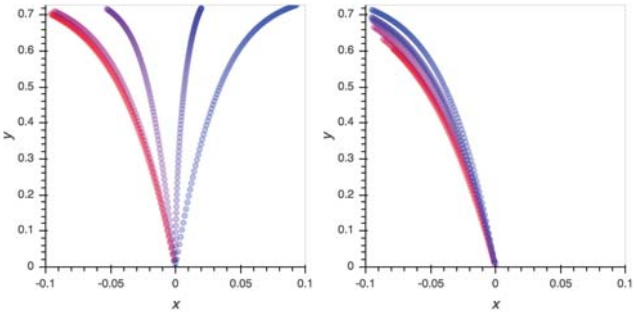


図 5: TCVLAE+seq2seq にたいして各 z を変化させて decode した x_t をプロットした図. 左: ladder1 の z_1 を変化させた結果. 右: ladder1 の z_2 を変化させた結果

参考文献

[Achille 17] Achille, A. and Soatto, S.: Information Dropout: learning optimal representations through noise, in *ICLR* (2017)

[Bradbury 17] Bradbury, J., Merity, S., Xiong, C., and Socher, R.: QUASI-RECURRENT NEURAL NETWORKS, in *ICLR* (2017)

[Burgess 17] Burgess, C. P., Higgins, I., Pal, A., Matthey, L., Watters, N., Desjardins, G., and Lerchner, A.: Understanding disentangling in β-VAE, in *NIPS* (2017)

[Chen 16] Chen, X., Chen, X., Duan, Y., Houthooft, R., Schulman, J., Sutskever, I., and Abbeel, P.: InfoGAN: Interpretable Representation Learning by Information Maximizing Generative Adversarial Nets, in *NIPS* (2016)

[Chung 14] Chung, J., Gulcehre, C., Cho, K., and Bengio, Y.: Empirical evaluation of gated recurrent neural networks on sequence modeling, in *NIPS* (2014)

[Durugkar 16] Durugkar, I. P., Dernbach, S., Rosenbaum, C., and Mahadevan, S.: Deep Reinforcement Learning with Macro-Actions, *[arXiv:1606.04615 [cs.LG]]* `https://arxiv.org/abs/1606.04615` (2016)

[Goodfellow 14] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., and Bengio, Y.: Generative Adversarial Nets, in *NIPS* (2014)

[Higgins 14] Higgins, I., Matthey, L., Xavier Glorot, A. P., Uria, B., Blundell, C., Mohamed, S., and Lerchner, A.: Early Visual Concept Learning with Unsupervised Deep Learning, *[arXiv:1606.05579 [stat.ML]]* `https://arxiv.org/abs/1606.05579` (2014)

[Higgins 17] Higgins, I., Matthey, L., Pal, A., Burgess, C., Glorot, X., Botvinick, M., Mohamed, S., and Lerchner, A.: beta-VAE: Learning Basic Visual Concepts with a Constrained Variational Framework, in *ICLR* (2017)

[Hochreiter 97] Hochreiter, S. and Schmidhuber, J.: Long Short-Term Memory, *Neural Comput.* (1997)

[Kingma 14] Kingma, D. P. and Welling, M.: Auto-Encoding Variational Bayes, in *ICLR* (2014), `https://arxiv.org/abs/1312.6114`

[Mnih 15] Mnih, V., Kavukcuoglu, K., et al.: Human-level control through deep reinforcement learning, No. 7540, pp. 529–533 (2015)

[Sharma 17] Sharma, S., Lakshminarayanan, A. S., and Ravindran, B.: Learning to Repeat: Fine Grained Action Repetition for Deep Reinforcement Learning, in *ICLR* (2017)

[Sutskever 14] Sutskever, I., Vinyals, O., and Le, Q. V.: Sequence to Sequence Learning with Neural Networks, in *NIPS* (2014)

[Vezhnevets 16] Vezhnevets, A., Mnih, V., Osindero, S., Graves, A., Vinyals, O., Agapiou, J., and kavukcuoglu, k.: Strategic Attentive Writer for Learning Macro-Actions, in *NIPS* (2016)

[Zhao 17] Zhao, S., Song, J., and Ermon, S.: Learning Hierarchical Features from Deep Generative Models, in *ICML* (2017)

The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

満足化を通じた最適な自律的探索

Autonomous optimal exploration through satisficing

甲野 佑 *1　　高橋達二 *2
Yu Kono　　Tatsuji Takahashi

*1株式会社ディー・エヌ・エー　　*2東京電機大学
DeNA Co., Ltd.　　Tokyo Denki University

As deep layered neural networks enables reinforcement learning in huge action-state spaces, the exploration–exploitation tradeoff becomes more serious. Several heuristics have been proposed to deal with the tradeoff, utilizing noises. The probabilistic methods have difficulty in parameter tuning, and they amplify the problem of huge dispersion in performance of deep reinforcement learning algorithms. We propose a deterministic action selection algorithm based on a cognitive satisficing value function (RS) inspired by how humans explore under uncertainty. We define a method to enable optimal (minimal) exploration, utilizing the relationship between the aspiration level and the potential exploration distribution. The resulting algorithm exhibits an optimal performance in multi-armed bandit problems, and it opens the possibility for a new class of reinforcement learning algorithms.

1. はじめに

人間は一定の基準値 R を超える行動を探索し，発見後は探索を停止する，満足化と呼ばれる意思決定・試行錯誤の方策を実施するとされる．効率的な満足化に基づく試行錯誤学習を行うエージェントやロボットが開発できれば，R を利用者やエージェント自身が与えられる場合には，工学的にも有用である．また，満足化アルゴリズムを人間や動物の行動の分析に用いることで，行動科学的な知見を得ることもできるであろう．しかしながら，多腕バンディット問題のような単純な問題を除いては，満足化を効率的に行うアルゴリズムは知られていなかった．これに関し，その傾向を多腕バンディット問題において実現する認知的な満足化価値関数 RS が提案されている [高橋 16]．RS は R 以上の価値を持つ選択肢を速やかに見つけ出し, また R が最適，すなわち最適な行動のみが満足な行動であるように設定すれば，満足化の結果として最適化を非常に効率的に行い, 有限 regret を実現することが証明されている [玉造 18]. R の設定に関しては，まず R が入るべき範囲がわかる場合は色々ありうる．一日に必要な食物の量などのエージェントの内的な需要を R とすれば良い場合や，タスク・環境の情報から最適な R が計算できる場合がある．また，同様のタスクを解いている他エージェントから有益な R をもらえる場合もある．例えば陸上競技で誰かが 100m 走で 10 秒を切ると，他の選手も相次いで後続する，といった場合には，当初の新記録が R となっていると考えられる．満足化については，そのスケーラビリティ，すなわち行動数が爆発しても有効に働くことも分かっている [Oyo 17]．これは現実的な強化学習タスクを扱うには重要な性質である．しかし現在, 静的なバンディット問題を扱う際に RS は二つの課題を有している．

1. タスク中のオンライン情報のみからの最適基準値の算出法
2. 満足できる選択肢の発見までの探索配分の最適性

前者は事前情報がない状態での動的な基準値の算出の最適化, 後者は満足化における後悔の度合いの最適化についてを意味する．本研究では Chernoff–Hoeffding bound [Lai 85] からこの二点に関する RS の改善案を提示する．

連絡先: 甲野　佑, 株式会社ディー・エヌ・エー, 150–8510, 東京都渋谷区渋谷 2–11–1 渋谷ヒカリエ, yu.kohno.02@gmail.com

2. 多腕バンディット問題

多腕バンディット問題とは確率的に報酬が得られる複数の行動の選択肢 $a_i \in A$ が存在する環境で, 事前知識のない状態から単位時間毎に一種の行動を選んで発生する報酬値を観測する試行錯誤を続け, 報酬を最大化することを目的とした最もシンプルな意思決定課題である．また割引率を無視すれば，K 種の選択肢を有する初期状態を持ち, かつ 1 回の行動毎に終端状態へとたどり着く強化学習のエピソードタスクとしても捉える事もできる．本研究では報酬 r は必ず任意の選択肢 a_i を試行すると確率 p_i で $r = 1$, 確率 $1 - p_i$ で $r = 0$ が与えられる二値バンディットを扱う．

2.1 経験期待値の更新方法

バンディット問題における RS の算出に必要な数値は試行量 $n(a_i)$ と経験期待値 $V(a_i)$ であり, 以下のように更新される．ここで α は学習率, K は選択肢の数で, a^{select} はそのステップで選択された選択肢である．学習率 α は試行量 $n(a_i)$ に応じて減少していく．また総試行量を N と表記する．

$$\alpha \leftarrow \frac{1}{1 + n(a^{\text{select}})} \tag{1}$$

$$V(a^{\text{select}}) \leftarrow (1-\alpha)V(a^{\text{select}}) + \alpha r \tag{2}$$

$$n(a^{\text{select}}) \leftarrow n(a^{\text{select}}) + 1 \tag{3}$$

$$N = \sum_{k=1}^{K} n(a_k) \tag{4}$$

2.2 経験期待値の初期値

その初期値は以下のようにしている．試行量 $n(a_i)$ にはごく微小な ϵ を, RS 式でゼロ除算を防ぐために初期値として代入する．変数 $n(a_i)$ を試行量と呼ぶのはこの初期値のため試行回数そのものではないためである．

$$n(a_i) \leftarrow \epsilon \tag{5}$$

$$V(a_i) \leftarrow 0.5 \tag{6}$$

3. RS の定義

満足化価値関数 RS は式 (7) で定義される．ここで変数 R は満足化における基準値で, 既存研究では事前知識として与えられたり, なんらかの経験的な手法で動的に算出されていた．

$$RS(a_i) = \frac{n(a_i)}{N}\big(V(a_i) - R\big) \tag{7}$$

$$a^{\text{select}} \leftarrow \arg\max_{a_k}\big(RS(a_k)\big) \tag{8}$$

本研究ではその時点で RS の評価値が最も高い (RS–greedy) 選択肢を試行するエージェントを便宜上 RS エージェントと呼ぶ.

4. 非満足状況

エージェントにとって, 多腕バンディット問題における K 個の選択肢すべての経験期待値 $V(a_i)$ が $V(a_i) < R$ であると観測されている環境を “非満足状況” であると定義する. 非満足状況では現時点で経験期待値 $V(a_i)$ が最も高い (すなわち greedy な) 選択肢 a_G より基準値 R は高くなる ($R \geq V(a_G)$) ため, RS の定義では試行量とその総和の比率 (試行量割合) $\rho(a_i) = n(a_i)/N$ が高ければ高いほど RS 価値関数が算出する評価値は低くなっていく. ある選択肢 a_i が選択されるほどそれ以外の選択肢 a_j に対する試行量割合 $\rho(a_j) = n(a_j)/N$ は減少するため, 非満足状況ではある選択肢を試行するほど, それ以外の選択肢の RS 評価値は高くなる. その際の RS 評価値の上昇率は試行割合の変化量に応じて低くなるため, 総試行量 N が大きくなればなるほど, 非満足状況における RS 評価値の変化は小さくなる. しかし任意の選択肢の試行に対して, 不満足状況では RS は減少しかしないため, いずれ全ての選択肢に対してほぼ一定 (均衡値 $-Z$) になる. これを “非満足下の RS 均衡” と呼び, 前述の均衡値 $-Z$ を RS 均衡値と呼ぶ. それに伴い総試行量 N が充分大きい際の RS エージェントの試行割合 $n(a_i)/N$ を逆算的に算出できる. この均衡はある一定の割合に試行割合の配分を矯正する働きを有しており, 非満足状況下では常にその時点で RS の評価値が最も高い (RS–greedy) 選択肢を選び続けると, なるべく試行量 $n(a_i)$ が式 (10) に近づくように選択が行われていく.

$$RS(a_i) = -Z \tag{9}$$

$$\rho(a_i) = \frac{n(a_i)}{N} = \frac{Z}{R - V(a_i)} \tag{10}$$

非満足状況における RS 均衡値 ($-Z$) は, 試行量割合 $\rho(a_i)$ の総和が 1 になることから算出できる.

$$\sum_{k=1}^{K}\rho(a_i) = \sum_{k=1}^{K}\frac{n(a_i)}{N} \tag{11}$$

$$= \sum_{k=1}^{K}\frac{Z}{R - V(a_i)} \tag{12}$$

$$= 1 \tag{13}$$

$$Z = \frac{1}{\sum_{k=1}^{K}\frac{1}{R - V(a_k)}} \tag{14}$$

また RS 均衡値 $-Z$ が式 (14) から得られるため, 試行割合 $n(a_i)/N$ は基準値 R と経験期待値 $V(a_i)$ から定義できる. これによって RS エージェントの挙動が予想でき, 目的とする試行量割合 $\rho(a_i)$ から基準値 R を算出することができる.

4.1 非満足状況下で regret を最適化する基準値

前述の議論から非満足状況の時に RS–greedy に試行し続けると, greedy な選択肢 a_G の RS 評価値とそれ以外の選択肢 a_j の RS による評価値は “非満足下の RS 均衡” によっていずれ等しくなる.

$$RS(a_G) = RS(a_j) \tag{15}$$

$$n(a_G)\big(V(a_G) - R\big) = n(a_j)\big(V(a_j) - R\big) \tag{16}$$

$$n(a_j) = n(a_G)\frac{\big(R - V(a_G)\big)}{\big(R - V(a_j)\big)} \tag{17}$$

$$R = V(a_G)\frac{1 - \frac{V(a_j)}{V(a_G)}\frac{n(a_j)}{n(a_G)}}{1 - \frac{n(a_j)}{n(a_G)}} \tag{18}$$

ここで $V(a_j)/V(a_G)$ はその時点での greedy な選択肢の定義と報酬が非負である定義上, 必ず 1 以下になる.

$$\frac{V(a_j)}{V(a_G)} \leq 1 \tag{19}$$

式 (17) から, 現時点で我々が RS において対象とできるのは, 現時点で greedy な選択肢 a_G 任意の選択肢 a_j の関係のみである. しかしゆえに非満足化状況では理想的な $n^*(a_j)/n^*(a_G)$ の関係がわかれば, それを逆算的に実現する基準値 R を定義できるということがわかる. そこで本項では greedy な選択肢とそれ以外の任意の選択肢 a_j の潜在的な選択比率 $\mu = n(a_j)/n(a_G)$ を最適化することを目的とし, その最適な比率 μ^* を Chernoff-Hoeffding bound [Lai 85] から推定する. 各選択肢の現時点からの試行回数の目的値 $n^*(a_i)$ で表すとき, 任意の選択肢 a_j に対する最適な潜在的選択比率 μ_j^* は $n^*(a_j)/n^*(a_G)$ で表される. ここで ρ_k^* は最適な試行割合を意味する.

$$\mu_j^* = \frac{n^*(a_j)}{n^*(a_G)} = \frac{n^*(a_j)}{N}\frac{N}{n^*(a_G)} = \frac{\rho_j^*}{\rho_G^*} \tag{20}$$

あくまでも μ は比率であるため, $n(a_i)$ の絶対的大きさに依存しない. ここで現時点での総試行回数で $n^*(a_i)$ を割ると, 現時点で要求されるべき試行割合 ρ_i^* になる. 本研究では要求されるべき試行割合 ρ_i^* を現時点で greedy な選択肢の真の期待値 $V^*(a_G)$ が任意の選択肢の真の期待値 $V^*(a_i) = p_i$ 以上である (つまり実は a_G が 最良の選択肢ではなく $V^*(a_G) \leq V^*(a_i)$ である) 可能性と等しいと定義し, Chernoff–Hoeffding bound を用いて以下の式 (21) から式 (22) を定義した.

$$\Pr\big(V(a_j) \geq p_i + \epsilon\big) \leq \exp\big(-n(a_j)D_{KL}(p_i + \epsilon || p_i)\big) \tag{21}$$

$$\begin{aligned}\rho_i^* &= \frac{n^*(a_i)}{N} \\ &= \Pr\big(V^*(a_i) \geq V^*(a_G)\big) \\ &= \exp\big(-n(a_i)D_{KL}(V(a_i)||V(a_G))\big)\end{aligned} \tag{22}$$

ここで任意の選択肢 a_i が greedy な選択肢の a_G だった場合, $V^*(a_i) = V^*(a_G)$ であるので確率 $\Pr\big(V^*(a_G) \geq V^*(a_G)\big)$ は 1 になる.

$$\begin{aligned}\rho_G^* &= \frac{n^*(a_G)}{N} \\ &= \Pr\big(V^*(a_G) \geq V^*(a_G)\big) \\ &= \exp\big(-n(a_G)D_{KL}(V(a_G)||V(a_G))\big) \\ &= 1\end{aligned} \tag{23}$$

ここで ρ_k^* はあくまでも今後目指すべき試行割合であり, 総和が $\sum\rho_k^* = 1$ を満たさなければならないわけではない. よって任意の選択肢に対して Chernoff–Hoeffding bound から導かれる近似的に最適な潜在選択比率の推定値 $\mu_j^{\text{CH}} \simeq \mu_j^*$ は以下のように定義される.

$$\mu_j^{\mathrm{CH}} = \frac{n^*(a_j)}{N}\frac{N}{n^*(a_G)} = \exp\big(-n(a_j)D_{KL}(V(a_j)||V(a_G))\big) \quad (24)$$

$$R^{\mathrm{CH}} = \max\left(V(a_G)\frac{1-\frac{V(a_j)}{V(a_G)}\mu_j^{\mathrm{CH}}}{1-\mu_j^{\mathrm{CH}}}\right) \quad (25)$$

また近似的な最適潜在選択比率 μ_j^{CH} を用いて算出された基準値 R を非満足基準値 R^{CH} とし, それを用いた RS 価値関数を RS–CH と呼ぶ.

5. RS–CH の多腕対応

前述した段階での RS–CH はある選択肢 a_j と greedy 選択肢との間の Chernoff–Hoeffding Theorem から導かれる理想的な比率 μ_j^{CH} に基づくのみで, 選択肢が二つしかない 2 本腕バンディット問題のみにしか使用できない. それ以上に後述する理論的な問題があるために現行の RS の形式では 3 本腕以上のバンディット問題では最適にはならないと思われる.

5.1 3 本腕バンディット問題以上での非最適性

総試行回数 N が十分大きい場合の a_i に対する理想的な試行割合は式 (26) になるため, ゆえに greedy ではない任意の二つの選択肢 a_i と a_j の選択比率は式 (27) になる.

$$\rho^*(a_i) = \exp\big(-n(a_i)D_{KL}(V(a_i)||V(a_G))\big) \quad (26)$$

$$\frac{\rho^*(a_i)}{\rho^*(a_j)} = \frac{\exp\big(-n(a_i)D_{KL}(V(a_i)||V(a_G))\big)}{\exp\big(-n(a_j)D_{KL}(V(a_j)||V(a_G))\big)} \quad (27)$$

RS 価値関数に対して greedy な選択をし続けた最終的な試行割合 ρ^{RS} (RS 目的試行割合) は式 (28) であるため, greedy ではない任意の二つの選択肢 a_i と a_j の間の選択比率は式 (29) のようになる.

$$\rho^{\mathrm{RS}}(a_i) = \frac{Z}{R-V(a_i)} \quad (28)$$

$$\frac{\rho_i^{\mathrm{RS}}}{\rho_j^{\mathrm{RS}}} = \frac{R-V(a_j)}{R-V(a_i)} \quad (29)$$

全ての選択肢に対する RS 目的試行割合の間の選択比率 (式 (29)) が $N\to\infty$ の時に式 (27) を満たす基準値 R が存在しない限り, RS はいかなる基準値 R の定義を持とうと 3 本腕以上のバンディット問題では最適ではないと言える. 従来の RS エージェントでは基準値 R は全ての選択肢に対する RS 評価値に対して共通であるため, 式 (27) と一致はしない.

ただしこれは非満足化状況 ($R \geq V(a_G)$) での満足化に限定した場合であり, 満足化状況 ($R \leq V(a_G)$) を取りうる基準値 R の定義である場合には適用されない.

5.2 3 本腕以上のバンディット問題への対応

従来の RS 価値関数のように全ての選択肢に対して等しい基準値 R を用いる場合, 3 本腕以上のバンディット問題での後悔の最小化は不可能である. そのため本研究では実装上, 現時点で経験期待値が最も高い greedy な選択肢 a_G とそれ以外の選択肢 a_j を一つずつ比較する手法を提案する. 具体的には $V(a_G)$, $n(a_G)$, $V(a_k)$, $n(a_k)$ の四つの変数を用いて 2 本腕バンディットと同じく式 (25) 及び RS 価値関数を計算する. その上で全ての非 greedy 選択肢 a_j と比較して greedy 選択肢 a_G の RS 評価値が上回る場合は a_G を選択する. 非 greedy 選択肢 a_k の RS 価値関数が a_G を上回る選択肢があった場合, その選択肢を選ぶ. そして greedy 選択肢 a_G の RS 値を上回る非 greedy 選択肢が複数あった場合, その中で a_G との潜在的選択比率 μ_j^{CH} が最も高い選択肢, もし最も高い潜在的選択肢 $a^{\max} = \arg\max \mu_j^{\mathrm{CH}}$ が複数あった場合は R^{CH} が最も高い選択肢を選択する (それも同値だった場合はその選択肢の中でランダムに選択する).

6. 実験と結果

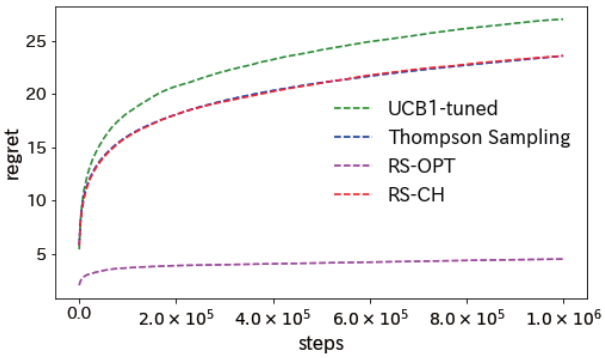


図 1: 2 本腕の結果

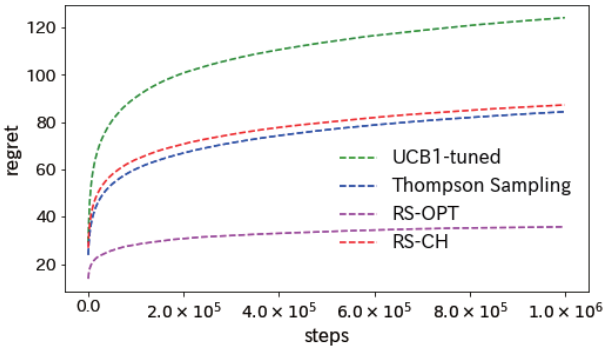


図 2: 8 本腕の結果

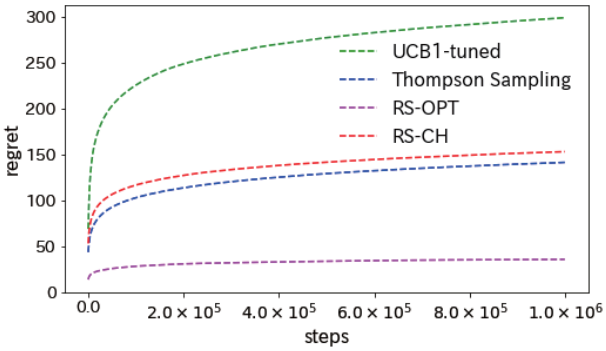


図 3: 20 本腕の結果

実験は各々シードの異なる 10,000 回のシミュレーションを平均で評価した. 選択肢数は 20 個で, それぞれ選択肢 a_k の真の報酬出現確率 p_k はシミュレーション毎に一様分布からサンプリングされ, 1 回のシミュレーション中は固定される. 1 回の選択を 1 step として 1,000,000 step 選択を行なった. 比較する選択アルゴリズムには UCB1–tuned [Wang 05] と Thompson Sampling [Agrawal 12] を用いた. また理想的な基準値 R^{OPT} [高橋 16, Oyo 17, 玉造 18] が既知の場合にそれを用いた RS–OPT も併記する. 理想的な基準値 R^{OPT} は選択肢 a_k を真の報酬出現確率 p_k に対して同値を排除し, 高い順に降順に並べた選択肢 q_m に対して, 以下の式で定義される.

$$R^{\mathrm{OPT}} = \frac{q_1 + q_2}{2} \tag{30}$$

評価は各プロット点の step 数を T と, ある step t において選ばれた選択肢 a_t^{select} の真の確率 p_t^{select} から定義される regret (後悔の度合い) によって比較する.

$$\text{regret} : \sum_{t=0}^{T} \left(q_1 - p_t^{\mathrm{select}}\right) \tag{31}$$

選択指数はそれぞれ $K = 2, 8, 20$ の場合をそれぞれ図 1, 2, 3 にしめす. 本研究で提案した基準値を用いた価値関数 RS–CH により 2 本腕では Thompson Sampling と同水準の成績を得られた. しかし選択肢の数が増えるほどに徐々に regret が劣っていく結果になった. 同時に RS–CH が UCB1–tuned に対して優っている度合いも増えていった.

7. 今後の展望

RS–CH と従来の RS の違いは基準値 R の定義のみであるため, いままで考案されてきた従来の基準値 R と定義式を組み合わせるなどして, 非定常環境などにも用いることが出来る可能性がある. それ以外にも R^{CH} の更新に使う変数をステップ数でずらすだけで非定常環境に強くなる可能性はあると考えらえる. RS–CH は 2 値の報酬でのバンディット問題における KL 情報量での定義なため, 報酬の分布族がわかればベルヌーイバンディット問題以外にも用いることが可能だと思われる.

7.1 非満足状況化での最適基準値と理想基準値との関係

RS–CH は 2 本腕バンディット問題における非満足化状態 ($R \geq V(a_G)$) における RS 評価値の均衡を利用して, Chernoff–Hoeffding bound から導かれる regret の下限以上になりつつ $O(\log N)$ になるよう調整したアルゴリズムである. それにより損失の上限を抑えるという基本的な考え方は Upper Confidence bound (UCB) 系アルゴリズムの導出や Thompson Sampling の最低性の証明にも用いられている. これらの既存最適化アルゴリズムは “greedy な選択肢 a_G の期待値よりその他の選択肢 a_i の期待値が低いと確信するための探索回数を稼ぐ” ことを目的としていると言える.

それに対して満足化方策は RS–greedy な選択肢 a_G^{RS} の期待値が理想的な基準値 R^{OPT} より高い事を確信する事を目的としている. 理想基準値 R^{OPT} であれば, それを上回る真の期待値を持つ選択肢が一つしかないので, greedy に選択し続けても基準値 R^{OPT} より高い選択肢は最適な選択肢である. さらに RS 満足化は前述したように非満足化状態の際に RS 評価値の均衡が起こり, 現環境で観測された経験期待値と基準値 R との差に応じて探索具合を調整する性質がある. 基準値 R が高ければ高いほど試行割合が均等な配分になる.

最適化では step 毎に 1 対 $(K-1)$ の比較検証 (greedy 選択肢とそれ以外の選択肢を一つずつ比べなければならない) が必要になり, さらにその比較は regret 下限の制約を持つため, 非常に検証コストが大きい. それに対して満足化は, 飽くまでも常に基準値と選択肢の比較であり, 一つでもそれ以上の選択肢を見つければ良いため, 1 対 $M \leq (K-1)$ の検証の比較検証で済む. すなわち満足化は最適化と検証対象の違うために非常に検証コストが低い. これは満足化方策は基準値 R の値によっては選択収束 ($N \to \infty$ の時に $n(a_G) \simeq N$ になること) ができず, 最適化方策はいずれ必ず選択収束ができると言い換えることも出来るため一長一短である.

7.2 満足化の柔軟性としての展望

非満足化状態から満足化を目指す満足化過程を前提とする場合, 満足化は最適化方策と同じ問題を抱えてしまう. さらに前述の問題から 3 本腕以上のバンディット問題では後悔の度合いに対するタイトな最適化にはなり得ない. ゆえに理想基準値 R^{OPT} の動的な推定コストが RS における本研究の提案本手法 RS–CH のコストより低いものであれば本手法はその存在意義を失う. ゆえに今後は満足状況をも扱える満足化としての, 理想基準値の推定を検証すべきだと考えられる.

しかしバンディット問題に対して, 事前情報なしで基準値 R を最適化できることを示したのは本研究が初となる. これは満足化の枠組みの中で選択的に最適化も可能であることを示している. コストや, 与えられた目標値など, 事前に与えられた基準値とした R^{PRE} と比較したり二重の満足化を行うことで, 満足化を緩めて事前の目的を優先する事もできる.

8. 結論

満足化価値関数 RS は, 与えられた, あるいは動的に推定した基準値以上の選択肢を発見に優れた性質を有する. しかし, 満足が不可能な基準値を与えられた際の挙動や, その基準にどう対処すべきかは議論されてこなかった. 本研究の理論的な貢献はこの非満足化状況を定式化し, 非満足化時にそこから目指すべき探索配分, 潜在的探索比率 μ を導出したことにある. この潜在的探索比率 μ に Chernoff–Hoeffding bound を用いることで, Thompson sampling のような乱数や, KL–UCB のような数値計算を用いず, 2 値報酬のバンディット問題において regret をタイトに最適化できることを示した. この意味で, 決定論的な楽観的探索の形式の提案を行ったとも言える. 潜在的探索比率の導出により, RS の定量的な探索配分を明らかになったため, 状態空間を広げた一般的な強化学習課題に拡張した際の探索配分の分析, 改善に貢献できると考えられる.

参考文献

[Agrawal 12] Agrawal, S., Navin Goyal, N.: Analysis of thompson sampling for the multi-armed bandit problem. In Proceedings of the 25th Annual Conference on Learning Theory (COLT), (2012).

[Kohno 17] Kohno, Y., Takahashi, T.: A cognitive satisficing strategy for bandit problems, *International Journal of Parallel, Emergent and Distributed Systems*, 32, 2, 232–242. (2017)

[Lai 85] Lai, T. L., Robbins, H.: Asymptotically efficient adaptive allocation rules. *Advances in Applied Mathematics*, 6(1), 4–22, (1985).

[Oyo 17] Oyo, K. and Takahashi, T.: Optimization through satisficing with prospects, in *AIP Conference Proceedings*, Vol. 1863, 360013 (2017)

[Wang 05] S. Gelly, Y. Wang., R. Munos. and O. Teytaud.: Modification of UCT with Patterns in Monte-Carlo Go, Technical Report, No.6062, INRIA (2005).

[高橋 16] 高橋達二, 甲野佑, 浦上大輔, 認知的満足化 限定合理性の強化学習における効用, 人工知能学会論文誌, 31(6), AI30-M_1–11. (2016). doi:10.1527/tjsai.AI30-M

[玉造 18] 玉造 晃弘, 高橋 達二：認知的満足化価値関数の分析：保証付き満足化と有限 regret, 2018 年度 人工知能学会全国大会（第 32 回）論文集 (2018)

CNN, FCN, U-Net を用いたびまん性肺疾患の領域抽出の比較

Comparison of extraction of diffuse lung disease areas using CNN, FCN and U-Net

村上 佳菜子[*1] Kanako Murakami　橋本 典明[*1] Noriaki Hashimoto　木戸 尚治[*1] Shoji Kido　平野 靖[*1] Yasushi Hirano

間普 真吾[*1] Shingo Mabu　近藤 堅司[*2*3] Kenji Kondo　小澤 順[*2] Jun Ozawa

[*1] 山口大学大学院創成科学研究科
Graduate school of Sciences and Technology for Innovation, Yamaguchi University

[*2] 産業技術総合研究所
Advanced Industrial Science and Technology

[*3] パナソニック株式会社
Panasonic Corporation

In recent years, a lot of analytical methods of medical images using deep learning are suggested. Especially, convolutional neural network (CNN) is a model generally used in image recognition. When we classify diffuse lung disease (DLD) patterns using CNN, it is necessary to set region-of-interests (ROIs) on CT images. However, detection is important on diagnosis of DLD as same as classification. So, we propose a method to detect DLD opacities and extract DLD areas without setting ROIs. In this study, we evaluated detection methods of DLD areas using CNN, FCN and U-Net.

1. はじめに

びまん性肺疾患とは，肺の広範囲に渡って病変が広がる疾患の総称である．CT(Computed Tomography)画像におけるびまん性肺疾患の異常陰影は非常に多彩であるため，疾患の診断は医師の経験や主観に左右される．また，CT 装置の進歩に伴って，CT 画像の枚数が増加し，診断する医師の負担が増加している．そのため，コンピュータ支援診断(Computer-aided Diagnosis:CAD)システムの必要性が高まっている．近年，CAD システムにおいて Deep Learning を用いる手法が多く提案されている[1][2]．Deep Learning の手法の一つに CNN (Convolutional Neural Network)がある．CNN は人間の脳の神経回路の仕組みを模したモデルであり，一般的に画像認識においてよく用いられる[3]．CNN を用いてびまん性肺疾患を分類する際，陰影ごとに関心領域を設定する必要がある．しかし，びまん性肺疾患の診断においては識別とともに検出が重要である．そこで本研究では，関心領域を設定せずに学習を行い，CT 画像からびまん性肺疾患の領域を検出・抽出することを目的とした．本手法では，FCN(Fully Convolutional Network)[4]と U-Net [5]を用いて肺野領域から 6 つのびまん性肺疾患の陰影パターンの領域を抽出した．得られた結果に対して，CNN を用いた結果と比較を行った．

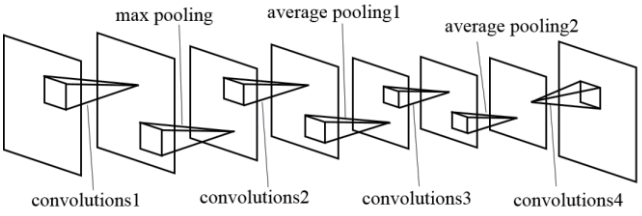


図 1　本研究で用いた FCN の概要

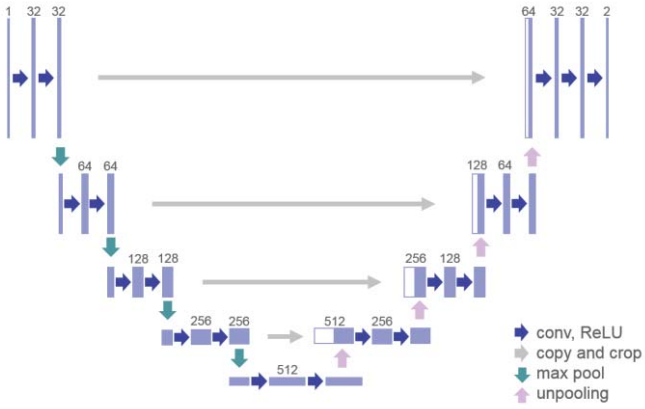


図 2　本研究で用いた U-Net の概要

2. 手法

2.1 提案手法の概要

本手法では，図 1 と図 2 に示す FCN と U-Net を用いて肺野領域からびまん性肺疾患の領域抽出を行った．ここで，使用した陰影はびまん性肺疾患の代表的な陰影パターンである浸潤影(CON)，すりガラス状陰影(GGO)，蜂巣状陰影(HCM)，肺気腫陰影(EMP)，粒状影(NOD)の 5 つの陰影と，正常肺(NOR)を加えた合計 6 つの陰影である．

2.2 データセットの作成

本研究では放射線科医の指導のもと，マニュアルでセグメンテーションした肺野領域画像を学習データとして使用し，透視変換・鏡映を用いてデータ数を増やし，各陰影をそれぞれ 5800 枚として学習を行った．

連絡先：村上佳菜子，山口大学大学院創成科学研究科電気電子情報系専攻，〒755-8611　山口県宇部市常盤台 2-16-1，g094vg@yamaguchi-u.ac.jp

2.3 FCN を用いた学習

FCN はセグメンテーションモデルであり，全ての層が畳込み層で構成されたネットワークモデルのことである．また，全結合層がないため，入力画像のサイズに制約がないという特徴がある．

2.4 U-Net を用いた学習

U-Net は FCN と同様，セグメンテーションを行うためのモデルであり，医用画像を学習対象とする Deep Learning の手法の一つである SegNet[6]で提案されているような Encoder-Decoder 構造であり，Encoder 部分と Decoder 部分の対応した特徴マップをつないでいるため，画像を復元する際に位置情報も含めることができるという特徴がある．

3. 実験と結果

3.1 実験データ

実験には山口大学医学部附属病院にて撮影された胸部 CT 画像 406 症例を用いた．実験に使用した陰影ごとのスライス数の内訳を表 1 に示す．また，CT 画像において 3 人の医師がそれぞれ病変部をマークし，そのうち 2 人以上のマークが一致した領域を正解データとした． CT 画像から放射線科医の指定した病変部を 32×32pixel の大きさの ROI 画像として切り出した．病変部は 32×32pixel の正方形領域で切り出せるとは限らないため，中心座標が病変部に含まれているものを各陰影 500 枚ずつとした．回転・鏡映を用いて水増しした ROI 画像は各陰影 4000 枚ずつであった．また，透視変換・鏡映を用いて水増しした CT 画像は各陰影 5800 枚ずつであった．

表 1 使用した陰影ごとのスライス数

症例の種類	スライス数
浸潤影(CON)	150 枚
すりガラス状陰影(GGO)	114 枚
蜂巣状陰影(HCM)	129 枚
肺気腫陰影(EMP)	163 枚
粒状影(NOD)	34 枚
正常肺(NOR)	55 枚

3.2 評価方法

本手法によって抽出した異常陰影の領域と正解データの領域との類似度を Dice 係数によって評価を行った．Dice 係数は以下の式によって算出した．A は CNN, FCN, U-Net によって抽出した異常陰影の領域，B は正解データの異常陰影の領域を表す．

$$\text{Dice 係数} = \frac{2 \times |A \cap B|}{|A| + |B|} \quad (1)$$

3.3 実験結果

表 2 は，CNN, FCN, U-Net を用いて陰影ごとに病変部を抽出し，Dice 係数によって類似度を求めた．このときの FCN と U-Net を用いて抽出した場合の結果画像を図 3 に示す．陰影ごとの正解データと FCN と U-Net を用いて病変部の抽出を行った結果画像である．

本研究での入力画像は，FCN と U-Net では 512×512pixel の CT 画像であり，ネットワークへの入力の際に FCN では 32×32pixel，U-Net では 96×96pixel に圧縮して使用した．また，CNN では 32×32pixel の大きさで切り出した ROI 画像を使用した．

表 2 CNN, FCN, U-Net の抽出結果

症例の種類	Dice 係数		
	CNN	FCN	U-Net
CON	0.999±0.001	0.609±0.034	0.836±0.063
GGO	0.777±0.154	0.700±0.069	0.470±0.337
HCM	0.941±0.032	0.228±0.267	0.177±0.250
EMP	0.868±0.010	0.250±0.060	0.812±0.131
NOD	0.914±0.011	0.008±0.011	0.639±0.242
NOR	0.939±0.031	0.351±0.133	0.904±0.003
平均	0.906±0.070	0.358±0.235	0.640±0.252

4. 考察

各陰影の平均 Dice 係数は，FCN を用いた場合では 0.358±0.235，U-Net を用いた場合では 0.640±0.252，CNN を用いた場合では 0.906±0.070 という結果になった．FCN と U-Net では入力画像の圧縮を行っているが，CNN では圧縮を行っていない．そのため，解像度の違いが原因で FCN と U-Net での抽出精度が低下したと考えられる．すりガラス状陰影と蜂巣状陰影においては，FCN と U-Net を用いた場合に全く領域を抽出できない症例を含んでいた．そこで，領域を抽出できた画像のみで評価を行った結果，すりガラス状陰影では FCN が 0.700±0.069，U-Net が 0.706±0.070 となり，蜂巣状陰影では FCN が 0.604±0.003，U-Net が 0.530±0.010 となった．この結果から，学習は適切に行えていると考えられる．

また，粒状影において FCN と U-Net を用いた場合の抽出精度が低下した原因として，入力画像の圧縮を行ったために小結節が見えなくなり，学習が十分にできていないと考えられる．今後，入力画像を片肺ずつに切り出した画像とするなどの処理により，圧縮率を小さくすることで改善が見込まれる．

5. まとめ

本稿では，関心領域の設定を行わずに CT 画像からびまん性肺疾患の異常陰影を抽出する方法として FCN と U-Net を用いた方法を提案した．今後の課題として，圧縮率の改善と臨床現場での利用を考慮して，複数陰影での領域抽出への適応が挙げられる．

6. 謝辞

本研究は JPS 科研費 JP26108009，JP17H02110 による助成を受けた．

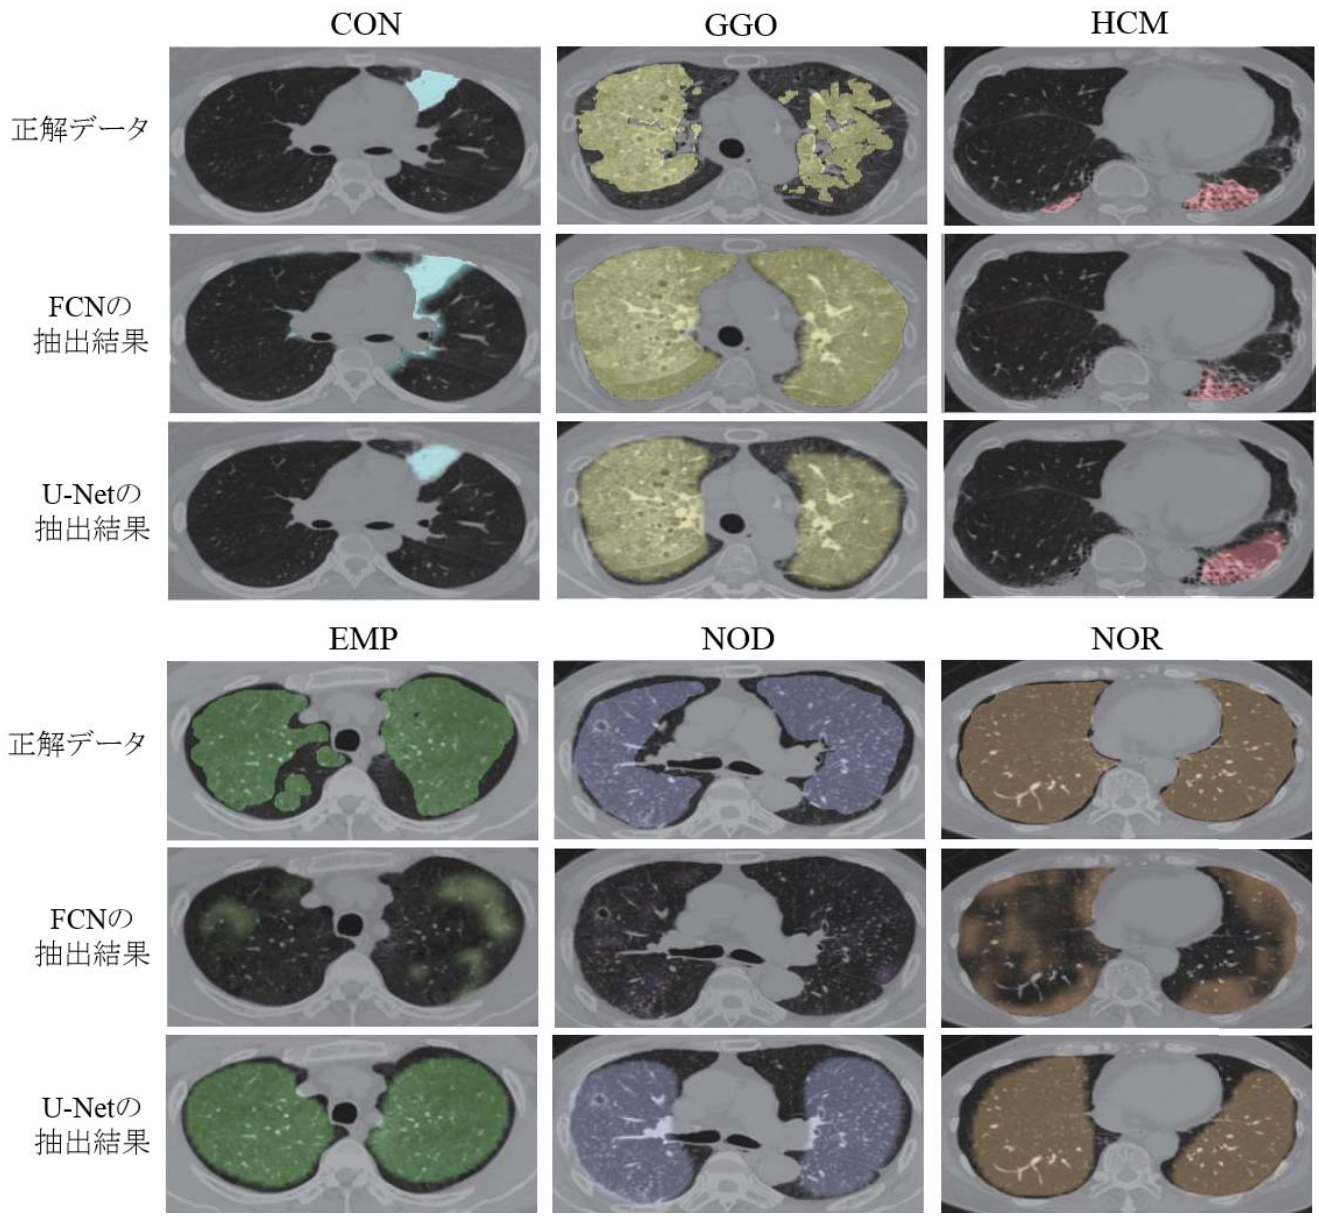


図 3　FCN と U-Net を用いて抽出した結果画像

参考文献

[1] Mingchen Gao, Ziyue Xu, Le Lu, et al., “Segmentation label propagation using deep convolutional neural networks and dense conditional random field”, Proceedings-International Symposium on Biomedical Imaging, pp. 1265-1268, 2016

[2] M. Anthimopoulos, S. Christodoulidis, et al., “Lung Pattern Classification for Interstitial Lung Diseases Using a Deep Convolutional Neural Network”, IEEE Transactions on Medical Imaging, Vol. 35, pp. 1207-1216, 2016

[3] A. Krizhevsky, I. Sutskever, and G. Hinton, “ImageNet classification with deep convolutional neurak networks”, Advances in Neural Information Processing Systems, Vol. 2, pp. 1097-1105, 2012

[4] E. Shelhamer, J. Long, and T. Darrell, “Fully Convolutional Networks for Semantic Segmentation”, IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016

[5] O.Ronneberger, P.Fischer, T.Brox, “U-net: Convolutional networks for biomedical image segmentation”, Lecture Notes in Computer Science, Vol. 9351, pp. 234-241, 2015

[6] V. Badrinarayanan, A. Handa, R. Cipolla, “SegNet: A Deep Convolutional Encoder-Decoder Architecture for Robust Semantic Pixel-Wise Labelling”, CVPR, 2015