Thu. Jun 7, 2018

Room P

Poster presentation | General Session | Interactive

[3Pin1] インタラクティブ(1)

9:00 AM - 10:40 AM Room P (4F Emerald Lobby)

[3Pin1-01] Optimization method for Educational Application of Structural Engineering

○Takuya Suzuki[1], Keiichi Iguchi[2], Takuya Kinoshita[1], Akihiro Ishikawa[2] （1. Takenaka Corporation, 2. HEROZ）

9:00 AM - 10:40 AM

[3Pin1-02] Benchmark Functions for Cooperative Coevolution and Analysis of Influence by Dynamic Problem Decomposition

○Yuki Nakashima[1], Jun-ichi Matsuoka[1], Asuka Hisatomi[1], Satoshi Ono[1] （1. Kagoshima University）

9:00 AM - 10:40 AM

[3Pin1-03] Incorporating Knowledge Graph Embeddings into Latent Variable Models

○Naoya Takeishi[1,2], Kosuke Akimoto[1] （1. The University of Tokyo, 2. RIKEN）

9:00 AM - 10:40 AM

[3Pin1-04] Covariate shift bias correction induced by action

○Ryota Higa[1] （1. NEC Corporation）

9:00 AM - 10:40 AM

[3Pin1-05] Batch Reinforcement Learning for Linearly Solvable MDP

○Tomoki Nishi[1], Keisuke Otaki[1], Takayoshi Yoshimura[1] （1. Toyota Central R&D Labs., Inc.）

9:00 AM - 10:40 AM

[3Pin1-06] Cappuccino: Bootstrapping from Structural Data

○Ryo Hanafusa[1], Masafumi Oyamada[2] （1. Kwansei Gakuin University, 2. NEC Corporation）

9:00 AM - 10:40 AM

[3Pin1-07] Non-negative matrix factorization with information expansion using item class information

○Katsuhiko Murakami[1] （1. The University of Tokyo）

9:00 AM - 10:40 AM

[3Pin1-08] Proposal of direct policy search using reduction of policy parameters by principal component analysis

○Yuuki Murata[1], Megumi Miyashita[1], Shiro Yano[1], Toshiyuki Kondo[1] （1. Tokyo University of Agriculture and Technology）

9:00 AM - 10:40 AM

[3Pin1-09] Curriculum Learning for Similar Learning Cases

○Yuta Ota[1], Yuta Taki[1] （1. KOZO KEIKAKU ENGINEERING Inc.）

9:00 AM - 10:40 AM

[3Pin1-10] Graph Feature Extraction Using Graph Fragment Decision Trees

○Haruki Sakagami[1], Ichigaku Takigawa[1], Hiroki Arimura[1] （1. Hokkaido University）

9:00 AM - 10:40 AM

[3Pin1-11] Objective Correction for Policy Improvement under Entropy Regularization

○Ryo Iwaki[1], Minoru Asada[1] （1. Osaka University）

9:00 AM - 10:40 AM

[3Pin1-12] Experimental evaluation of Time-Series Gradient Boosting Tree with Time-Series Benchmark datasets

○Mitsuyoshi Imamura[1,2], Kei Nakagawa[1,2], Kenichi Yoshida[1] （1. University of Tsukuba, 2. Nomura Asset Management Ltd.）

9:00 AM - 10:40 AM

[3Pin1-13] Batch Random Walk for GPU-Based Classical Planning(Extended Abstract)

○Ryo Kuroiwa[1], Alex Fukunaga[1] （1. the University of Tokyo）

9:00 AM - 10:40 AM

[3Pin1-14] Learning to resample for time-series generative model

○Takaaki Kaneko[1], Shohei Ohsawa[1], Yutaka Matsuo[1] （1. Department of Technology Management for Innovation, The University of Tokyo）

9:00 AM - 10:40 AM

[3Pin1-15] End-of-Query Detection in Text Chat System

○Shun Tanaka[1] （1. CyberAgent, Inc.）

9:00 AM - 10:40 AM

[3Pin1-16] Debating AI: Counterargument Generation Based on Textual Supportiveness Recognition

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

9:00 AM - 10:40 AM

[3Pin1-17] Associative Dialog System for Recipe

©The Japanese Society for Artificial Intelligence

Recommendation Using Food Knowledge

○Katsuyoshi Yamagami[1,2], Mitsuru Endo[2], Hirokazu Kiyomaru[3], Sadao Kurohashi[3] （1. Advanced Industrial Science and Technology (AIST), 2. Panasonic Corporation, 3. Kyoto University）

9:00 AM - 10:40 AM

[3Pin1-18] Analysis of work motivation by persuasion in dialogue

○Takuya Mizukami[1] （1. Waseda University）

9:00 AM - 10:40 AM

[3Pin1-19] Acquiring Utterance Candidates for Chat-oriented Dialogue Systems from Wikipedia Based on a State Space Model

○Tomoki Matsumoto[1], Masato Sakai[1], Mikio Nakano[2] （1. Nextremer Co., Ltd., 2. Honda Research Institute Japan Co., Ltd.）

9:00 AM - 10:40 AM

[3Pin1-20] Knowledge Graph Expansion for Constructing Dialogue Systems Responding to Queries about Unknown Attributes

○Yuma Fujioka[1], Kazunori Komatani[1] （1. The Institute of Scientific and Industrial Research, Osaka University）

9:00 AM - 10:40 AM

[3Pin1-21] Utterance understanding and emotion generation in a dialogue system for children

○Kento Yamamoto[1], Syunya Omura[2], Ryo Nemoto[2], Shiori Wada[1], Toru Sugimoto[2] （1. Graduate School of Engineering and Science,Shibaura Institute of Technology, 2. College of Engineering,Shibaura Institute of Technology）

9:00 AM - 10:40 AM

[3Pin1-22] Augmentation of Dialogue Database by Generating Interrogative Sentences Using Templates

○Yota Osanai[1], Tomoya Ogata[1], Mamoru Komachi[1], Eri Sato-Simokawara[1], Kazuyoshi Wada[1], Toru Yamaguchi[1], Tomoya Takatani[2] （1. Tokyo Metropolitan University, 2. TOYOTA MOTOR CORPORATION）

9:00 AM - 10:40 AM

[3Pin1-23] Utterance Intention Classification and Database Construction for Conversational News Delivery System

○Katsuya Yokoyama[1], Hiroaki Takatsu[1], Hiroshi Honda[2], Shinya Fujie[1,3], Yoshihiko Hayashi[1], Tetsunori Kobayashi[1] （1. Waseda University, 2. Honda R&D Co., Ltd, 3. Chiba Institute of Technology）

9:00 AM - 10:40 AM

[3Pin1-24] A proposal of automatic negotiation simulator Jupiter for negotiation agent using machine learning.

○Tomoya Fukui[1], Takayuki Ito[1] （1. Nagoya Institute of Technology）

9:00 AM - 10:40 AM

[3Pin1-25] An analysis of multilingual communication for solving global environmental issues

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

9:00 AM - 10:40 AM

[3Pin1-26] Premise generation based on argumentation schemes for dialogue systems

○Koh Mitsuda[1], Ryuichiro Higashinaka[1], Taichi Katayama[1], Junji Tomita[1] （1. NTT）

9:00 AM - 10:40 AM

[3Pin1-27] Metaphor creation using corpus and thesaurus

○Ryoga Sato[1], Toru Sugimoto[1] （1. Shibaura Institute of Technology）

9:00 AM - 10:40 AM

[3Pin1-28] Uncombined Elements in an Integrated Narrative Generation System and Expanding Conceptual Dictionaries by Attribute Information

○Jumpei Ono[1], Takuya Ito[2], Takashi Ogata[2] （1. Graduate School of Iwate Prefectural University, 2. Iwate Prefectural University）

9:00 AM - 10:40 AM

[3Pin1-29] Research on Sharing of Robotics Skills

○Guilherme de Campos Affonso[1], Kei Okada[1], Masayuki Inaba[1] （1. Univ. of Tokyo）

9:00 AM - 10:40 AM

[3Pin1-30] Hybrid Policy Gradient for Deep Reinforcement Learning

○praveen singh Thakur[1], Masaru Sogabe[1], Katsuyoshi Sakamoto[2], Koichi Yamaguchi[2], Dinesh Bahadur Malla[2], Shinji Yokogawa[2], Tomah Sogabe[1,2] （1. GRID Inc., 2. The University of Electro-communications）

9:00 AM - 10:40 AM

[3Pin1-31] A mobile robot based on real-time

©The Japanese Society for Artificial Intelligence

reinforcement learning using human evaluation

○Ken Yamane[1], Hiromasa Uetsuki, Hideyasu Yokomatsu[2] (1. Teikyo University, 2. Taito Corporation)

9:00 AM - 10:40 AM

[3Pin1-32] Study on evolutionary calculation by real world feedback from physical experiment determining the shape of an underwater robot.

○Ryota Nakamura[1], Satoru Inoue[1] (1. Saitama Institute of Technology)

9:00 AM - 10:40 AM

[3Pin1-33] Person Re-identification by Online Transfer Learning for Mobile Robot using Region-based CNN and Triplet Loss

○Yuki Murata[1], Masayasu Atsumi[1] (1. Soka University Graduate School of Engineering)

9:00 AM - 10:40 AM

[3Pin1-34] An AI game player trained by a genetic algorithm that avoids bombardments in a shooting game

○Shizuma Namekawa[1], Taro Tezuka[1] (1. University of Tsukuba)

9:00 AM - 10:40 AM

[3Pin1-35] Action acquisition by Memory Reinforcement Learning useing a prior knowledge

○Yuna Inamori[1], Tsubasa Hirakawa[1], Takayoshi Yamashita[1], Hironobu Fujiyoshi[1], Ryota Kashihawa[2], Masaki Inaba[2], Naoki Nitanda[2] (1. Chubu University, 2. DENSO CORPORATION)

9:00 AM - 10:40 AM

[3Pin1-36] Neural Headline Generation with Self-Training

Shintaro Takemae[2], Kazuma Murao[1], ○Taichi Yatsuka[1], Hayato Kobayashi[1,3], Masaki Noguchi[1], Hitoshi Nishikawa[2], Takenobu Tokunaga[2] (1. Yahoo Japan Corporation, 2. Tokyo Institute of Technology, 3. RIKEN AIP)

9:00 AM - 10:40 AM

[3Pin1-37] Security Reinforcement for ATM by Using Image Sensing

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

9:00 AM - 10:40 AM

[3Pin1-38] Study on Image Recognition in Tank/Hold of Ship

○Masaru Hirakata[1], Ma Chong[1], Tomoyuki Taniguchi[1] (1. National Institute of Maritime, Port and Aviation Technology)

9:00 AM - 10:40 AM

[3Pin1-39] Prediction of Bascketball Free Throw Scoring by OpenPose

○Masato Nakai[1], Yoshihiko Tunoda[1], Caidong Sun[1], Hideki Murakoshi[1], Hisashi Hayashi[1], Tuyoshi Aziro[1] (1. Advanced Institute Industrial Technology)

9:00 AM - 10:40 AM

[3Pin1-40] BGM Recommendation System Considering the Atmosphere

○Kikue Sato[1], Shiori Sakai[1], Eichi Takaya[2], Kazuki Yamauchi[3], Hayato Oya[3], Satoshi Kurihara[2] (1. The University of Electro-Communications, 2. Keio University, 3. RecoChoku Co.,Ltd.)

9:00 AM - 10:40 AM

[3Pin1-41] Music Generation from Motion Data

Junta Suzuki[1], ○Syogo Watanabe[2], Kazuaki Rokusawa[1] (1. Department of Computer Science, Chiba Institute of Technology, 2. Graduate School of Information and Computer Science, Chiba Institute of Technology)

9:00 AM - 10:40 AM

[3Pin1-42] Acquisition of uniform impression of music using graph kernel filter

○Hisashi IKARI[1] (1. Sockets Co., Ltd.)

9:00 AM - 10:40 AM

[3Pin1-43] Feature Extraction and Anomaly Detection by Non-negative Matrix Factorization of Vibration Data of Machine

○Masatoshi Sekine[1], Kazuki Kobayashi[1], Satoshi Ikada[1] (1. Corporate Research and Development Center, Oki Electric Industry Co., Ltd.)

9:00 AM - 10:40 AM

[3Pin1-44] Anomaly Detection in Control Valves by 1d CNN-LSTM

○Takahiro Motegi[1], Yuya Nakazawa[1], Tetsuya Tabaru[1] (1. Azbil Corporation)

9:00 AM - 10:40 AM

[3Pin1-45] Constructing Diagnosis Corpus Using Collaborative Learning Environment for Improving Dementia Care

○Naoki Kamiya[1], Hideki Ueno[2,3,4], Takumi Yoshizawa[1], Shogo Ishikawa[1], Kenta Imada[1], Hayato

©The Japanese Society for Artificial Intelligence

Nishiyama[1], Shinya Kiriyama[1,4], Akira Tamai[3], Yoichi Takebayashi[1,4] (1. Shizuoka University, 2. Chiba University Hospital, 3. Tsuruga Onsen Hospital, 4. The Society of Citizen Informatics for Human Cognitive Disorder)
9:00 AM - 10:40 AM

[3Pin1-46] Construction and Practice of Collaborative Learning Environment for Personality-focused Care in Dementia Care

○Atsushi Omata[1], Shogo Ishikawa[1], Hatsue Munakata[1], Ayumi Nakanome[2], Mio Ito[3], Yutaka Sakane[4], Miwako Honda[5], Hisao Hara[2], Shinya Kiriyama[1,6], Yoichi Takebayashi[1,4,6] (1. Shizuoka University, 2. Koriyama Medical Care Hospital, 3. Tokyo Metropolitan Institute of Gerontology, 4. ExaWizards Inc., 5. Tokyo Medical Center, 6. The Society of Citizen Informatics for Human Cognitive Disorder)
9:00 AM - 10:40 AM

[3Pin1-47] Co-production of care knowledge for people with dementia based on an emotion thinking models

○Shogo Ishikawa[1], Yuki Sasaki[1], Shinya Kiriyama[1], Miwako Honda[2], Yves Gineste[3], Yoichi Takebayashi[1] (1. Shizuoka University, 2. Tokyo Medical Center, 3. Institute Gineste Marescotti)
9:00 AM - 10:40 AM

[3Pin1-48] Patient's sitting position estimation using skeleton information and bed position detection

○MADOKA INOUE[1,2], RYO TAGUCHI[2], TAIZO UMEZAKI[2,3] (1. AIPHONE CO., LTD., 2. Nagoya Institute of Technology, 3. The University of Tokyo)
9:00 AM - 10:40 AM

[3Pin1-49] Accurate drowsiness estimation via eye-related movements: a neural-network-based investigation

Mingfei Sun[2], ○Masanori Tsujikawa[1], Yoshifumi Onishi[1], Xiaojuan Ma[2], Atsushi Nishino[3], Satoshi Hashimoto[3] (1. NEC Corporation, 2. Hong Kong University of Science and Technology, 3. DAIKIN Industries, LTD)
9:00 AM - 10:40 AM

[3Pin1-50] Estimating nursing care necessity degree using by assessment information

○Shu Kobayashi[1], Sachiko Hirata-Mogi[1], Fukuda Shoji[1] (1. SMS CO., LTD.)
9:00 AM - 10:40 AM

[3Pin1-51] Attempt to visualize clinical data for grasping status of patients

○Masamichi Ishii[1], Kengo Miyo[1] (1. National Center for Global Health and Medicine)
9:00 AM - 10:40 AM

[3Pin1-52] Development of “Sleep Diary” application and continuation prediction of behavior for improvement sleeping habits

○Jou Akitomi[1], Ikuo Kajiyama[1], Miho Ishii[1], Isa Okajima[2], Mineko Yamaguchi[1] (1. NEC Solution Innovators, Ltd., 2. Tokyo Kasei University)
9:00 AM - 10:40 AM

[3Pin1-53] Simulation of Target Word Prediction for Neural Machine Translation

○Yuto Takebayashi[1], Chenhui Chu[3], Yuki Arase[1], Masaaki Nagata[2] (1. Graduate school of Information Science and Technology of Osaka University, 2. NTT Corporation, 3. Osaka University)
9:00 AM - 10:40 AM

[3Pin1-54] Research of abnormal node eradication conditions of self-repair network

○Yoshiyuki Tamura[1], Yoshiteru Ishida[1] (1. Toyohashi University of Technology)
9:00 AM - 10:40 AM

©The Japanese Society for Artificial Intelligence

Thu. Jun 7, 2018

Room A

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

[3A1] [General Session] 2. Machine Learning

座長:椿 真史（産業技術総合研究所）
1:50 PM - 3:30 PM Room A (4F Emerald Hall)

[3A1-01] Task-free Attention Learning with Intrinsic Reward and Adversarial Learning
〇Tatsuya Matsushima[1], Shohei Osawa[1], Yutaka Matsuo[1] （1. The University of Tokyo）
1:50 PM - 2:10 PM

[3A1-02] A new methodology of deterioration prediction using deep learning scheme for coastal facilities
〇Kentaro Kumagai[1], Naoki Fujii[2] （1. Kyoto University, 2. Tokyo Electric Power Services CO.,Ltd.）
2:10 PM - 2:30 PM

[3A1-03] Improving SRGAN for Super-Resolving Low Resolution Food Images
〇Yudai Nagano[1], Yohei Kikuta[2] （1. The University of Tokyo, 2. Cookpad Inc.）
2:30 PM - 2:50 PM

[3A1-04] Enhancing Visual Explanation of Deep Neural Networks by Activation Freezing
〇Satoshi Hara[1] （1. Osaka University）
2:50 PM - 3:10 PM

[3A1-05] Similarity Learning Based Adversarial Training for Censoring Representatoins
〇Yusuke Iwasawa[1], Yutaka Matsuo[1] （1. The University of Tokyo）
3:10 PM - 3:30 PM

Room B

Oral presentation | Organized Session | [Organized Session] OS-22

[3B1-OS-22a] [Organized Session] OS-22

1:50 PM - 3:30 PM Room B (4F Moon Light)

[3B1-OS-22a-01] On a Multi-faceted Structure of the Representation of a Cup of Sake
〇Hiroki Fukushima[1] （1. Kyushu Women's University）
1:50 PM - 2:10 PM

[3B1-OS-22a-02] Mimetic words and nursing care level in the free description text of long-term care records
〇Sachiko Hirata-Mogi[1], Shu Kobayashi[1], Shoji Fukuda[1] （1. SMS Co., Ltd.）
2:10 PM - 2:30 PM

[3B1-OS-22a-03] Effects of Context Creation Work in Impression of Abstract Paintings
〇Kotone Tadaki[1], Akinori Abe[1,2] （1. Chiba University (Graduate School of Humanities), 2. DWANGO Artificial Intelligence Laboratory）
2:30 PM - 2:50 PM

[3B1-OS-22a-04] A Consideration on a Multiple Approach for Haiku Generation
〇Takuya Ito[1], Kota Igarashi[1], Takashi Ogata[1] （1. Iwate Prefectural University）
2:50 PM - 3:10 PM

[3B1-OS-22a-05] Body-mind integrative science to increase cellular power (1)
〇Yoriko Atomi[1], Miho Shimizu[1], Yoshikazu Higashi[1], Eri Fujita[1], Tomoaki Atomi[2], Kazuya Tanaka[2], Yu Takada[3] （1. Tokyo University of Agriculture and Technology, 2. Teikyo University of Science, 3. Uno hospital）
3:10 PM - 3:30 PM

Oral presentation | Organized Session | [Organized Session] OS-22

[3B2-OS-22b] [Organized Session] OS-22

3:50 PM - 5:30 PM Room B (4F Moon Light)

[3B2-OS-22b-01] Is the expression of taste abstract or representational?
〇Akinori Abe[1] （1. Chiba University）
3:50 PM - 4:10 PM

[3B2-OS-22b-02] Analysis of Taste Expressions Similarity of Japanese Sake
〇Junichi Fukumoto[1] （1. Ritsumeikan University）
4:10 PM - 4:30 PM

[3B2-OS-22b-03] Multi-layered Taste Representation with Shapes and Adjectives
〇Kazunori Miyamoto[1], Hiroki Fukushima[1] （1. Kyushu Women's University）
4:30 PM - 4:50 PM

[3B2-OS-22b-04] Invited Lecture
〇Yuki Watanabe[1], Takashi Okamoto[1] （1. SENSY Inc.）
4:50 PM - 5:30 PM

Room C

©The Japanese Society for Artificial Intelligence

Oral presentation | Organized Session | [Organized Session] OS-14

[3C1-OS-14a] [Organized Session] OS-14

1:50 PM - 3:10 PM Room C (4F Orchid)

[3C1-OS-14a-01] Analysis of the effect of agent's embodiment and gaze amount on personality perception

TAKUTO ISHIOH[1], ○TOMOKO KODA[1] （1. Osaka Institute of Technology）

1:50 PM - 2:10 PM

[3C1-OS-14a-02] Evaluation of active listening in psychotherapy

○Ryoko Hanada[1], Ryutaro Nakajima[2], Masashi Inoue[3], Nobuhiro Furuyama[4], Toshio Irino[5] （1. Tokyo Woman's Christian University, 2. Graduate school of the University of Tokyo, 3. Tohoku Institute of Technology, 4. Waseda University, 5. Wakayama University）

2:10 PM - 2:30 PM

[3C1-OS-14a-03] Predicting Important Utterance based on Fusing Verbal and Nonverbal Information

○Fumio Nihei[1], Yukiko Nakano[2], Yutaka Takase[2] （1. Graduate school of Seikei University, 2. Seikei University）

2:30 PM - 2:50 PM

[3C1-OS-14a-04] Monitoring walking condition by wearable devices and sensor attached trekking stock

○Kenichi Sakaguchi[1], Kanako Nakayama[1], Yu Kudo[1] （1. Technosolution Co., Ltd.）

2:50 PM - 3:10 PM

Oral presentation | Organized Session | [Organized Session] OS-14

[3C2-OS-14b] [Organized Session] OS-14

3:50 PM - 5:30 PM Room C (4F Orchid)

[3C2-OS-14b-01] Social Responses of a Robotic Salesperson Based on the Engagement of Visitors

Jian Zhou[1], Masaya Iwasaki[1], ○Yen-Ru Chin[1], Michelle Geilenberg[1], Mizuki Ikeda[1], Tatsuyuki Kawamura[2], Hideyuki Nakanishi[1] （1. Department of Adaptive Machine Systems, Osaka University, 2. Kyoto Innovation, Inc.）

3:50 PM - 4:10 PM

[3C2-OS-14b-02] Enhancing the Lingering Presence of Remote Speakers by Visual Morphing in Telepresence Robot.

○Hirokazu Yoshida[1], Fumihide Tanaka[1] （1. University of Tsukuba）

4:10 PM - 4:30 PM

[3C2-OS-14b-03] Consideration of Group Discussion Participating Robot Autonomously Performing Head Movement

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

4:30 PM - 4:50 PM

[3C2-OS-14b-04] Predicting User’ s Interest Level in Dialogues with Multimodal Features

○Haruto Nishimoto[1], Kazunori Komatani[1] （1. The Institute of Science and Industrial Research (ISIR), Osaka University）

4:50 PM - 5:10 PM

[3C2-OS-14b-05] Analysis of Influence of Turn-taking by Mutual Action Between Non-speaker

○Takashi Makino[1], Yoshinari Takegawa[1], Keiji Hirata[1] （1. Future University Hakodate）

5:10 PM - 5:30 PM

Room D

Oral presentation | Organized Session | [Organized Session] OS-7

[3D1-OS-7a] [Organized Session] OS-7

1:50 PM - 3:30 PM Room D (4F Cattleya)

[3D1-OS-7a-01] Projection of self-body image in the full body illusion

○Atsushi Yumoto[1], Eiji Otake[2], Sotaro Shimada[2] （1. Meiji University Graduate School, 2. Meiji University ）

1:50 PM - 2:10 PM

[3D1-OS-7a-02] “Time” and “Projection”: Models of

©The Japanese Society for Artificial Intelligence

Others Emerging by Temporal Overlapping

○Tetsuo Ono[1], Kazuki Mizumaru[1] （1. Hokkaido University）

2:10 PM - 2:30 PM

[3D1-OS-7a-03] The model of behavioral change induced by external self-projection using a robotic system.

○Hideyuki Takahashi[1], Hiroshi Ishiguro[1] （1. Osaka university）

2:30 PM - 2:50 PM

[3D1-OS-7a-04] Activating Third-Person Perspective Self on HMD using Constructive Approach

○Kenri Kodaka[1] （1. Graduate School of Design and Architecture, Nagoya-city University）

2:50 PM - 3:30 PM

Oral presentation | Organized Session | [Organized Session] OS-7

[3D2-OS-7b] [Organized Session] OS-7

3:50 PM - 4:50 PM Room D (4F Cattleya)

[3D2-OS-7b-01] Projection in Experience Sharing

○Eimei Oyama[1], Kohei Tokoi[2], Naoji Shiroma[3], Sosuke Nakamura[4], Tomoko Yonemura[5], Natsuo Suzuki[6], Takashi Omori[6], Hiroyuki Okada[6] （1. AIST, 2. Wakayama University, 3. Ibaraki University, 4. Hosei University, 5. Meikai University, 6. Tamagawa University）

3:50 PM - 4:10 PM

[3D2-OS-7b-02] Does literary reading enhance social abilities?

○Hidetsugu Komeda[1], Kenshiro Ichimura[1], Satoru Nishiyama[1], Miho Nishiguchi[1], Tomoya Watanabe[1] （1. Kyoto University）

4:10 PM - 4:30 PM

[3D2-OS-7b-03] A generative model describing the process of projection

○Hiroki Yokoyama[1], Hiroyuki Okada[1] （1. Tamagawa University Brain Science Institute）

4:30 PM - 4:50 PM

Room E

Oral presentation | General Session | [General Session] 8. Soft Computing

[3E2] [General Session] 8. Soft Computing

座長:松井 藤五郎（中部大学）

3:50 PM - 5:50 PM Room E (4F Queen)

[3E2-01] A study on application of satisfaction method of constraints based on their difficulties in many constrained optimization problems

○Kento Niwa[1], Tomohiro Yoshikawa[1] （1. Nagoya University）

3:50 PM - 4:10 PM

[3E2-02] Evolutionary Acquisition of Multiple Block Preserving Outerplanar Graph Patterns by Clustering Outerplanar Graphs

Fumiya Tokuhara[1], ○Tetsuhiro Miyahara[1], Tetsuji Kuboyama[2], Yusuke Suzuki[1], Tomoyuki Uchida[1] （1. Graduate School of Information Sciences, Hiroshima City University, 2. Computer Centre, Gakushuin University）

4:10 PM - 4:30 PM

[3E2-03] Medical image diagnosis of liver cancer using deep RBF GMDH-type neural network

○Tadashi Kondo[1], Shoichiro Takao[1], Sayaka Kondo, Junji Ueno[1] （1. Tokushima University）

4:30 PM - 4:50 PM

[3E2-04] Proposal a new feature evaluation measure for filter type feature subset selection with Evolutionary Algorithm

○Atsushi Kawamura[1], Basabi Chakuraborty[2] （1. Iwate Prefecture University Graduate School, 2. Iwate Prefecture University）

4:50 PM - 5:10 PM

[3E2-05] Three Dimensional Image Registration Using Silhouette-based Objective function and CMA-ES Including Partial Restart with Variable Fixing

○Takuto Shigenobu[1], Takuya Ushinohama[1], Hiroshi Kawasaki[2], Satoshi Ono[1] （1. Kagoshima University, 2. Kyushu University）

5:10 PM - 5:30 PM

[3E2-06] A study on Neural Network with Cell Differentiation Algorithm

○Masayuki Yoshinobu

5:30 PM - 5:50 PM

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

[3E1] [General Session] 13. AI Application

座長:桂樹 哲雄（豊橋技術科学大学）

1:50 PM - 3:10 PM Room E (4F Queen)

[3E1-01] Predicting the protein stability changes upon single-point mutation using BPE Sequence to

©The Japanese Society for Artificial Intelligence

Sequence

○Keisuke Kawano[1], Satoshi Koide[1], Imamura Chie[1] （1. TOYOTA CENTRAL R&D LABS., INC）

1:50 PM - 2:10 PM

[3E1-02] Material discovery by AI

○Seiji Takeda[1], Hsiang Han Hsu[1], Toshiyuki Hama[1], Toshiyuki Yamane[1], Koji Masuda[1], Daiju Nakano[1] （1. IBM Research - Tokyo）

2:10 PM - 2:30 PM

[3E1-03] Automatic Tracking of Honeybee Dancer’ and Follower’ Walking Trajectories

○Shinya Takahashi[1], Sakashi Maeda[1], Koji Hashimoto[1], Naoyuki Tsuruta[1], Hiroyuki Ai[1] （1. Fukuok University）

2:30 PM - 2:50 PM

[3E1-04] Molecular Hypergraph Grammar

○Hiroshi Kajino[1] （1. IBM Research）

2:50 PM - 3:10 PM

Room F

Oral presentation | Organized Session | [Organized Session] OS-12

[3F1-OS-12a] [Organized Session] OS-12

1:50 PM - 2:50 PM Room F (4F Garreria)

[3F1-OS-12a-01] PCSA: Probabilistic Causal Semantic Analysis

○Koji Nomori[1] （1. Analytics Design Lab Inc.）

1:50 PM - 2:10 PM

[3F1-OS-12a-02] Consideration of Visualizing Word Meanings in Word2Vec Space

○Yoshiyuki Mori[1], Yasufumi Takama[1] （1. Tokyo Metropolitan University）

2:10 PM - 2:30 PM

[3F1-OS-12a-03] Personality Estimation of Twitter Users by Using Deep Learning

○Yuki Wakamiya[1], Wataru Sunayama[2], Yuji Hatanaka[2], Kazunori Ogohara[2] （1. Graduate School of Engineering, The University of Shiga Prefecture, 2. School of Engineering, The University of Shiga Prefecture）

2:30 PM - 2:50 PM

Oral presentation | Organized Session | [Organized Session] OS-12

[3F2-OS-12b] [Organized Session] OS-12

3:50 PM - 4:50 PM Room F (4F Garreria)

[3F2-OS-12b-01] A Study on Creation of Supplementary Learning Materials for Foreign Language by Using Comics

○Kohei Matsuoka[1], Yoko Nishihara[1], Ryosuke Yamanishi[1] （1. Ritsumeikan University）

3:50 PM - 4:10 PM

[3F2-OS-12b-02] Consideration of Quantitative Evaluation Method of Scientific Papers based on Text Analysis

○Shota Shimizu[1], Yasufumi Takama[1] （1. Tokyo Metropolitan University）

4:10 PM - 4:30 PM

[3F2-OS-12b-03] Document Writing Support by Visualizing Favorable Words and Malicious Words for Building Good Relationships

○Shota Ihori[1], Wataru Sunayama[1], Yuji Hatanaka[1], Kazunori Ogohara[1] （1. The University of Shiga Prefecture）

4:30 PM - 4:50 PM

Room G

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

[3G1] [General Session] 9. NLP / IR

座長:星野 綾子（日本電気株式会社）

1:50 PM - 3:30 PM Room G (5F Ruby Hall Hiten)

[3G1-01] A Method for Detecting Overgeneralized Be-Verb based on Subject-compliment Identification

○Ryo Nagata[1,2], Shoya Nishite[1], Hokuto Ototake[3] （1. Konan University, 2. JST,PRESTO, 3. Fukuoka University）

1:50 PM - 2:10 PM

[3G1-02] Semantic Graph-based Simple Semantic Textual Similarity Metrics

○Takaaki Tanaka[1], Masaaki Nagata[1], Yuki Arase[2], Makoto Onizuka[2] （1. NTT Communication Science Laboratories, 2. Osaka University Graduate School of Information Science and Technology）

2:10 PM - 2:30 PM

[3G1-03] Extraction of rare cause-result expressions from summary of financial statements

○Hiroyuki Sakai[1], Hiroki Sakaji[2], Risa Murono[1], Ryozo Kitajima[1], Jason Bennett[3] （1. Seikei University, 2. The

©The Japanese Society for Artificial Intelligence

University of Tokyo, 3. Sumitomo Mitsui Asset Management Company, Limited）
2:30 PM - 2:50 PM

[3G1-04] Automatic alignment of figures and tables with texts in scientific literatures
○Hiroto Shinoda[1], Ichiro Nakaema[1], Hidetsugu Nanba[1], Toshiyuki Takezawa[1] （1. Hiroshima City University）
2:50 PM - 3:10 PM

[3G1-05] Semantic Parsing in ccg2lambda and its Application to Financial Document Processing
Yasunori Hokazono[4], Takahiro Hasegawa[5], Kazuki Watanabe[2], ○Kana Manome[1], Yukiko Yana[1], Hitomi Yanaka[2], Ribeka Tanaka[1], Pascual Mart'inez-G'omez[3], Koji Mineshima[1], Daisuke Bekki[1] （1. Ochanomizu University, 2. University of Tokyo, 3. National Institute of Advanced Industrial Science and Technology, 4. Nomura Research Institute, 5. Omega Partners）
3:10 PM - 3:30 PM

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

[3G2] [General Session] 9. NLP / IR

座長:西田 京介（NTT）
3:50 PM - 5:30 PM Room G (5F Ruby Hall Hiten)

[3G2-01] Proposal of Metrics Measuring Coherence Based on Sentence Similarity Graph with Document Structure
○Mana Ihori[1], Atsuko Tominaga[2], Yoshinari Takegawa[2], Keiji Hirata[2] （1. Future University Hakodate Graduate School, 2. Future University Hakodate）
3:50 PM - 4:10 PM

[3G2-02] Textual Evidence Inference for Debating AI
○Kohsuke Yanai[1], Misa Sato[1], Toshihiko Yanase[1], Yuta Koreeda[1] （1. Hitachi, Ltd.）
4:10 PM - 4:30 PM

[3G2-03] Automatically building English synonym dictionaries by using European Patent publications
○Koji Marusaki[1], Kazuhiko Tsuda[1] （1. Graduate School of Business Sciences, University of TSUKUBA）
4:30 PM - 4:50 PM

[3G2-04] Continuous Representation of Confusion Networks for Neural Spoken Utterance Classification robust to Automatic Speech Recognition Errors
○Ryo Masumura[1], Yusuke Ijima[1], Taichi Asami[1], Hirokazu Masataki[1], Ryuichiro Higashinaka[1] （1. NTT Corporation）
4:50 PM - 5:10 PM

[3G2-05] Lexical Simplification Using Word Embedding to Approximate Word Sense
Shohei Takada[1], ○Yuki Arase[1], Satoru Uchida[2] （1. Graduate School of Information Science and Technology, Osaka University, 2. Faculty of Languages and Cultures, Kyushu University）
5:10 PM - 5:30 PM

Room H

Oral presentation | Organized Session | [Organized Session] OS-25

[3H1-OS-25a] [Organized Session] OS-25

1:50 PM - 3:30 PM Room H (10F Sky Hall)

[3H1-OS-25a-01] The comparison of AI Ethics Guidelines among Japan, the US and Europe, focusing on issues related to national character
○Keiko Uemura[1], Akio Kozato[1], Takahiro Shiga[1], Keiichiro Hayakawa[1] （1. TOYOTA CENTRAL R&D LABS.,INC.）
1:50 PM - 2:10 PM

[3H1-OS-25a-02] Challenges for AI which promotes humans' ethical behaviors
○Keiko Fukuhara[1] （1. Nagoya University）
2:10 PM - 2:30 PM

[3H1-OS-25a-03] Can AI Involve AI Engineers in Ethical Design Activities?
○Kaira Sekiguchi[1], Koichi Hori[1,2] （1. Graduate School of Engineering, The University of Tokyo, 2. Center for Advanced Intelligence Project, RIKEN）
2:30 PM - 2:50 PM

[3H1-OS-25a-04] Extraction of new guideline items from the view point of ELSI (Ethics, Legal, Social Issues) for service utilized AI
○Shin'ichi Fukuzumi[1], Mariko Jinno[1], Kasumi Inagaki[1], Hiroko Yasu[1], Toshihiko Hiroaki[1], Haruka Maeda[2], Takuya Mizukami[2], Osamu Sakura[2] （1. NEC Corporation, 2. University of Tokyo）
2:50 PM - 3:10 PM

[3H1-OS-25a-05] Design dialogue and community to

©The Japanese Society for Artificial Intelligence

discuss IEEE “*Ethically Aligned Design*”

○Arisa Ema[1], Katsue Nagakura[2], Fumiko Kudo[3] （1. The University of Tokyo, 2. Science Writer, 3. Makaira KK）

3:10 PM - 3:30 PM

Oral presentation | Organized Session | [Organized Session] OS-25

[3H2-OS-25b] [Organized Session] OS-25

3:50 PM - 5:10 PM Room H (10F Sky Hall)

[3H2-OS-25b-01] A Consideration on Anonymization of Personal Information to Establish Both Anonymity and Usability Based on Residuals

○Soichiro Morishita[1] （1. CyberAgent, Inc.）

3:50 PM - 4:10 PM

[3H2-OS-25b-02] A Study on the Ethical Aspects of Design Principles of Autonomous Robots from Sci-fi Movie

○Shigeyoshi IIZUKA[1], Chieko Takamori[2], Miwa Yamaura[3] （1. Kanagawa University, 2. AmidA Co., Ltd., 3. YAMAGATA INTECH Corporation）

4:10 PM - 4:30 PM

[3H2-OS-25b-03] Artificial intelligence and journalism ethics with a focus on "fake news"

○Fumiko Kudo[1] （1. Makaira KK）

4:30 PM - 4:50 PM

[3H2-OS-25b-04] “It’ s Public, and also Private”: An Analysis of Flaming Fan Studies

○Hirotaka Osawa[1], Arisa Ema[2], Rena Saijo[3], Akinori Kubo[4], Nobutsugu Kanzaki[5], Minao Kukita[6], Ryutaro Ichise[7], Hiromitsu Hattori[8], Naonori Akiya[9], Takushi Otani[10] （1. University of Tsukuba, 2. The University of Tokyo, 3. Hokkaido University, 4. Hitotsubashi University, 5. Nanzan University, 6. Nagoya University, 7. National Institute of Informatics, 8. Ritsumeikan University, 9. Yamaguchi University, 10. Kibi International University）

4:50 PM - 5:10 PM

Room J

Oral presentation | General Session | [General Session] 7. Agent

[3J1] [General Session] 7. Agent

座長:福田 直樹（静岡大学）

1:50 PM - 3:30 PM Room J (2F Royal Garden B)

[3J1-01] k-partition problem with uncertainty of agents' participation

Kazuki Nomoto[1], ○Yuko Sakurai[2], Yoshio Okamoto[3,4], Makoto Yokoo[1,4] （1. Kyushu University, 2. National Institute of Advanced Industrial Science and Technology, 3. The university of Electro-Communications, 4. RIKEN, Center for Advanced Intelligence Project AIP）

1:50 PM - 2:10 PM

[3J1-02] Proposal of traffic signal control system by multi agent using Deep Q-Network

○Yohei Kanzaki[1], Kikue Sato[1], Eichi Takaya[1], Ryo Pgawa[2], Yuta Ashihara[1,3], Satoshi Kurihara[1] （1. Keio University, 2. The University of Electro-Communications, 3. XCompass Ltd.）

2:10 PM - 2:30 PM

[3J1-03] Iterative Greedy Combinatorial Auction for Self Interested Multi-Agent Path nding

○Manao Machida[1] （1. NEC Corporation）

2:30 PM - 2:50 PM

[3J1-04] Estimation of people flow considering time delay

○Hiroshi Kiyotake[1], Masahiro Kohjima[1], Tatsushi Matsubayashi[1], Hiroyuki Toda[1] （1. NTT Service Evolution Laboratory）

2:50 PM - 3:10 PM

[3J1-05] Modeling Agents from the Perspective of Human Umwelt towards AI Safety

○Yosuke Fukuchi[1], Masahiko Osawa[1,2], Hiroshi Yamakawa[3,4], Michita Imai[1] （1. Graduate School of Science and Technology, Keio University, 2. Research Fellow of Japan Society for the Promotion of Science (DC1), 3. DWANGO Co., ltd Dwango Artificial Intelligence Laboratory, 4. The Whole Brain Architecture Initiative）

3:10 PM - 3:30 PM

Oral presentation | General Session | [General Session] 7. Agent

[3J2] [General Session] 7. Agent

座長:金森 亮（名古屋大学）

3:50 PM - 5:30 PM Room J (2F Royal Garden B)

[3J2-01] A Study of Optimization Method Considering Bottlenecks in Asymmetric Constraint Optimization Problem

©The Japanese Society for Artificial Intelligence

○Toshihiro Matsui[1] (1. Nagoya Institute of Technology)
3:50 PM - 4:10 PM

[3J2-02] Impact of Ego-Ships in Ship Collision Avoidance using Distributed Stochastic Search Algorithm
Hiroki Karato[1], ○Katsutoshi Hirayama[1], Tenda Okimoto[1], Donggyun Kim[2] (1. Kobe University, 2. Beijing Institute of Technology)
4:10 PM - 4:30 PM

[3J2-03] Modeling of Classroom SNSs and Classroom Network Based on the Socion Theory
○Kosuke Naito[1], Shohei Kato[1,2] (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)
4:30 PM - 4:50 PM

[3J2-04] Continuous conversation with two-robot coordination
○Hiroaki Sugiyama[1], Masahiro Mizukami[1], Hiromi Narimatsu[1] (1. NTT Communication Science Labs.)
4:50 PM - 5:10 PM

[3J2-05] A Preliminary Approach on a Coalition Formation Simulator with Inertia on Continuous Cooperative Games
○Masaaki Horie[1], Naoki Fukuta[1] (1. Shizuoka University)
5:10 PM - 5:30 PM

Room K

Oral presentation | Organized Session | [Organized Session] OS-18

[3K1-OS-18a] [Organized Session] OS-18
1:50 PM - 3:10 PM Room K (3F Azisai Mokuren)

[3K1-OS-18a-01] High-Speed Calculation in Structural Analysis by Reinforcement Learning
○Soshi Nakamura[1], Takuya Suzuki[2] (1. McGill University, 2. Takenaka Corporation)
1:50 PM - 2:10 PM

[3K1-OS-18a-02] A simulation of total evacuation drill in office building using multi agent model
○Takaki Tojo[1], Mineko Imanishi[1], Akihide Jo[1] (1. Takenaka Corporation)
2:10 PM - 2:30 PM

[3K1-OS-18a-03] Damage evaluation of building via convolutional neural network
○Takenori Hida[1], Taro Yaoyama[1], Tsuyoshi Takada[1] (1. The University of Tokyo)
2:30 PM - 2:50 PM

[3K1-OS-18a-04] Image Recognition Examination for Classification of Reinforcing Bar
○Kyosuke Ichikawa[1], Go Sakaguchi[1] (1. Ark Information System)
2:50 PM - 3:10 PM

Oral presentation | Organized Session | [Organized Session] OS-18

[3K2-OS-18b] [Organized Session] OS-18
3:50 PM - 5:10 PM Room K (3F Azisai Mokuren)

[3K2-OS-18b-01] Prototype and implementation of privacy-sensitive human flow measurement system using depth sensor
○Takanobu Otsuka[1], Tomohiro Nishida[1], Daichi Shibata[1], Takayuki Ito[1] (1. Nagoya Institute of Technology)
3:50 PM - 4:10 PM

[3K2-OS-18b-02] Damage Detection of Wooden Structural Members Using Piezoelectric Sensor and Autoencoder for Structural Health Monitoring
○Natsuhiko Sakiyama[1], Ayumu Ushigome[1], Sakuya Kishi[1], Akihiro Kishi[1], Yoichiro Hashizume[1], Takashi Nakajima[1], Takumi Ito[1] (1. Tokyo University of Science)
4:10 PM - 4:30 PM

[3K2-OS-18b-03] Charge Control of Regenerative Power for Energy-Saving Railway Systems
○Yasuhiro Yoshida[1], Sachiyo Arai[1] (1. Chiba University)
4:30 PM - 4:50 PM

[3K2-OS-18b-04] Microscopic Simulation of Coupled Traffic and Electric Grids
○Hideaki Uchida[1], Hideki Fujii[1], Shinobu Yoshimura[1] (1. The University of Tokyo)
4:50 PM - 5:10 PM

Room L

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

[3L2] [General Session] 2. Machine Learning
座長:木村 昭悟（NTT）
3:50 PM - 5:30 PM Room L (3F Sapphire Hall Asuka)

©The Japanese Society for Artificial Intelligence

[3L2-01] Fast point set registration using a statistical shape model

○Osamu Hirose[1] （1. Kanazawa University）

3:50 PM - 4:10 PM

[3L2-02] Depth Image Prediction for Transparent Objects and its Application to Home Assistant Robot Based on Automatic Training Data Generation Using Mesh Model

○Yuto Uchimi[1], Kentaro Wada[1], Kei Okada[1], Masayuki Inaba[1] （1. The University of Tokyo）

4:10 PM - 4:30 PM

[3L2-03] Image Reconstruction for Super Resolution Microscope Using Recursive Bayesian Computation

○Shunsuke Kido[1], Takashi Washio[1], Tetsuichi Wazawa[1], Takeharu Nagai[1] （1. The Institute of Scientic and Industrial Research, Osaka University）

4:30 PM - 4:50 PM

[3L2-04] Examination of object tracking method for space-temporal data based on greedy EM algorithm

○Ryo Hayashi[1], Rie Honda[1] （1. Kochi University）

4:50 PM - 5:10 PM

[3L2-05] Embedding and retrieval of images and text data using probability distribution

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

5:10 PM - 5:30 PM

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

[3L1] [General Session] 3. Data Mining

座長:大澤 昇平（東京大学）

1:50 PM - 3:30 PM Room L (3F Sapphire Hall Asuka)

[3L1-01] Trip Prediction in Bike Sharing Systems

○Maya Okawa[1], Takeshi Kurashima[1], Yusuke Tanaka[1], Hiroyuki Toda[1] （1. NTT）

1:50 PM - 2:10 PM

[3L1-02] Autoregressive Tensor Factorization for Spatio-temporal Predictions

○Koh Takeuchi[1,2], Hisashi Kashima[2,3], Naonori Ueda[1,3] （1. NTT Communication Science Laboratories, 2. Graduate School of Informatics, Kyoto University, 3. RIKEN Center for Advanced Intelligence Project）

2:10 PM - 2:30 PM

[3L1-03] Online prediction of self-adaptive memory over data stream

○Akihiro Yamaguchi[1], Shigeru Maya[1], Tatsuya Inagi[1], Ken Ueno[1] （1. Toshiba Corporation）

2:30 PM - 2:50 PM

[3L1-04] Improve Sales Forecasting with Customer Behavior Analysis

○Yusuke Yamaura[1], Yusuke Yamaura[1], Takeshi Onishi[1] （1. Fuji Xerox Co., Ltd. Japan）

2:50 PM - 3:10 PM

[3L1-05] Embedding special-day effects for demand prediction

○Takuji Tahara[1], Yiou Wang[1], Keiichi Nemoto[1] （1. Fuji Xerox Co., Ltd.）

3:10 PM - 3:30 PM

Room O

Oral presentation | Organized Session | [Organized Session] OS-1

[3O1-OS-1a] [Organized Session] OS-1

1:50 PM - 3:30 PM Room O (2F Kaimon)

[3O1-OS-1a-01] Morality in Japanese Lyrics

○Kazutoshi Sasahara[1], Yasuhiro Taguchi[2] （1. Nagoya University, 2. Aichi University）

1:50 PM - 2:10 PM

[3O1-OS-1a-02] Bullied-Experience Talks in Online Communications

Masanori Takano[1], ○Takaaki Tsunoda[1] （1. CyberAgent, Inc.）

2:10 PM - 2:30 PM

[3O1-OS-1a-03] Analysis of readers by Classification of Articles in a News Service from Network Structures

○Atom Sonoda[1], Fujio Toriumi[1], Hiroto Nakajima[2], Miyabi Gouji[2] （1. The University of Tokyo, 2. Nikkei Inc.）

2:30 PM - 2:50 PM

[3O1-OS-1a-a] OS invited talk

○Nobuo Sato[1] （1. Hitachi, Ltd.）

2:50 PM - 3:30 PM

Oral presentation | Organized Session | [Organized Session] OS-1

[3O2-OS-1b] [Organized Session] OS-1

3:50 PM - 5:30 PM Room O (2F Kaimon)

[3O2-OS-1b-01] Analysis of Moving-time Patterns from Entry and Exit Data of Office Workers

○Seidai Kojima[1], Hayato Ishigure[1], Miwa

©The Japanese Society for Artificial Intelligence

Sakata[1], Atsuko Mutoh[1], Koichi Moriyama[1], Nobuhiro Inuzuka[1] （1. Department of Computer Science, Graduate School of Engineering, Nagoya Institute of Technology）
3:50 PM - 4:10 PM

[3O2-OS-1b-02] Adaptive experimental designs and method of estimating causal effect
〇Hirotoshi Yanagi[1], Takahiro Hoshino[2], Keisuke Takahata[1] （1. Graduate School of Economics, Keio University, 2. Faculty of Economics, Keio University）
4:10 PM - 4:30 PM

[3O2-OS-1b-03] Opinion Formation Model Including Pressure and Silence Caused by Inconsistency
〇Sonoko Kimura[1], Kimitaka Asatani[2], Toshiharu Sugawara[1] （1. Waseda University, 2. The University of Tokyo）
4:30 PM - 4:50 PM

[3O2-OS-1b-04] Analysis of differences in viewing behavior of politics news by age
〇Yoshifumi Seki[1] （1. Gunosy Inc）
4:50 PM - 5:10 PM

[3O2-OS-1b-05] Conflict mineral regulations based on network structure of global supply chain
〇Takayuki Mizuno[1], Takaaki Ohnishi[2], Tsutomu Watanabe[2] （1. NII, 2. Univ. of Tokyo）
5:10 PM - 5:30 PM

Room Z

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

[3Z1] [General Session] 13. AI Application

座長:日和 悟（同志社大学）
1:50 PM - 3:10 PM Room Z (3F Matsu Take)

[3Z1-01] Linear independent non-negative matrix factorization for automatic decomposition of experimental spectra
〇Nobuaki Kikkawa[1], Akitoshi Suzumura[1], Shin Tajima[1], Shunsuke Yamakawa[1], Ryoji Asahi[1] （1. Toyota Central R&D Labs., Inc.）
1:50 PM - 2:10 PM

[3Z1-02] A universal 3D voxel descriptor for solid-state materials informatics with convolutional neural networks
〇Seiji Kajita[1], Nobuko Ohba[1], Ryoji Asahi[1] （1. Toyota Central R&D Labs. Inc.）
2:10 PM - 2:30 PM

[3Z1-03] Visualization of SEM/EBSD Features of Ionic Conductivity with Convolutional Neural Networks
〇Ruho Kondo[1], Shunsuke Yamakawa[1], Yumi Masuoka[1], Shin Tajima[1], Ryoji Asahi[1] （1. Toyota Central R&D Labs., Inc.）
2:30 PM - 2:50 PM

[3Z1-04] Infra Machine Learning for Predictive Maintenance via Classification Models
〇Takato Yasuno[1] （1. Yachiyo engineering Co., Ltd.）
2:50 PM - 3:10 PM

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

[3Z2] [General Session] 13. AI Application

座長:井上 中順（東京工業大学）
3:50 PM - 5:30 PM Room Z (3F Matsu Take)

[3Z2-01] Mindful Driving:Analysis of the attention states during simulated driving using fNIRS
〇Yusuke Fujiwara[1], Satoru Hiwa[2], Tomoyuki Hiroyasu[2] （1. Graduate School of Life and Medical Sciences, Doshisha University, 2. Faculty of Life and Medical Sciences, Doshisha University）
3:50 PM - 4:10 PM

[3Z2-02] Acceleration of Nonparametric Bayesian Double Articulation Analyzer
〇Ryo Ozaki[1], Tadahiro Taniguchi[1] （1. Ritsumeikan University）
4:10 PM - 4:30 PM

[3Z2-03] Experimenal Images Identificaton with Simulation Images and Finetuning for Objects Identificaton of Ground Penetrating Radar Using Deep Learning
〇Jun Sonoda[1], Tomoyuki Kimoto[2] （1. National Institute of Technology, Sendai College, 2. National Institute of Technology, Oita College）
4:30 PM - 4:50 PM

[3Z2-04] Efficiency of Traffic Flow with Mutual Concessions of Autonomous Cars Using Deep Q-Network
〇Ichitaro Ogawa[1], Soichiro Yokoyama[1], Toyohasha Yanashita[1], Hidenori Kawamura[1], Akira Sakatoku[2], Tadashi Yanagihara[2], Tomohiko Ogishi[2], Hideaki Tanaka[2] （1. Hokkaido University, 2. KDDI Research

©The Japanese Society for Artificial Intelligence

Inc.）

4:50 PM - 5:10 PM

[3Z2-05] Fontender: A Method to Design Text by Font Fusion for Comic Creation

○Junki Saito[1], Satoshi Nakamura[1] （1. Meiji University）

5:10 PM - 5:30 PM

©The Japanese Society for Artificial Intelligence

Thu. Jun 7, 2018

Room A

Special session | Plenary session | Invited talk

[3A0] 「人工知能は未来の経済をどう変えるか？」(井上 智洋)
11:30 AM - 12:40 PM Room A (4F Emerald Hall)

[3A0-01] 「人工知能は未来の経済をどう変えるか？」
Tomohiro Inoue （1. 駒澤大学経済学部 准教授）
11:30 AM - 12:40 PM

Special session | Other | Participants' networking meeting

[3A3] 参加者交流会
6:00 PM - 7:30 PM Room A (4F Emerald Hall)

[3A3-01] Participants' networking meeting
6:00 PM - 7:30 PM

Room F

Special session | Night / Luncheon | Luncheon seminar

[3F4] ランチョンセミナー4((株)電通)
12:50 PM - 1:40 PM Room F (4F Garreria)

[3F4-01] AI時代の「クリエーティビティ」を探る
福田 宏幸 （株式会社電通）
12:50 PM - 1:40 PM

Room I

Special session | Tutorial | Tutorial

[3I1] 「"深層学習時代の" ゼロから始める自然言語処理」(荒瀬 由紀)
座長:小林 一郎（お茶の水女子大学）
1:50 PM - 3:30 PM Room I (2F Royal Garden A)

[3I1-01] 「"深層学習時代の" ゼロから始める自然言語処理」
Yuki Arase （1. 大阪大学大学院情報科学研究科）
1:50 PM - 3:30 PM

Special session | Tutorial | Tutorial

[3I2] 「実践 Deep Learning – いまさら聞けない入門編」(2) (中山 浩太郎)
座長:植野 研（株式会社東芝）
3:50 PM - 5:30 PM Room I (2F Royal Garden A)

[3I2-01] 「実践 Deep Learning – いまさら聞けない入門編」（後編）
Kotaro Nakayama （1. 東京大学 工学系研究科 技術経営戦略学専攻）
3:50 PM - 5:30 PM

Special session | Night / Luncheon | Luncheon seminar

[3I4] ランチョンセミナー6(インテル(株))
12:50 PM - 1:40 PM Room I (2F Royal Garden A)

[3I4-01] 高い電力効率、低遅延で演算処理を高速化する手法 ～インテル® FPGAと Xeon® プロセッサー～
12:50 PM - 1:40 PM

Room L

Special session | Night / Luncheon | Luncheon seminar

[3L4] ランチョンセミナー5(日本マイクロソフト(株))
12:50 PM - 1:40 PM Room L (3F Sapphire Hall Asuka)

[3L4-01] マイクロソフトの深層学習への取り組み
田丸 健三郎 （日本マイクロソフト株式会社）
12:50 PM - 1:40 PM

Room M

Special session | Proposed session | Student session

[3M1] 「最新の人工知能技術は，未解決問題をどう解決に導くか」(溝口 理一郎，松尾 豊)
1:50 PM - 3:30 PM Room M (2F Amethyst Hall Hoo)

[3M1-01] 「最新の人工知能技術は，未解決問題をどう解決に導くか」
Riichiro Mizoguchi, Yutaka Matsuo （1. 北陸先端科学技術大学院大学，2. 東京大学）
1:50 PM - 3:30 PM

Special session | Industrial session | Industrial session

[3M2] インダストリアル(4)
座長:脇谷 勉（本田技術研究所）
3:50 PM - 5:30 PM Room M (2F Amethyst Hall Hoo)

[3M2-01] Industrial session (4)
3:50 PM - 5:30 PM

Room N

Special session | Proposed session | Proposed session

[3N1] KS-7 機械知能の理解にむけて ー物理学との対話を通してー
1:50 PM - 3:30 PM Room N (2F Sakurajima)

[3N1-01] KS-7 機械知能の理解にむけて ー物理学との対話を通してー
1:50 PM - 3:30 PM

Special session | Proposed session | Proposed session

©The Japanese Society for Artificial Intelligence

[3N2] KS-4 インセンティブ設計科学

3:50 PM - 5:30 PM Room N (2F Sakurajima)

[3N2-01] KS-4 インセンティブ設計科学

3:50 PM - 5:30 PM

©The Japanese Society for Artificial Intelligence

Poster presentation | General Session | Interactive

[3Pin1] インタラクティブ(1)

Thu. Jun 7, 2018 9:00 AM - 10:40 AM Room P (4F Emerald Lobby)

[3Pin1-01] Optimization method for Educational Application of Structural Engineering

○Takuya Suzuki[1], Keiichi Iguchi[2], Takuya Kinoshita[1], Akihiro Ishikawa[2] （1. Takenaka Corporation, 2. HEROZ）

9:00 AM - 10:40 AM

[3Pin1-02] Benchmark Functions for Cooperative Coevolution and Analysis of Influence by Dynamic Problem Decomposition

○Yuki Nakashima[1], Jun-ichi Matsuoka[1], Asuka Hisatomi[1], Satoshi Ono[1] （1. Kagoshima University）

9:00 AM - 10:40 AM

[3Pin1-03] Incorporating Knowledge Graph Embeddings into Latent Variable Models

○Naoya Takeishi[1,2], Kosuke Akimoto[1] （1. The University of Tokyo, 2. RIKEN）

9:00 AM - 10:40 AM

[3Pin1-04] Covariate shift bias correction induced by action

○Ryota Higa[1] （1. NEC Corporation）

9:00 AM - 10:40 AM

[3Pin1-05] Batch Reinforcement Learning for Linearly Solvable MDP

○Tomoki Nishi[1], Keisuke Otaki[1], Takayoshi Yoshimura[1] （1. Toyota Central R&D Labs., Inc.）

9:00 AM - 10:40 AM

[3Pin1-06] Cappuccino: Bootstrapping from Structural Data

○Ryo Hanafusa[1], Masafumi Oyamada[2] （1. Kwansei Gakuin University, 2. NEC Corporation）

9:00 AM - 10:40 AM

[3Pin1-07] Non-negative matrix factorization with information expansion using item class information

○Katsuhiko Murakami[1] （1. The University of Tokyo）

9:00 AM - 10:40 AM

[3Pin1-08] Proposal of direct policy search using reduction of policy parameters by principal component analysis

○Yuuki Murata[1], Megumi Miyashita[1], Shiro Yano[1], Toshiyuki Kondo[1] （1. Tokyo University of Agriculture and Technology）

9:00 AM - 10:40 AM

[3Pin1-09] Curriculum Learning for Similar Learning Cases

○Yuta Ota[1], Yuta Taki[1] （1. KOZO KEIKAKU ENGINEERING Inc.）

9:00 AM - 10:40 AM

[3Pin1-10] Graph Feature Extraction Using Graph Fragment Decision Trees

○Haruki Sakagami[1], Ichigaku Takigawa[1], Hiroki Arimura[1] （1. Hokkaido University）

9:00 AM - 10:40 AM

[3Pin1-11] Objective Correction for Policy Improvement under Entropy Regularization

○Ryo Iwaki[1], Minoru Asada[1] （1. Osaka University）

©The Japanese Society for Artificial Intelligence

9:00 AM - 10:40 AM

[3Pin1-12] Experimental evaluation of Time-Series Gradient Boosting Tree with Time-Series Benchmark datasets

○Mitsuyoshi Imamura[1,2], Kei Nakagawa[1,2], Kenichi Yoshida[1] （1. University of Tsukuba, 2. Nomura Asset Management Ltd.）

9:00 AM - 10:40 AM

[3Pin1-13] Batch Random Walk for GPU-Based Classical Planning(Extended Abstract)

○Ryo Kuroiwa[1], Alex Fukunaga[1] （1. the University of Tokyo）

9:00 AM - 10:40 AM

[3Pin1-14] Learning to resample for time-series generative model

○Takaaki Kaneko[1], Shohei Ohsawa[1], Yutaka Matsuo[1] （1. Department of Technology Management for Innovation, The University of Tokyo）

9:00 AM - 10:40 AM

[3Pin1-15] End-of-Query Detection in Text Chat System

○Shun Tanaka[1] （1. CyberAgent, Inc.）

9:00 AM - 10:40 AM

[3Pin1-16] Debating AI: Counterargument Generation Based on Textual Supportiveness Recognition

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

9:00 AM - 10:40 AM

[3Pin1-17] Associative Dialog System for Recipe Recommendation Using Food Knowledge

○Katsuyoshi Yamagami[1,2], Mitsuru Endo[2], Hirokazu Kiyomaru[3], Sadao Kurohashi[3] （1. Advanced Industrial Science and Technology (AIST), 2. Panasonic Corporation, 3. Kyoto University）

9:00 AM - 10:40 AM

[3Pin1-18] Analysis of work motivation by persuasion in dialogue

○Takuya Mizukami[1] （1. Waseda University）

9:00 AM - 10:40 AM

[3Pin1-19] Acquiring Utterance Candidates for Chat-oriented Dialogue Systems from Wikipedia Based on a State Space Model

○Tomoki Matsumoto[1], Masato Sakai[1], Mikio Nakano[2] （1. Nextremer Co., Ltd., 2. Honda Research Institute Japan Co., Ltd.）

9:00 AM - 10:40 AM

[3Pin1-20] Knowledge Graph Expansion for Constructing Dialogue Systems Responding to Queries about Unknown Attributes

○Yuma Fujioka[1], Kazunori Komatani[1] （1. The Institute of Scientific and Industrial Research, Osaka University）

9:00 AM - 10:40 AM

[3Pin1-21] Utterance understanding and emotion generation in a dialogue system for children

○Kento Yamamoto[1], Syunya Omura[2], Ryo Nemoto[2], Shiori Wada[1], Toru Sugimoto[2] （1. Graduate School of Engineering and Science,Shibaura Institute of Technology, 2. College of

©The Japanese Society for Artificial Intelligence

Engineering,Shibaura Institute of Technology）
9:00 AM - 10:40 AM

[3Pin1-22] Augmentation of Dialogue Database by Generating Interrogative Sentences Using Templates

○Yota Osanai[1], Tomoya Ogata[1], Mamoru Komachi[1], Eri Sato-Simokawara[1], Kazuyoshi Wada[1], Toru Yamaguchi[1], Tomoya Takatani[2] （1. Tokyo Metropolitan University, 2. TOYOTA MOTOR CORPORATION）
9:00 AM - 10:40 AM

[3Pin1-23] Utterance Intention Classification and Database Construction for Conversational News Delivery System

○Katsuya Yokoyama[1], Hiroaki Takatsu[1], Hiroshi Honda[2], Shinya Fujie[1,3], Yoshihiko Hayashi[1], Tetsunori Kobayashi[1] （1. Waseda University, 2. Honda R&D Co., Ltd, 3. Chiba Institute of Technology）
9:00 AM - 10:40 AM

[3Pin1-24] A proposal of automatic negotiation simulator Jupiter for negotiation agent using machine learning.

○Tomoya Fukui[1], Takayuki Ito[1] （1. Nagoya Institute of Technology）
9:00 AM - 10:40 AM

[3Pin1-25] An analysis of multilingual communication for solving global environmental issues

○Yuqi Liao[1], Bo Wang[1], Yuya Ieiri[1], Yuu Nakajima[2], Reiko Hishiyama[1] （1. Waseda University, 2. Toho University）
9:00 AM - 10:40 AM

[3Pin1-26] Premise generation based on argumentation schemes for dialogue systems

○Koh Mitsuda[1], Ryuichiro Higashinaka[1], Taichi Katayama[1], Junji Tomita[1] （1. NTT）
9:00 AM - 10:40 AM

[3Pin1-27] Metaphor creation using corpus and thesaurus

○Ryoga Sato[1], Toru Sugimoto[1] （1. Shibaura Institute of Technology）
9:00 AM - 10:40 AM

[3Pin1-28] Uncombined Elements in an Integrated Narrative Generation System and Expanding Conceptual Dictionaries by Attribute Information

○Jumpei Ono[1], Takuya Ito[2], Takashi Ogata[2] （1. Graduate School of Iwate Prefectural University, 2. Iwate Prefectural University）
9:00 AM - 10:40 AM

[3Pin1-29] Research on Sharing of Robotics Skills

○Guilherme de Campos Affonso[1], Kei Okada[1], Masayuki Inaba[1] （1. Univ. of Tokyo）
9:00 AM - 10:40 AM

[3Pin1-30] Hybrid Policy Gradient for Deep Reinforcement Learning

○praveen singh Thakur[1], Masaru Sogabe[1], Katsuyoshi Sakamoto[2], Koichi Yamaguchi[2], Dinesh Bahadur Malla[2], Shinji Yokogawa[2], Tomah Sogabe[1,2] （1. GRID Inc., 2. The University of Electro-communications）
9:00 AM - 10:40 AM

[3Pin1-31] A mobile robot based on real-time reinforcement learning using human evaluation

©The Japanese Society for Artificial Intelligence

○Ken Yamane[1], Hiromasa Uetsuki, Hideyasu Yokomatsu[2] （1. Teikyo University, 2. Taito Corporation）

9:00 AM - 10:40 AM

[3Pin1-32] Study on evolutionary calculation by real world feedback from physical experiment determining the shape of an underwater robot.

○Ryota Nakamura[1], Satoru Inoue[1] （1. Saitama Institute of Technology）

9:00 AM - 10:40 AM

[3Pin1-33] Person Re-identification by Online Transfer Learning for Mobile Robot using Region-based CNN and Triplet Loss

○Yuki Murata[1], Masayasu Atsumi[1] （1. Soka University Graduate School of Engineering）

9:00 AM - 10:40 AM

[3Pin1-34] An AI game player trained by a genetic algorithm that avoids bombardments in a shooting game

○Shizuma Namekawa[1], Taro Tezuka[1] （1. University of Tsukuba）

9:00 AM - 10:40 AM

[3Pin1-35] Action acquisition by Memory Reinforcement Learning useing a prior knowledge

○Yuna Inamori[1], Tsubasa Hirakawa[1], Takayoshi Yamashita[1], Hironobu Fujiyoshi[1], Ryota Kashihawa[2], Masaki Inaba[2], Naoki Nitanda[2] （1. Chubu University, 2. DENSO CORPORATION）

9:00 AM - 10:40 AM

[3Pin1-36] Neural Headline Generation with Self-Training

Shintaro Takemae[2], Kazuma Murao[1], ○Taichi Yatsuka[1], Hayato Kobayashi[1,3], Masaki Noguchi[1], Hitoshi Nishikawa[2], Takenobu Tokunaga[2] （1. Yahoo Japan Corporation, 2. Tokyo Institute of Technology, 3. RIKEN AIP）

9:00 AM - 10:40 AM

[3Pin1-37] Security Reinforcement for ATM by Using Image Sensing

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

9:00 AM - 10:40 AM

[3Pin1-38] Study on Image Recognition in Tank/Hold of Ship

○Masaru Hirakata[1], Ma Chong[1], Tomoyuki Taniguchi[1] （1. National Institute of Maritime, Port and Aviation Technology）

9:00 AM - 10:40 AM

[3Pin1-39] Prediction of Bascketball Free Throw Scoring by OpenPose

○Masato Nakai[1], Yoshihiko Tunoda[1], Caidong Sun[1], Hideki Murakoshi[1], Hisashi Hayashi[1], Tuyoshi Aziro[1] （1. Advanced Institute Industrial Technology）

9:00 AM - 10:40 AM

[3Pin1-40] BGM Recommendation System Considering the Atmosphere

○Kikue Sato[1], Shiori Sakai[1], Eichi Takaya[2], Kazuki Yamauchi[3], Hayato Oya[3], Satoshi Kurihara[2] （1. The University of Electro-Communications, 2. Keio University, 3. RecoChoku Co.,Ltd.）

9:00 AM - 10:40 AM

[3Pin1-41] Music Generation from Motion Data

Junta Suzuki[1], ○Syogo Watanabe[2], Kazuaki Rokusawa[1] （1. Department of Computer Science, Chiba Institute of Technology, 2. Graduate School of Information and Computer Science,

©The Japanese Society for Artificial Intelligence

Chiba Institute of Technology）

9:00 AM - 10:40 AM

[3Pin1-42] Acquisition of uniform impression of music using graph kernel filter

○Hisashi IKARI[1] （1. Sockets Co., Ltd.）

9:00 AM - 10:40 AM

[3Pin1-43] Feature Extraction and Anomaly Detection by Non-negative Matrix Factorization of Vibration Data of Machine

○Masatoshi Sekine[1], Kazuki Kobayashi[1], Satoshi Ikada[1] （1. Corporate Research and Development Center, Oki Electric Industry Co., Ltd.）

9:00 AM - 10:40 AM

[3Pin1-44] Anomaly Detection in Control Valves by 1d CNN-LSTM

○Takahiro Motegi[1], Yuya Nakazawa[1], Tetsuya Tabaru[1] （1. Azbil Corporation）

9:00 AM - 10:40 AM

[3Pin1-45] Constructing Diagnosis Corpus Using Collaborative Learning Environment for Improving Dementia Care

○Naoki Kamiya[1], Hideki Ueno[2,3,4], Takumi Yoshizawa[1], Shogo Ishikawa[1], Kenta Imada[1], Hayato Nishiyama[1], Shinya Kiriyama[1,4], Akira Tamai[3], Yoichi Takebayashi[1,4] （1. Shizuoka University, 2. Chiba University Hospital, 3. Tsuruga Onsen Hospital, 4. The Society of Citizen Informatics for Human Cognitive Disorder）

9:00 AM - 10:40 AM

[3Pin1-46] Construction and Practice of Collaborative Learning Environment for Personality-focused Care in Dementia Care

○Atsushi Omata[1], Shogo Ishikawa[1], Hatsue Munakata[1], Ayumi Nakanome[2], Mio Ito[3], Yutaka Sakane[4], Miwako Honda[5], Hisao Hara[2], Shinya Kiriyama[1,6], Yoichi Takebayashi[1,4,6] （1. Shizuoka University, 2. Koriyama Medical Care Hospital, 3. Tokyo Metropolitan Institute of Gerontology, 4. ExaWizards Inc., 5. Tokyo Medical Center, 6. The Society of Citizen Informatics for Human Cognitive Disorder）

9:00 AM - 10:40 AM

[3Pin1-47] Co-production of care knowledge for people with dementia based on an emotion thinking models

○Shogo Ishikawa[1], Yuki Sasaki[1], Shinya Kiriyama[1], Miwako Honda[2], Yves Gineste[3], Yoichi Takebayashi[1] （1. Shizuoka University, 2. Tokyo Medical Center, 3. Institute Gineste Marescotti）

9:00 AM - 10:40 AM

[3Pin1-48] Patient's sitting position estimation using skeleton information and bed position detection

○MADOKA INOUE[1,2], RYO TAGUCHI[2], TAIZO UMEZAKI[2,3] （1. AIPHONE CO., LTD., 2. Nagoya Institute of Technology, 3. The University of Tokyo）

9:00 AM - 10:40 AM

[3Pin1-49] Accurate drowsiness estimation via eye-related movements: a neural-network-based investigation

Mingfei Sun[2], ○Masanori Tsujikawa[1], Yoshifumi Onishi[1], Xiaojuan Ma[2], Atsushi Nishino[3], Satoshi Hashimoto[3] （1. NEC Corporation, 2. Hong Kong University of Science and Technology, 3. DAIKIN Industries, LTD）

9:00 AM - 10:40 AM

©The Japanese Society for Artificial Intelligence

[3Pin1-50] Estimating nursing care necessity degree using by assessment information

○Shu Kobayashi[1], Sachiko Hirata-Mogi[1], Fukuda Shoji[1] （1. SMS CO., LTD.）

9:00 AM - 10:40 AM

[3Pin1-51] Attempt to visualize clinical data for grasping status of patients

○Masamichi Ishii[1], Kengo Miyo[1] （1. National Center for Global Health and Medicine）

9:00 AM - 10:40 AM

[3Pin1-52] Development of “Sleep Diary” application and continuation prediction of behavior for improvement sleeping habits

○Jou Akitomi[1], Ikuo Kajiyama[1], Miho Ishii[1], Isa Okajima[2], Mineko Yamaguchi[1] （1. NEC Solution Innovators, Ltd., 2. Tokyo Kasei University）

9:00 AM - 10:40 AM

[3Pin1-53] Simulation of Target Word Prediction for Neural Machine Translation

○Yuto Takebayashi[1], Chenhui Chu[3], Yuki Arase[1], Masaaki Nagata[2] （1. Graduate school of Information Science and Technology of Osaka University, 2. NTT Corporation, 3. Osaka University）

9:00 AM - 10:40 AM

[3Pin1-54] Research of abnormal node eradication conditions of self-repair network

○Yoshiyuki Tamura[1], Yoshiteru Ishida[1] （1. Toyohashi University of Technology）

9:00 AM - 10:40 AM

©The Japanese Society for Artificial Intelligence

建築構造教育アプリケーションに対する各種最適化手法の適用性検討

Optimization method for Educational Application of Structural Engineering

鈴木　琢也[*1]　Takuya Suzuki
井口　圭一[*2]　Keiichi Iguchi
木下　拓也[*1]　Takuya Kinoshita
石川　明洋[*2]　Akihiro Ishikawa

[*1] 竹中工務店　Takenaka Corporation
[*2] HEROZ　HEROZ

The purpose of this paper is to confirm an applicability of some optimization methods to an application for architectural structural education. First, the outline of the developed application is explained. This application takes advantage of the features of smart devices as to anyone from adults to children can enjoy it. Secondary, the detail of three optimization method is explained. And then, by each method, optimization analyses are conducted for 50 stages. Finally, the optimization results are compared, and the applicability of these optimization methods is examined.

1. はじめに

建築物の安全性を支える構造に関する技術の理解には，高度な専門的技術・知識を必要とする。そのため，一般の人々から理解されにくいものとなっている。しかし，技術者が構造解析の結果や意味をよりわかりやすく伝えることができれば，一般の人々はより正しく「安全」を理解し，今以上に「安心」を得ることができると考えられる。「いかにわかりやすく伝えるか」は，建築技術者にとって重要な課題といえる。

一方で，近年スマートフォンやタブレット端末といった高性能な携帯型情報端末（以下，「スマートデバイス」という）が広く普及している。スマートデバイスは，タッチパネルによる直感的なインターフェースや，各種センサーを内蔵することにより，これまでとは異なる計算機と人との関わり方を可能にしている。

このような背景から，著者の一人は，構造解析をよりわかりやすくするためのツールとしての可能性をスマートデバイスに見出し，これまでに，スマートデバイスの特徴を活かした建築構造解析アプリケーションに関する調査研究を行ってきた[鈴木 2017]。

本報では，新たにタッチで出来る構造最適化アプリケーションの対戦版を提案し，そこで利用する対戦コンピューターの戦略ロジックを決定するために実施した，各種最適化手法の適用性検討結果を報告する。

2. 開発するアプリケーションの概要

タッチで出来る構造最適化アプリケーションである StartOPT[鈴木 2017]を対戦型に改良したものである。

図 1 にはゲーム画面を示す。ボールを支えるのに不要と思われる部分をタッチで消した後，残ったブロックのみで変形解析が行われる。2 人のプレイヤーがブロック（最大 10 個，パスも可）を交互に消していき，先にボールを規定ラインよりも下に落としたプレイヤーが負けとなる。その点では，子どもの遊びである砂山崩しに近い。ただし，両者がパスした場合には，その時点で，より多くのブロックを消したプレイヤーの勝ちとなる。

様々な荷重条件，境界条件下における強い形を数多く試すことを通して，効率的な構造を直感的に理解するとともに，建築構造の基礎である「力の流れ」を，老若男女問わず楽しく理解することができる。

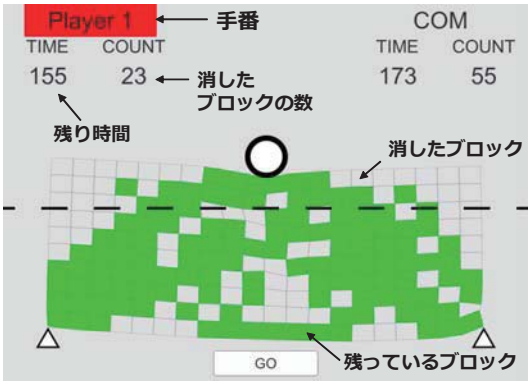


図 1　ゲーム画面

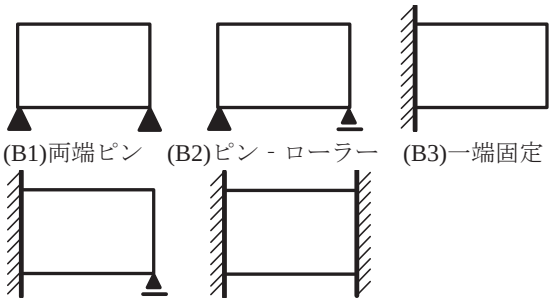


図 2　境界条件

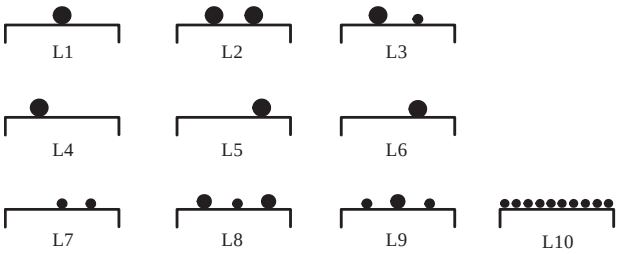


図 3　荷重条件

連絡先：鈴木琢也，竹中工務店，千葉県印西市大塚 1-5-1，0476-47-1700，0476-47-6460，suzuki.takuya@takenaka.co.jp

各ステージは，ブロックの境界条件（どこが支えられているか），および荷重条件（ボールの位置，個数，重さ）が変化する。

境界条件は，図 2 に示す建築構造で基本となる 5 パターン，荷重条件は図 3 に示す 10 パターン用意し，これらを組み合わせた計 50 種のステージが用意されている。これらの境界条件，荷重条件に応じて，最適な形状も様々に変化することになり，多くのステージをプレイすることで，プレイヤーの理解度も深まっていく。

3. 検討する最適化手法

前章で紹介したアプリケーションのコンピュータープレイヤーの構築には，ボールを規定ラインよりも落とさないための，最も有効なブロックを選択するロジックを作成する必要がある。その嚆矢として本報においては，「ボールを規定ラインよりも落とさない条件で，最も多くのブロックが消去された状態」を，3 つの最適化手法を用いて計算し，この構造最適化問題における適用性を検討する。比較する手法は表 1 に示す，貪欲法，反復局所探索法(Iterated Local Search (ILS)，密度法の 3 種の方法である。それぞれの詳細について以降で説明する。

貪欲法は，入力条件を変更させた結果，出力がどのように変化するかを確認した上で，消去するブロックを選択する。具体的には，ある状態において残っているブロックのうち，一つだけを抜いた場合の解析を，全ブロックに対して実施する。その後，最も影響の小さい（ボールの鉛直変位増分が小さい）ブロック 1 つを消去する。この操作をボールがクリアラインを越えるまで繰り返してブロックを一つずつ消去していき，消去できるブロックの最大個数を算出する。なお，計算回数の低減を図るために，感度計算の途中で「消去することでクリアラインを越えると判定されたブロック」は，以降の消去候補としないこととしている。

反復局所探索法(Iterated Local Search (ILS))は組合せ最適化問題を解くのに使われる手法で、その名の通り局所探索を繰り返す手法である。反復局所探索法では、まず、ブロックを一つずつ除いていく局所探索を行う。そして、どのブロックを除いてもボールがクリアラインを越えてしまう状態になれば、ランダムにいくつかのブロックを復活させて再び局所探索を行うという操作を制限時間まで何度も繰り返す。制限時間が来れば探索したすべての解の中で最も多くブロックを除いた解を出力して終了する。なお、復活させるブロックの数は削除済みブロックの半数以下とし、制限時間は 10 分とした。

密度法は、トポロジー最適化手法の一つで、材料のヤング率が密度のべき乗となるよう問題を緩和して最適解を求める手法である[Bensoe 2002]。本報では、支持構造全体の体積の制約条件の下で、静的コンプライアンス（外力仕事）を最小化するような要素密度分布を求める問題とした。このような問題設定を行うことで、目的関数及び制約条件の感度を一度の変形解析後の既知量から陽に算定することができ、計算効率が大幅に向上する。ここでは、密度のべき乗数 p=4 とし、体積制約をある程度大きい値から始めて、体積制約値を徐々に減らしながら複数回の最適化を行った。最適解の変形量が制限値を超えたとき、それまでに最もブロックを消したケースを出力して終了とした。なお、最適要素密度は実数で出力されるため、各最適化試行後に全要素をブロック有り／無しのいずれかに 2 値化させる処理を施している。

表 2　検討結果

STAGE		貪欲法	ILS	密度法
Boundary	Load			
B1	L1	165	178	178
	L2	160	170	170
	L3	156	165	160
	L4	148	170	165
	L5	148	170	164
	L6	140	165	160
	L7	142	159	158
	L8	145	158	160
	L9	143	159	160
	L10	140	158	150
B2	L1	129	132	132
	L2	146	152	150
	L3	119	143	138
	L4	134	142	137
	L5	128	141	135
	L6	132	141	138
	L7	120	139	134
	L8	123	134	137
	L9	117	128	136
	L10	133	132	134
B3	L1	165	158	165
	L2	132	127	128
	L3	148	145	146
	L4	186	181	189
	L5	83	81	83
	L6	111	107	108
	L7	125	120	119
	L8	113	107	106
	L9	125	124	114
	L10	98	102	91
B4	L1	143	171	179
	L2	154	163	167
	L3	161	162	167
	L4	182	180	185
	L5	146	161	166
	L6	153	155	165
	L7	148	158	159
	L8	149	156	161
	L9	152	154	161
	L10	157	154	156
B5	L1	153	162	179
	L2	172	164	178
	L3	146	164	179
	L4	150	170	188
	L5	150	171	188
	L6	156	163	179
	L7	148	156	162
	L8	156	158	168
	L9	141	156	168
	L10	152	152	158
合計		7123	7518	7658
Best Score の回数		9	16	30



(a)貪欲法



(b)ILS



(c)密度法

図 2　算出された最適解（B1，L1）



(a)貪欲法



(b)ILS



(c)密度法

図 3　算出された最適解（B1，L6）

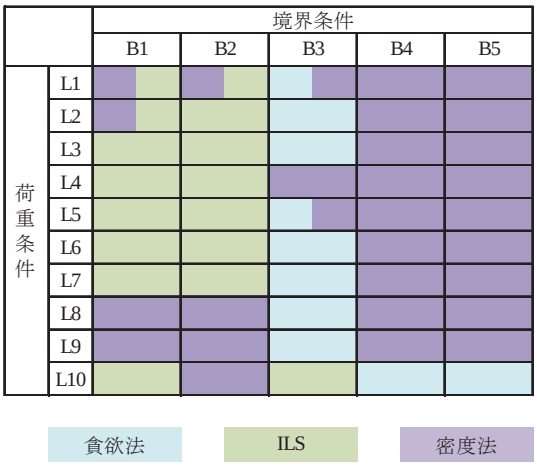


図 4　最小解を算出した最適化手法

4. 検討結果

表 2 には，各手法によって算出された消去できるブロックの最大の数の一覧を示す。大きな値が算出できるほど効率的な形を導出できたと判断する。各条件において最も多くのブロックを消すことができた手法は網掛け表示としている。

表より，境界条件，荷重条件によって，最適形状を算出できる最適化手法は異なることがわかる。三者による算定手法の差が最も小さいのは「B3, L5」のケース，最も大きいのは「B5, L4」および「B5, L5」のケースであった。

また，表には，全 50 ステージで算出された最大ブロック消去数の合計値，最大ブロック消去数を算出できたステージ数も併せて示す。表より平均的な観点では，密度法による方法が，合計値 7658，ステージ数 30 となり，最も有効であった。なお，ILS による方法も，合計値は 7518 と密度法との差は僅かであった。

図 2，図 3 には一例として，境界条件 B1（両端ピン）における最も基本的な荷重条件である L1 と，3 者の評価に最も差がついた L6 のケースにおいて，得られた最適形状の解析結果を示す。図 2 より，それぞれの最適化手法から算定された形は，概ね同傾向にあり，密度法と ILS による方法はほぼ同じ形を算出した。これらと比較すると，貪欲法によって得られた解には，まだ削ることができるブロックが残されていることがわかる。一方，図 3 においては，算出された形に差異がみられた。探索ルートが異なった結果，異なる最適化形状に至る一例と言える。

図 4 には，各ステージにおいて最適な解を算出できた手法を荷重条件，境界条件によって整理したものを示す。図より，条件によって最適形状を算出できる手法は様々に変化することがわかる。今回の検討範囲では，荷重条件よりは，境界条件よって最適形状を算出できる手法が変化する傾向があり，B1，B2 においては ILS，B3 においては貪欲法，B4，B5 においては密度法がより適切な解を算出する傾向が確認できる。

5. まとめ

本報では，タッチで出来る構造最適化アプリケーションの対戦版を提案し，そこで利用する対戦コンピューターの戦略ロジックとして，適切な最適化手法について検討を行った。

その結果，密度法による方法が，平均的に最適な形状を見つけやすい結果となった。ただし，荷重条件によっては他の方法の方が優れている場合もあるため，最適化手法を採用する際には，十分な事前検討が必要と考えられる。

参考文献

[鈴木　2017] 鈴木琢也ほか：スマートデバイスの特徴を活かした教育用構造解析アプリケーションの開発と展開，日本建築学会学術講演会梗概集，教育，pp. 47-48, 2017.7

[Bensoe　2002] Bensoe, M.P., Sigmund, O.: Topology Optimization; Theory, Methods, and Applications, Springer, 2002.

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

協調型共進化の性能評価を目的としたベンチマーク問題と問題の再分割が性能に与える影響の検証

Benchmark Functions for Cooperative Coevolution and Analysis of Influence by Dynamic Problem Decomposition

中島 有貴 *1 Yuki Nakashima　松岡 淳一 *1 Jun-ichi Matsuoka　久冨 あすか *1 Asuka Hisatomi　小野 智司 *1 Satoshi Ono

*1鹿児島大学大学院 理工学研究科 情報生体システム工学専攻
Department of Information Science and Biomedical Engineering, Graduate School of Science and Engineering, Kagoshima University

This paper proposes benchmark functions for cooperative coevolution (CC), which dynamically divides a target problem into smaller subproblems and solves in parallel. The proposed benchmark functions allow adjusting dependency strength between variables by changing the number of linkages and linkage types. Experimental results showed the influence of dynamic decomposition change frequency to CC's optimization performance.

1. はじめに

近年，進化計算の分野では，大規模な最適化問題を部分問題へと分割し，それぞれを探索する集団を複数用意することで最適化を行う協調型共進化アルゴリズムの研究が行われている [Potter 94]．従来の進化計算が数十次元の問題を対象としていたのに対し，協調型共進化は数百から数千次元の問題を対象としており，部分問題へと分割しそれぞれを低次元の問題として最適化することで，良好な解を得ることが期待できる．

一方，協調型共進化では対象問題の変数間に依存性がある場合，問題分割により各ソルバが部分問題を跨ぐような変数間の依存性を考慮できなくなり局所解へ陥ることがある．しかし，分割の仕方を一定の頻度で変更し，部分問題内の変数を入れ替えることで局所解が発生するリスクを回避している．協調型共進化において分割の方法を変更可能である理由は，対象問題が大規模であるもののほぼ均質な性質を持つことを仮定しているためである．

本研究では，部分問題間の依存形状，および依存性の強さを調整可能なベンチマーク問題を提案する．本問題は，協調型共進化の性能評価を目的としており，協調型共進化における特有の局所解の発生の解析や回避方法の開発への寄与を目指す．本研究では，実験により，問題分割の頻度および問題の依存性の強さを変更することで協調型共進化の性能が変化することを確認する．

2. 関連研究 : 問題分割型共進化（DECC-G）

Wang らが設計した協調型共進化である DECC-G は，対象問題の変数をランダムに各部分問題へ割り当て，各部分問題の最適化アルゴリズムに SaNSDE（Self-adaptive DE with Neighborhood Search）を適用した協調型共進化アルゴリズムである [Yang 08]．SaNSDE ではスケール係数 F と交叉率 CR を更新しながら最適化を行う．各部分問題の最適化を T_g 世代の間行った後に，部分問題を結合する．各部分問題の最適化の後に最良個体，ランダムな個体，最悪個体を用いて重み付け用の個体群を DE で最適化を行い，最適化に用いた 3 個体を更新して個体群の評価を行う．ここまでを 1 サイクルとして，終了後，また対象問題の再分割を行い最適化を行う．この際，分割の方法を変更するため，各部分問題に含まれる変数は 1 サイクル時とは異なる．DECC-G はこのサイクルを繰り返すことで大規模な最適化問題を解くことが可能となる．

連絡先: 中島有貴，鹿児島大学大学院 理工学研究科 情報生体システム工学専攻，〒 890-0065 鹿児島市郡元 1-21-40，sc114035@ibe.kagoshima-u.ac.jp

表 1: Linkage form

Problems	Linkage form
Absolute	$L(x) = \|x\|$
Linear	$L(x) = x$
Nonlinear	$L(x) = \frac{sin(\pi\times\ x)}{2}$
	$L(x) = \frac{x}{\sqrt{\|x\|}}$
	$L(x) = x^2$
Deceitful	$L(x) = sin(\pi\times\ x)$

3. 共進化評価用ベンチマーク問題

本研究では，松岡らにより提案された共進化評価用のベンチマーク問題を改良した問題 [Mat 17] を提案する．本問題は連続 NK-Landscape 問題を参考に設計され，互いに依存関係のある 2 つの部分問題を持ち，さらに依存関係の強さを調整できるという特徴がある．

連続 NK-Landscape 問題は，実数値変数を含みつつ一般的な NK-Landscape と同様に設計変数間の依存性を制御できるよう設計された問題である [Kauffman 92, Wang 08]．連続 NK-Landscape 問題の評価関数を以下の式 (1) から式 (3) に示す．

$$f(\boldsymbol{x}) = \frac{1}{N}\Sigma_{j=1}^{N} f_j(x_j, z_1^{(j)}, ..., z_K^{(j)}) \tag{1}$$

$$f_j(x_j, z_1^{(j)}, ..., z_K^{(j)}) = \left| x_j - z_1^{(j)} - ... - z_K^{(j)} \right| \tag{2}$$

$$z_i^{(j)} = L(x_{(i+j)modN}) \tag{3}$$

ここで，$\boldsymbol{x} = \{x_1, x_2, ..., x_N\}$ は解候補を表すベクトルであり，$x_j \in [-1, 1]$ とする．また，式 (3) に含まれる関数 $L(x_i)$ は Linkage form と呼ばれ，表 1 に示す式のいずれかを用いる．$L(x_i)$ の定義により，連続 NK-Landscape 問題は Sphere 関数や Rosenbrock 関数などの一般的なベンチマーク問題を表現することができる．

共進化評価用のベンチマーク問題は，この連続 NK-Landscape 問題における解 $\boldsymbol{x}$ を $\boldsymbol{x}^{C_1}$ と $\boldsymbol{x}^{C_2}$ に分け，それぞ

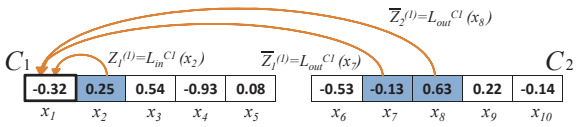
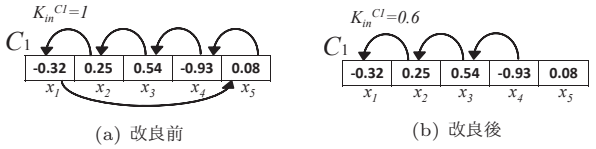


図 1: 共進化評価用ベンチマーク問題における依存関係の例



(a) 改良前　(b) 改良後

図 2: 共進化評価用ベンチマーク問題における $K_{in}^{C_1}$ の例

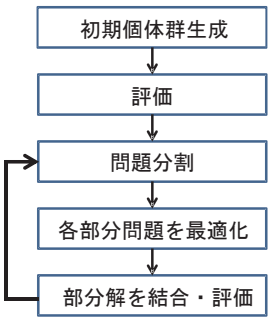


図 3: 実装した協調型共進化のフローチャート

れの解を持つ部分問題を定義する．また，それぞれ $\boldsymbol{x}^{C_1}$，$\boldsymbol{x}^{C_2}$ の解を持つ部分集団を C_1，C_2 とする．これらの部分問題は互いの解を組み合わせることで目的関数の値が計算できるものとする．

依存関係に関して，$\boldsymbol{x}^{C_1}$ と $\boldsymbol{x}^{C_2}$ は自身の解に含まれる変数のみから影響を受けるだけでなく，他の解に含まれる設計変数からも影響を受ける．ここで，自身の解からの影響を K_{in}，他の解からの影響を K_{out} とする．C_1 に関して自身の解からの影響の強さを $K_{in}^{C_1}$，他の解からの影響の強さを $K_{out}^{C_2}$ とし，C_2 に関して自身の解からの影響の強さを $K_{in}^{C_2}$，他の解からの影響の強さを $K_{out}^{C_2}$ とする．$K_{in}^{C_1}$，$K_{out}^{C_1}$，$K_{in}^{C_2}$，$K_{out}^{C_2}$ はいずれも $[0, N/2-1]$ の範囲の値を持つ．

目的関数を以下のように定義する．

$$f(\boldsymbol{x}) = \Sigma_{i=1}^{N}(\beta x_i)^2 + f^{C_1}(\boldsymbol{x}) + f^{C_2}(\boldsymbol{x}) \tag{4}$$

$$f^{C_1}(\boldsymbol{x}) = \frac{1}{N/2}\Sigma_{j=1}^{N/2} f_j(x_j, z_1^{(j)}, ..., z_{K_{in}^{C_1}}^{(j)}, \bar{z}_1^{(j)}, ..., \bar{z}_{K_{out}^{C_1}}^{(j)}) \tag{5}$$

$$f^{C_2}(\boldsymbol{x}) = \frac{1}{N/2}\Sigma_{j=\frac{N}{2}+1}^{N/2} f_j(x_j, z_1^{(j)}, ..., z_{K_{in}^{C_2}}^{(j)}, \bar{z}_1^{(j)}, ..., \bar{z}_{K_{out}^{C_2}}^{(j)}) \tag{6}$$

$$f_j(x_j, z_1^{(j)}, ..., z_{K_{in}^{C}}^{(j)}, \bar{z}_1^{(j)}, ..., \bar{z}_{K_{out}^{C}}^{(j)}) = \left| x_j, z_1^{(j)}, ..., z_{K_{in}^{C}}^{(j)}, \bar{z}_1^{(j)}, ..., \bar{z}_{K_{out}^{C}}^{(j)} \right| \tag{7}$$

$$z_i^{(j)} = L_{in}^{C}(x_{(i+j)}) mod \frac{N}{2} \tag{8}$$

$$\bar{z}_i^{(j)} = L_{out}^{C}(x_{\frac{N}{2}+(i+j)}) mod \frac{N}{2} \tag{9}$$

解 x^{C_1} の内部の依存関係は，j 番目の変数である x_j の値に着目した場合，$j+1$ 番目から $j+K_{in}$ 番目までの変数 $x_{j+1}, ..., x_{j+K_{in}}$ からの影響を受ける．また，相手の解である $\boldsymbol{x}^{C_2}$ における変数 $x_{N/2+j+1}, ..., x_{N/2+j+K_{out}}$ からも影響を受ける．図 1 に $K_{in}^{C_1}=1$，$K_{out}^{C_1}=2$ における依存関係を示す．図 1 では，x_1 に着目しており，自身の解の内部では x_2 から影響を受ける．また，他の解において x_7，x_8 からの影響を受けるようになっている．なお，式 (4) の第 1 項は大域的最適解の単一性を保障するための成分を示す．

本研究では，共進化評価用ベンチマーク問題について，より詳細な結果を得るために，$K_{in}^{C_1}$，$K_{out}^{C_1}$，$K_{in}^{C_2}$，$K_{out}^{C_2}$ をそれぞれ $[0,1/N]$ の範囲の実数値を持つように改良する．ここで N は各ソルバに含まれる変数の数を示す．共進化評価用ベンチマーク問題における $K_{in}^{C_1}$ にのみ着目した際の例を図 2 に示す．また，図 2(a) には改良前，図 2(b) には改良後の例を示している．改良前は，$K_{in}^{C_1}=1$ の場合，自身の解に含まれる全ての変数は自身の解の内部にある 1 つの変数から影響を受けるように設計されている．このため，変数ごとに影響を受ける数を変更することができない．改良後は $N=5$ の場合，$K_{in}^{C_1}$ は 0.2 刻みで増加していく．図 2(b) に示すように $K_{in}^{C_1}=0.6$ では，自身の解に含まれる 3 つの変数が依存性を受けるようになっている．このように設計することで，変数ごとに影響を受ける変数の数を変更することが可能となり，より詳細な結果を得ることができる．

4. 評価実験

本研究では Wang らが設計した DECC-G の問題分割方法にもとづく協調型共進化を実装し，実装した協調型共進化で共進化評価用ベンチマーク問題を解く．実装した協調型共進化のフローチャートを図 3 に示す．実験の際には，問題分割の頻度を 1 世代ごと，250 世代ごと，500 世代ごとの 3 パターンに変更し，頻度ごとの性能を調査する．本研究において，これらの分割の頻度に関して，それぞれ分割世代ごとに $T_g=1$，$T_g=250$，$T_g=500$ と定義する．

3 章で示した共進化評価用ベンチマーク問題は $K_{in}^{C_1}$，$K_{out}^{C_1}$，$K_{in}^{C_2}$，$K_{out}^{C_2}$ を変化させることが可能であるが，問題が複雑になることを避けるために $K_{in}^{C_1}$ および $K_{out}^{C_1}$ を変化させ，$K_{in}^{C_2}$，$K_{out}^{C_2}$ を 0 に固定し，C_1 にのみ依存性を持たせて実験を行う．問題全体の次元数は 10 次元とし，2 つの部分問題がそれぞれ 5 変数を含むように問題分割を行う．ここで協調型共進化が大規模な問題を対象にしているにも関わらず，問題の次元数を 10 次元としたのは，低次元の問題であっても依存性により最適解の発見が困難になることを示すためであり，また，解析を容易にするためである．また，問題全体の性質を均質にするために $L_{in}^{C_1}$ および $L_{out}^{C_1}$ には表 1 に示す”Absolute”の関数を割り当てることとする．なお，各部分問題の最適化アルゴリズムには jDE [Brest 06] を用いることとした．jDE の各パラメーターについて表 2 に示すように設定した．

実験結果を図 4 に示す．それぞれの図における z 軸は探索成功率 (Success Rate) を示し，これは 20 試行のうち，大域的最適解に収束した割合を示している．また，$T_g=1$ と $T_g=250$ の場合，$K_{in}^{C1}=0$ と $K_{in}^{C1}=1$ において成功率の差が激しかったため，K_{in}^{C1} を 0.2 刻みでで変化させて実験を行った．また，図 4(c) では K_{in}^{C1}，K_{out}^{C1} ともに 1 刻みで変化させている．

毎世代問題分割を変更する場合（$T_g=1$）は，$0.0 \leqq K_{in}^{C1} < 1.0$ では K_{out}^{C1} の値が大きくなるにつれて成功率は低下するこ

表 2: jDE の各パラメーター

項目	値
各ソルバ内で用いるアルゴリズム	jDE
個体数	50/集団
交叉方法	rand/1/exp
τ_1，τ_2	0.1，0.1
F_{max}，F_{min}	1.0，0.1
CR_{max}，CR_{min}	1.0，0.0

とが確認された．また，$K_{in}^{C1} = 1.0$ のとき K_{out}^{C1} の値に関わらず成功率は 0%となったが，$K_{in}^{C1} > 1.0$ では K_{out}^{C1} の値に関わらず成功率は 100%となった．$T_g = 250$ の場合は，$T_g = 1$ の場合と同様に $0.0 \leqq K_{in}^{C1} < 1.0$ のときに K_{out}^{C1} の値が大きくなるにつれて成功率は低下することが分かる．$K_{in}^{C1} = 1.0$ のとき，$T_g = 1$ の結果よりも成功率は上昇しており，K_{out}^{C1} の値が大きくなるにつれて成功率は低下することが確認された．$K_{in}^{C1} > 1.0$ では $T_g = 1$ の場合と同様の結果が得られた．$T_g = 500$ の場合は，$K_{in}^{C1} = 0$ のとき，$T_g = 1$，$T_g = 250$ の場合と同様に K_{out}^{C1} の値が大きくなるにつれて成功率は低下することが確認された．また，$K_{in}^{C1} > 0$ では K_{out}^{C1} の値に関わらず成功率は 100%となることが確認できた．

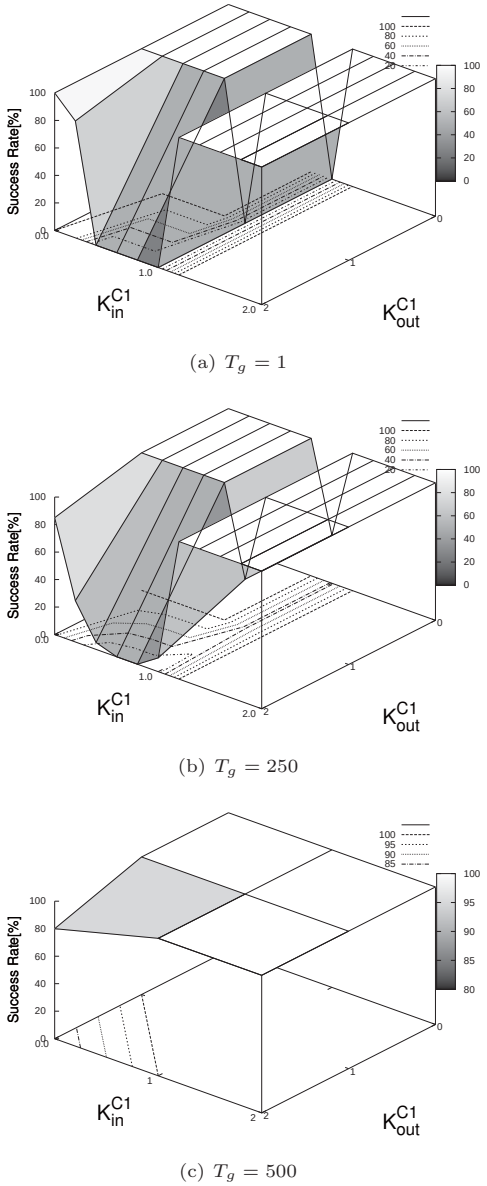
$K_{in}^{C1} = 1.0$ の場合の $T_g = 250$ についての 20 試行全てにおける最良個体の適応度の推移を図 5 に示す．$T_g \geqq 250$ の場合，図 5 のように，局所解に収束するものの世代を経て分割の仕方を変更することにより，局所解から脱出できる場合がある．これは，依存性のある変数同士を同じ部分問題に含みつつ最適化を行う期間が長いためであると考える．

$T_g = 1$ および $T_g = 250$ の場合，$K_{in}^{C1} = 1$ において成功率が極端に低下していたため，$K_{in}^{C1} = 1$，$K_{out}^{C1} = 0$ の問題で発生している局所解付近の適応度景観を作成し解析を行った．全ての次元数の組み合わせを掲載することは困難であるため，x_1 と $x_2, ..., x_{10}$ との組み合わせに着目した適応度景観のみを図 6 に掲載する．図 6 では，左側には 2 次元グラフで示した図，右側には 3 次元グラフで示した図を示す．また，2 次元グラフで示した図において，縦軸を x_1 としている．図 6 から，局所解付近が大域的に凸の形状になっている．他の変数の組み合わせにおいても同様に局所解付近では大域的に凸の形状をする適応度景観が確認された．このため，少なくとも 2 変数の同時変更だけでは局所解から抜け出すことが困難であることがわかる．

5. 結論

本研究では，DECC-G をもとに協調型共進化を実装し，共進化評価用ベンチマーク問題を解くことにより性能を調査した．その際，問題分割の頻度を 1 世代ごと，250 世代ごと，500 世代ごとに変化させ実験を行った．その結果，$K_{in}^{C_1} \leqq 1$ において，分割の頻度が高い場合は $K_{out}^{C_1}$ の値が大きくなるにつれて成功率が低下することが確認でき，分割の頻度が低い場合は，$0 < K_{in}^{C_1}$ において成功率が高くなることが確認できた．特に $K_{in}^{C_1} = 1$ のような難しい問題では，依存性のある変数同士を同じ部分問題に含みつつ最適化を行う期間を長くすることが，局所解から抜け出すために必要であることが分かった．

本稿では Linkage form に”Absolute”関数を用いた場合の実験を行ったため，今後は他の Linkage form ではどのような性能を示すか実験を行う必要がある．また，使用する最適化アルゴリズムに関して，本稿では jDE を用いて実験を行ったが，



(a) $T_g = 1$

(b) $T_g = 250$

(c) $T_g = 500$

図 4: 各分割頻度の結果

その他のアルゴリズムではどのような性能を示すか調査する必要がある．

謝辞

本研究の一部は科学研究費補助金（課題番号: 15H02758）による支援を受けて実施しました．ここに感謝の意を表します．

参考文献

[Brest 06] Brest, J., Greiner, S., Boskovic, B., Mernik, M., and Zumer, V.: Self-adapting control parameters in differential evolution: A comparative study on numerical benchmark problems, *IEEE transactions on evolutionary computation*, Vol. 10, No. 6, pp. 646–657 (2006)

[Kauffman 92] Kauffman, S. A.: The origins of order: Self-organization and selection in evolution, in *Spin glasses*

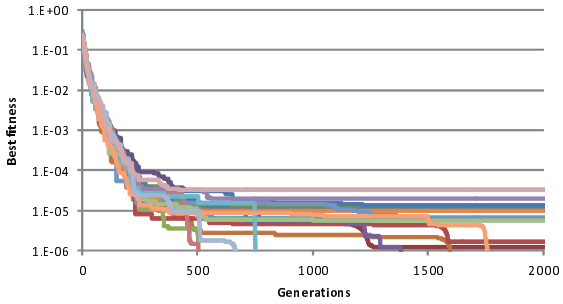


図 5: 全 20 試行における $T_g = 250$ の場合の BestFitness の推移

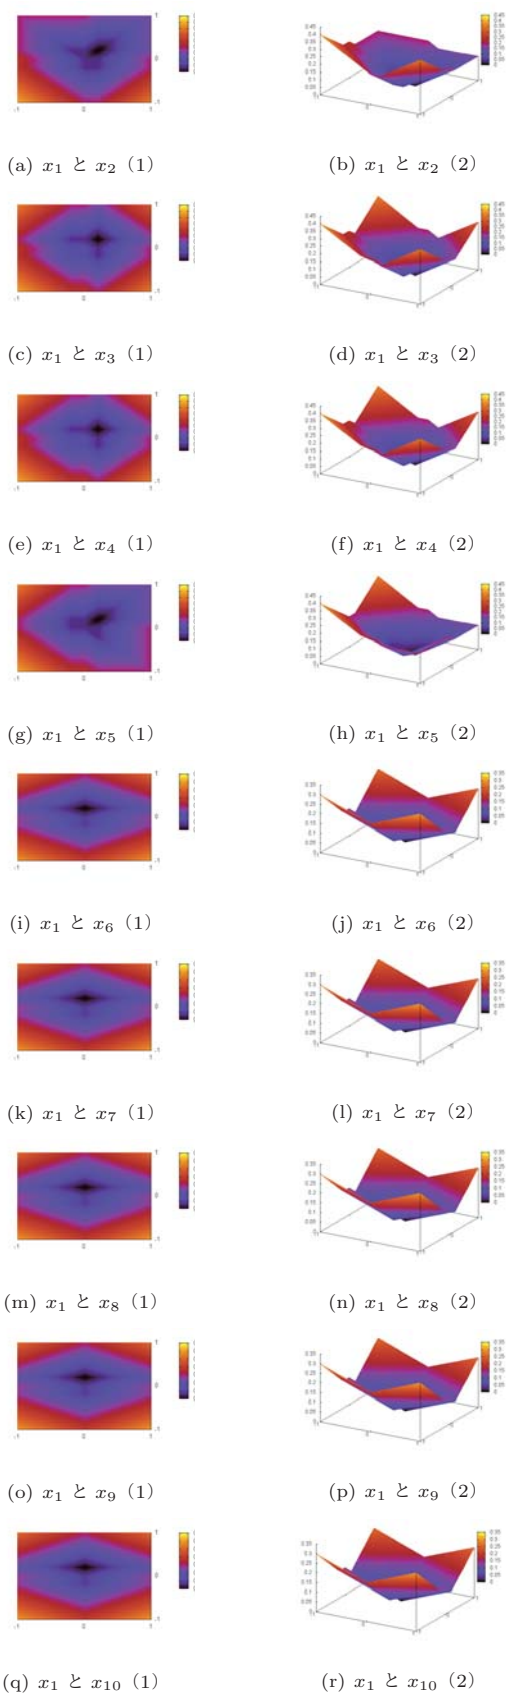
and biology, pp. 61–100, World Scientific (1992)

[Mat 17] *A Preliminary Study on Designing a Benchmark Problem for Analysis of Sparsely-Synchronized Heterogeneous Coevolution*IEEE (2017)

[Potter 94] Potter, M. A. and De Jong, K. A.: A cooperative coevolutionary approach to function optimization, in *International Conference on Parallel Problem Solving from Nature*, pp. 249–257Springer (1994)

[Wang 08] Wang, Y. and Li, B.: Understand behavior and performance of real coded optimization algorithms via nk-linkage model, in *Evolutionary Computation, 2008. CEC 2008.(IEEE World Congress on Computational Intelligence). IEEE Congress on*, pp. 801–808IEEE (2008)

[Yang 08] Yang, Z., Tang, K., and Yao, X.: Large scale evolutionary optimization using cooperative coevolution, *Information Sciences*, Vol. 178, No. 15, pp. 2985–2999 (2008)



(a) x_1 と x_2 (1) (b) x_1 と x_2 (2)

(c) x_1 と x_3 (1) (d) x_1 と x_3 (2)

(e) x_1 と x_4 (1) (f) x_1 と x_4 (2)

(g) x_1 と x_5 (1) (h) x_1 と x_5 (2)

(i) x_1 と x_6 (1) (j) x_1 と x_6 (2)

(k) x_1 と x_7 (1) (l) x_1 と x_7 (2)

(m) x_1 と x_8 (1) (n) x_1 と x_8 (2)

(o) x_1 と x_9 (1) (p) x_1 と x_9 (2)

(q) x_1 と x_{10} (1) (r) x_1 と x_{10} (2)

図 6: $K_{in}^{C_1} = 1$, $K_{out}^{C_1} = 0$ の局所解付近における適応度景観

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

潜在変数モデルとナレッジグラフ埋め込みの融合

Incorporating Knowledge Graph Embeddings into Latent Variable Models

武石 直也 *1　秋元 康佑 *1
Naoya Takeishi　Kosuke Akimoto

*1東京大学 航空宇宙工学専攻
Department of Aeronautics and Astronautics, The University of Tokyo

In this talk, we introduce an idea for incorporating information encoded in a knowledge graph to a latent variable model (LVM). We propose an extension of an LVM by two-view modeling, where the parameters and the latent variables of the LVM are shared between the original LVM and a probabilistic model for knowledge graph embedding. We specifically introduce how to incorporate a knowledge graph into probabilistic principal component analysis and show preliminary experimental results.

1. 背景

混合モデルや因子分析などの（特に、教師なしの）潜在変数モデル（latent variable model, LVM）は、次元削減やクラスタリングによる探索的データ分析をはじめとする種々のタスクに活用されている。LVM の潜在変数やパラメタはデータをもとに推定されるが、その推定量がどのような実際的・物理的な意味合いを持つかは多くの場合定かではない。例えば、主成分分析で得られた主成分方向の意味は必ずしも専門家から見てわかりよいとは限らない。無論それこそがデータ分析の意義のひとつといえる（常に既存の知識で説明できてしまう結果が出ていては新しい知見はない）が、一方で専門家の知識を LVM に事前知識として「入れ込む」ことができれば、データと既存知識との整合性／非整合性を定量的にとらえるのに役立つ可能性がある。一般的な LVM のモデル設計や推論・学習の過程においても、特徴量、仮説空間、正則化、初期値などの選択において事前知識といえるものが役立っている。また、データドメインに関してより直接的な形の事前知識として制約や論理式を LVM で考慮する研究もある [Fung 03, Varol 12, Andrzejewski 11, Mei 14, Foulds 15]。

本稿では、論理式などよりは間接的な形の事前知識として、**ナレッジグラフ**の形で表された知識を LVM に利用するための方法を提案する。ここでいうナレッジグラフとは、（通常、真の）タプル (h, r, t) の集合である。あるタプル (h, r, t) について、例えば

$$h = \text{Kagoshima}, \quad r = \text{is-located-in}, \quad t = \text{Japan},$$

であれば、そのタプルは真である。h や t はエンティティ、r はリレーションと呼ばれる。

ナレッジグラフは離散的なデータであるが、近年はエンティティやリレーションを連続値で表現するナレッジグラフ埋め込み（knowledge graph embedding, KGE）が盛んに研究され、リンク予測等のナレッジグラフ上のタスクのほか、question answering 等のナレッジグラフを利用するタスクに活用されている。よく知られた KGE として TransE [Bordes 13] とよばれる方法や DistMult [Yang 15] とよばれる方法がある。より複雑な最近の方法としては ConvE [Dettmers 17] などがある。本稿で紹介するのは、LVM にナレッジグラフによる知識を入れ込むために KGE を活用するという発想である。

連絡先: {takeishi,akimoto}@ailab.t.u-tokyo.ac.jp

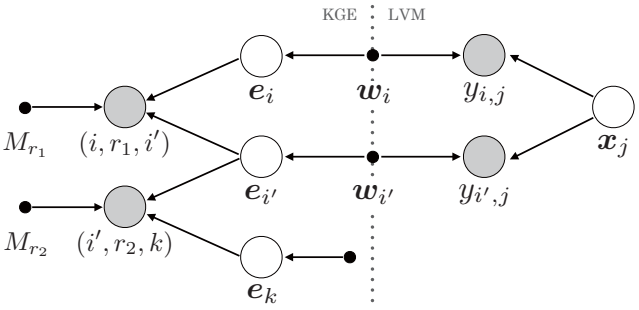


図 1: 提案手法のグラフィカルモデル表示の一部

2. 提案手法

まず、LVM および KGE 一般についてそれらを融合する方法論を紹介する。その後、確率的 PCA [Tipping 99] および KGE の一手法である DistMult [Yang 15] を組み合わせる場合についてのモデルや推論を特に記述する。

2.1 表記法

データは n 個のオブジェクトからなり、各々のオブジェクトは m 属性の観測からなるベクトル $\boldsymbol{y}_j \in \mathbb{R}^m$ である（ただし $j = 1, \ldots, n$）。$\boldsymbol{y}_j$ の i 番目の要素、すなわち属性 i のオブジェクト j での観測値を $y_{i,j} \in \mathbb{R}$ と表す（ただし $i = 1, \ldots, m$）。データ行列を $\boldsymbol{Y} = [\boldsymbol{y}_1 \ \cdots \ \boldsymbol{y}_n] \in \mathbb{R}^{m \times n}$ とする。

ある LVM が、パラメタの集合 θ および n 個の潜在変数ベクトル $\boldsymbol{x}_1, \ldots, \boldsymbol{x}_n$ を持っているとする（$\boldsymbol{x}_j \in \mathbb{R}^d$ は $\boldsymbol{y}_j$ に対応する）。$\theta = \{\boldsymbol{\pi}, \{\boldsymbol{w}\}\}$ の元には大域的パラメタと局所的パラメタの二種類があって、大域的パラメタ $\boldsymbol{\pi}$ が属性インデクス i によらないのに対して、m 個ある局所的パラメタ $\{\boldsymbol{w}_1, \ldots, \boldsymbol{w}_m\} \in \{\mathbb{R}^d\}^m$ は属性毎に存在するとする。*1 例えば確率的 PCA では、$\boldsymbol{\pi}$ には観測ノイズ分散などがあたり、$\boldsymbol{w}_i$ には因子負荷行列の i 行目があたる。また、LVM には観測モデル $p(\boldsymbol{Y} \mid \boldsymbol{X}, \theta)$ および事前分布 $p(\boldsymbol{X})$ が定まっているとする。パラメタの事前分布 $p(\theta)$ があってもよい。

KGE に関する量は次のように表す。エンティティの埋め込みは任意の添字とともに $\boldsymbol{e}_\cdot \in \mathbb{R}^q$ で表す。埋め込みのスコア付けのために用いるリレーション r に対応するパラメタは一般に

*1　$\boldsymbol{x}$ と $\boldsymbol{w}$ の次元は異なってもよいが、簡単のため両方 d とする。

M_r で表し、KGE のモデルによって行列 $\boldsymbol{M}_r$ やベクトル $\boldsymbol{m}_r$ として取られる。タプル (h,r,t) のスコアは $\psi(\boldsymbol{e}_h,\boldsymbol{e}_t,M_r)$ と書くことにする。また、タプルの負例は $(h,r,\tilde{t})$ などと表す。この場合は、タプル (h,r,t) に対して t だけを取り替えて作った負例という意味である。

2.2 LVM と KGE の two-view モデル

提案手法の主要な考え方を表すため、図 1 にグラフィカルモデルを示す。同図点線より右側は、ある LVM の観測モデルの一部（オブジェクト j と属性 i,i' に対応する部分）、すなわち

$$p(y_{i,j} \mid \boldsymbol{x}_j,\boldsymbol{w}_i)\cdot p(y_{i',j} \mid \boldsymbol{x}_j,\boldsymbol{w}_{i'}), \tag{1}$$

を表す。[*2] 同図点線より左側は KGE の一部を確率モデル化したものとその事前分布に対応していて、次の確率分布を表す：

$$\begin{gathered} p(\boldsymbol{e}_i \mid \boldsymbol{w}_i),\quad p(\boldsymbol{e}_{i'} \mid \boldsymbol{w}_{i'}),\quad p(\boldsymbol{e}_k),\\ p((i,r_1,i') \mid \boldsymbol{e}_i,\boldsymbol{e}_{i'},M_{r_1}),\quad p((i',r_2,k) \mid \boldsymbol{e}_{i'},\boldsymbol{e}_k,M_{r_2}). \end{gathered} \tag{2}$$

ここで、r_1 は属性 i と属性 i' との間のリレーション、r_2 は属性 i' とあるナレッジグラフ上のエンティティ k との間のリレーションを表す。このような two-view モデリングでは、LVM の局所的パラメタ $\boldsymbol{w}$ がエンティティの埋め込み $\boldsymbol{e}$ と関連づいている。このモデルの動機は、$\boldsymbol{w}$ を（$\boldsymbol{e}$ を通じて）ナレッジグラフのモデリングにも用いることによって、LVM の事前分布 $p(\boldsymbol{w})$ だけでなくナレッジグラフの構造も考慮した形で $\boldsymbol{w}$ の推定値や事後分布を得ることにある。

さて、式 (1) はオリジナルの LVM で定まっている一方、式 (2) の各分布は都合よく定めなくてはいけない。本稿では、

$$p(\boldsymbol{e} \mid \boldsymbol{f}(\boldsymbol{w})) = \mathcal{N}_{\boldsymbol{e}}(\boldsymbol{f}(\boldsymbol{w}),\boldsymbol{V}), \tag{3}$$

$$p(\boldsymbol{e}) = \mathcal{N}_{\boldsymbol{e}}(\boldsymbol{0},\boldsymbol{I}), \tag{4}$$

$$p((h,r,t)=\mathrm{true} \mid \boldsymbol{e}_h,\boldsymbol{e}_t,M_r) = \sigma(\psi(\boldsymbol{e}_h,\boldsymbol{e}_t,M_r)), \tag{5}$$

のようにモデリングすることを提案する。ただし、$\boldsymbol{f}:\mathbb{R}^d\to\mathbb{R}^q$ はユーザが設計すべき関数、σ はシグモイド関数である。また、$\boldsymbol{V}$ は大域的パラメタで $d\times d$ の実対称行列である。

推論や学習は基本的に通常の LVM と同様の手続きで行えばよい。ただし、KGE 部分の学習のためには予めナレッジグラフ上の負例を作成しておく前処理が重要となる（KGE に関して確率モデルを考えている先行研究だと [He 15, Xiao 16, Zhang 16] などを参照するとよい）。これは KGE 学習では一般的に行われている処理で、一種の data augmentation といえる。負例は正例タプルの一部をランダムサンプリングで変更して作成する（例えば、(h,r,t) から $(h,r,\tilde{t})$ を作る）ことが多いが、その詳細な方法は KGE のスコア関数設計と同様に本稿の対象の外となる。また、$\boldsymbol{e}$ の事後分布は解析的には計算できないので、サンプリングや近似推論が必要となる。しかし本稿では、ひとまず式 (3) のかわりに

$$p(\boldsymbol{e} \mid \boldsymbol{f}(\boldsymbol{w})) = \delta(\boldsymbol{e}-\boldsymbol{f}(\boldsymbol{w})), \tag{3'}$$

として（すなわち $\boldsymbol{e}=\boldsymbol{f}(\boldsymbol{w})$ として）、属性に対応しないエンティティについては式 (4) の事前分布は考えず、$\boldsymbol{e}$ をパラメタとして点推定する妥協策を用いる。$\boldsymbol{e}$ を確率変数としてみなすことでデータやナレッジグラフの不確かさを考慮することができるが、今後の課題とする。

*2 簡単のため j について独立な観測モデルであるとし、局所的パラメタの事前分布は考えず、図中では大域的パラメタを省略している。

2.3 ナレッジグラフ＋PCA

前節では LVM や KGE 一般について、それらを融合させるための two-view modeling に基づく方法論を提案した。この節では、そのような two-view modeling の例として、基本的な LVM のひとつである確率的 PCA [Tipping 99] および KGE のベースラインとしてよく参照される DistMult [Yang 15] を融合したモデルを定義し、学習方法を示す。

まず、確率的 PCA の観測モデルと事前分布は次の通り：

$$p(\boldsymbol{y}_j \mid \boldsymbol{x}_j,\theta) = \prod_{i=1}^{m}\mathcal{N}_{y_{i,j}}(\boldsymbol{w}_i^\top\boldsymbol{x}_j+\boldsymbol{\mu},\sigma^2), \tag{6}$$

$$p(\boldsymbol{x}_j) = \mathcal{N}_{\boldsymbol{x}_j}(\boldsymbol{0},\boldsymbol{I}). \tag{7}$$

ただし、$\boldsymbol{\mu}$, σ^2 は大域的パラメタである。次に、DistMult [Yang 15] のスコア関数は次のように定義される：

$$\psi(\boldsymbol{e}_h,\boldsymbol{e}_t,\boldsymbol{m}_r) = \boldsymbol{e}_h^\top\,\mathrm{diag}(\boldsymbol{m}_r)\boldsymbol{e}_t, \tag{8}$$

ただし、$\boldsymbol{m}_r\in\mathbb{R}^q$ はリレーション r に対応するパラメタである。$\boldsymbol{e}$ と $\boldsymbol{w}$ を関連させる関数 $\boldsymbol{f}$ の形は簡単にアフィン変換とする。すなわち、大域的パラメタ $\boldsymbol{A}\in\mathbb{R}^{q\times d}$, $\boldsymbol{b}\in\mathbb{R}^q$ を用いて

$$\boldsymbol{f}(\boldsymbol{w}) = \boldsymbol{A}\boldsymbol{w}+\boldsymbol{b}. \tag{9}$$

なお、$\boldsymbol{f}$ の設計には試行錯誤の余地が大いにある。確率的 PCA より複雑なモデルでは、j によって異なる $\boldsymbol{f}$ が必要な場合もある。

前述のように、$\boldsymbol{e}$ の事後分布推論は諦めて（というより、$\boldsymbol{e}$ を確率変数としないで）、$\boldsymbol{x}$ だけを潜在変数と見なす妥協策を採用する。このとき、学習時に最大化すべき不完全データ対数尤度は次の通り：

$$\begin{aligned} \mathcal{L} = &\sum_j \ln p(\boldsymbol{y}_j \mid \boldsymbol{W})\\ &+\sum_{(h,r,t)\in\mathcal{T}_1}\ln p((h,r,t) \mid \boldsymbol{e}_h,\boldsymbol{e}_t,\boldsymbol{m}_r)\\ &+\sum_{(i,r,t)\in\mathcal{T}_2}\ln p((i,r,t) \mid \boldsymbol{f}(\boldsymbol{w}_i),\boldsymbol{e}_t,\boldsymbol{m}_r)\\ &+\sum_{(h,r,i)\in\mathcal{T}_3}\ln p((h,r,i) \mid \boldsymbol{e}_h,\boldsymbol{f}(\boldsymbol{w}_i),\boldsymbol{m}_r)\\ &+\sum_{(i,r,i')\in\mathcal{T}_4}\ln p((i,r,i') \mid \boldsymbol{f}(\boldsymbol{w}_i),\boldsymbol{f}(\boldsymbol{w}_{i'}),\boldsymbol{m}_r). \end{aligned} \tag{10}$$

$\boldsymbol{x}$ は解析的に周辺化できるので、式 (10) の第一項は

$$\sum_j \ln\mathcal{N}_{\boldsymbol{y}_j}\left(\boldsymbol{\mu},\boldsymbol{W}\boldsymbol{W}^\top+\sigma^2\boldsymbol{I}\right),$$

と書ける。第二項以降は、例えば

$$\begin{aligned} \sum_{(i,r,t)\in\mathcal{T}_2}\Big\{&z_{(i,r,t)}\ln\left[\sigma(\psi(\boldsymbol{f}(\boldsymbol{w}_i),\boldsymbol{e}_t,\boldsymbol{m}_r))\right]\\ &+\left(1-z_{(i,r,t)}\right)\ln\left[1-\sigma(\psi(\boldsymbol{f}(\boldsymbol{w}_i),\boldsymbol{e}_t,\boldsymbol{m}_r))\right]\Big\}, \end{aligned}$$

のように書ける。ただし、$\mathcal{T}_1$ は head と tail の両者がデータの属性に関係しないタプルの集合、$\mathcal{T}_2$ は head だけがデータの属性に対応しているタプルの集合、以下同様に定義する。

3. 数値例

3.1 トイデータの用意と実験手順

次のように三次元の連続値データを生成した。まず、$\bar{y}_{1,1:n}$ および $\bar{y}_{2,1:n}$（ただし n は平方数）を $[-0.5, 1.5]^2$ 内の $\sqrt{n} \times \sqrt{n}$ 格子上の点としてとる。これをもとに $\bar{y}_{3,1:n}$ を次のように生成する：

$$\bar{y}_{3,j} = \bar{y}_{1,j}^3 + \bar{y}_{2,j}^3, \quad j = 1, \ldots, n. \tag{11}$$

このように生成した $\bar{y}$ に正規分布に従うノイズを加えてデータ $\boldsymbol{y}$ をつくる。

$$\boldsymbol{y}_j = \begin{bmatrix} \bar{y}_{1,j} \\ \bar{y}_{2,j} \\ \bar{y}_{3,j} \end{bmatrix} + \boldsymbol{v}_j, \quad \boldsymbol{v}_j \sim \mathcal{N}_{\boldsymbol{v}_j}(\boldsymbol{0}, 0.01\boldsymbol{I}) \tag{12}$$

また、利用するナレッジグラフとして単に

$$\mathcal{T} = \{(h = w_1, r = r_1, t = e_1), (w_2, r_1, e_1)\} \tag{13}$$

を用意する。w_1, w_2 はそれぞれデータの 1 次元目、2 次元目の特徴に対応するエンティティ、e_1 は何か任意のエンティティである。

以上をもとに、$q = 5, d = 2$ として次のような実験を行った。

1. 上記の手順でデータを生成する（$n = 400$）。
2. 訓練・検証用およびテスト用にデータを分割する。このとき、訓練・検証用データは範囲 $[-0.5, 1.5] \times [-0.5, 0.5]$ の 200 点、テスト用データは $[-0.5, 1.5] \times [0.5, 1.5]$ の 200 点を使用する（つまり、訓練時とテスト時で共変量シフトのようなことが起こっている設定）。訓練・検証用データは更にランダムに分割し、訓練用データ $\boldsymbol{Y}_{\mathrm{tr}} \in \mathbb{R}^{3\times 160}$、検証用データ $\boldsymbol{Y}_{\mathrm{val}} \in \mathbb{R}^{3\times 40}$ を用意する。テスト用データを $\boldsymbol{Y}_{\mathrm{te}} \in \mathbb{R}^{3\times 200}$ と表す。
3. $\boldsymbol{Y}_{\mathrm{tr}}$ から確率的 PCA のパラメタを学習する。このとき、次の三つの方法を試す：
   (a) データ共分散行列の固有値分解に基づく最尤推定 [Tipping 99]（$\mathcal{T}$ は使わない）
   (b) 勾配法による $-\mathcal{L}$ の最小化（$\mathcal{T}$ は使わない）
   (c) 勾配法による $-\mathcal{L}$ の最小化（$\mathcal{T}$ を使う）

   ただし、(b) および (c) では (a) の解を初期値とする。(c) で $\boldsymbol{e}$ の初期値はランダムに得る。さらに、(b) および (c) では勾配法の各ステップで $\boldsymbol{Y}_{\mathrm{val}}$ に対する再構成誤差を監視し、最小の検証再構成誤差を達成するパラメタを採用する。
4. 上記 (a)–(c) それぞれについて、$\boldsymbol{Y}_{\mathrm{te}}$ に対してテスト再構成誤差 $\boldsymbol{Y}_{\mathrm{te}}$ を計算して比較する。
5. 上記 1–3 を異なる乱数シードのもとで 100 回繰り返す。

3.2 実験結果

まず、方法 (b) および (c) による再構成誤差が方法 (a) によるものより明らかに小さくなったため、方法 (a) による再構成誤差については省略する。方法 (b) および (c) を比較するため、図 2 に、方法 (b) によるテストデータに対する平均再構成誤差から方法 (c) によるテストデータに対する平均再構成誤差を引いた値のヒストグラムを示す（なお、差をとる前の元の再構成誤差は 1.0 程度というオーダーである）。このとこから、ほとんどの場合にナレッジグラフを用いた方が用いない場合よりも再構成誤差が 10%前後小さくなることがわかる。参考までに、図 3 にある試行における訓練・検証用データとテスト用データ、および学習により得られた $\boldsymbol{W}$ に対応する平面をナレッジグラフを利用しない場合と利用する場合についてそれぞれ示す。

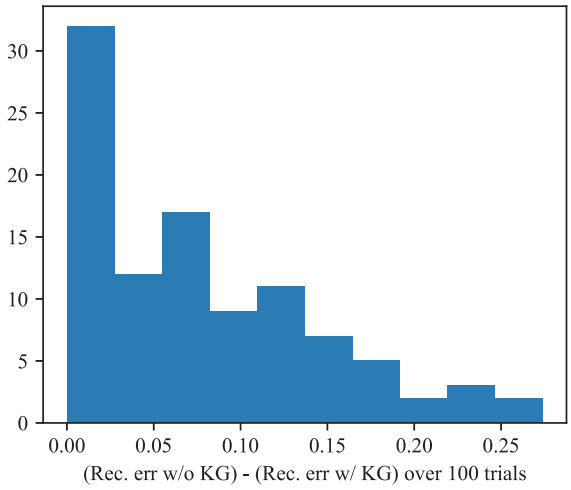


図 2: ナレッジグラフを使用した場合と使用しなかった場合のテスト再構成誤差の差に関するヒストグラム（正の値はナレッジグラフを使用した場合のテスト再構成誤差の方が使用しなかった場合より小さいことを示す）

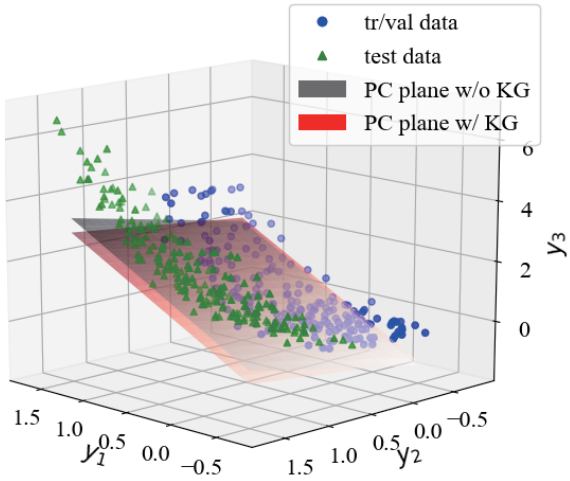


図 3: ある試行における訓練・検証データとテストデータ、および得られた $\boldsymbol{W}$ の示す平面

4. 今後の課題

本稿で紹介した方法では、$\boldsymbol{e}$ の事後分布推論についての方略が未完成である。局所的パラメタ $\boldsymbol{w}$ を点推定することにして、各局所的パラメタに対応するようなエンティティとナレッジグラフ中のエンティティとの関係のみを考慮するなら本稿で紹介した学習方法で十分であるかもしれないが、例えば各オブジェクトとナレッジグラフのエンティティとの関係も考慮したい際には、（オブジェクトに対応する $\boldsymbol{x}$ を確率変数として事後分布推論したい限りは）$\boldsymbol{e}$ の事後分布推論を考えなくてはな

らない。これについては、Pólya–Gamma data augmentation [Polson 13] による Gibbs サンプリングや、または確率的勾配変分ベイズ [Kingma 14] のような方法を検討したい。

また、当然実験も行う必要がある。まず、LVM 側の性能向上を示すという観点では、本稿で紹介したように PCA の再構成誤差が小さくなるなどの汎化性能向上を示したい。なお、本稿で作ったトイデータは結局線形モデルから生成されているために、ナレッジグラフの情報を用いない場合とあまり差が出なかったと考えられる。また、提案手法によってデータとナレッジグラフを同時に考慮できることから、KGE（によるタスク）の性能向上も期待される。これについても、実際利用されている大規模なナレッジグラフやそれに関連するデータを用いて検証したい。

参考文献

[Andrzejewski 11] Andrzejewski, D., Zhu, X., Craven, M., and Recht, B.: A Framework for Incorporating General Domain Knowledge into Latent Dirichlet Allocation using First-Order Logic, in *Proceedings of the 22nd International Joint Conference on Artificial Intelligence*, pp. 1171–1177 (2011)

[Bordes 13] Bordes, A., Usunier, N., Gracia-Durán, A., Weston, J., and Yakhnenko, O.: Translating Embeddings for Modeling Multi-relational Data, in *Advances in Neural Information Processing Systems*, Vol. 26, pp. 2787–2795 (2013)

[Dettmers 17] Dettmers, T., Minervini, P., Stenetorp, P., and Riedel, S.: Convolutional 2D Knowledge Graph Embeddings, arXiv:1707.01476 (2017)

[Foulds 15] Foulds, J., Kumar, S. H., and Getoor, L.: Latent Topic Networks: A Versatile Probabilistic Programming Framework for Topic Models, in *Proceedings of the 32nd International Conference on Machine Learning*, pp. 777–786 (2015)

[Fung 03] Fung, G. M., Mangasarian, O. L., and Shavlik, J. W.: Knowledge-Based Support Vector Machine Classifiers, in *Advances in Neural Information Processing Systems*, Vol. 15, pp. 537–544 (2003)

[He 15] He, S., Liu, K., Ji, G., and Zhao, J.: Learning to Represent Knowledge Graphs with Gaussian Embedding, in *Proceedings of the 24th ACM International on Conference on Information and Knowledge Management*, pp. 623–632 (2015)

[Kingma 14] Kingma, D. P. and Welling, M.: Stochastic Gradient VB and the Variational Auto-Encoder, in *Proceedings of the 2nd International Conference on Learning Representations* (2014)

[Mei 14] Mei, S., Zhu, J., and Zhu, X.: Robust RegBayes: Selectively Incorporating First-Order Logic Domain Knowledge into Bayesian Models, in *Proceedings of the 31st International Conference on Machine Learning*, No. 1, pp. 253–261 (2014)

[Polson 13] Polson, N. G., Scott, J. G., and Windle, J.: Bayesian Inference for Logistic Models Using Pólya–Gamma Latent Variables, *Journal of the American Statistical Association*, Vol. 108, No. 504, pp. 1339–1349 (2013)

[Tipping 99] Tipping, M. E. and Bishop, C. M.: Probabilistic Principal Component Analysis, *Journal of the Royal Statistical Society: Series B*, Vol. 61, No. 3, pp. 611–622 (1999)

[Varol 12] Varol, A., Salzmann, M., Fua, P., and Urtasun, R.: A Constrained Latent Variable Model, in *Proceedings of the 2012 IEEE Conference on Computer Vision and Pattern Recognition*, pp. 2248–2255 (2012)

[Xiao 16] Xiao, H., Huang, M., Hao, Y., and Zhu, X.: TransG : A Generative Model for Knowledge Graph Embedding, in *Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics*, pp. 2316–2325 (2016)

[Yang 15] Yang, B., Yih, tau W., He, X., Gao, J., and Deng, L.: Embedding Entities and Relations for Learning and Inference in Knowledge Bases, in *Proceedings of the 3rd International Conference on Learning Representations* (2015)

[Zhang 16] Zhang, F., Yuan, N. J., Lian, D., Xie, X., and Ma, W.-Y.: Collaborative Knowledge Base Embedding for Recommender Systems, in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 353–362 (2016)

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

作用によって生じる共変量シフトバイアスの補正

Covariate shift bias correction induced by action

比嘉　亮太
Ryota Higa

NEC データサイエンス研究所
NEC Data Science Research Laboratories

In this study, we consider the covariates shift caused by the action on the data problem. Also, consider the method of bias correction using the density ratio estimation.In the numerical experiments, the action actually cause unsteady/extrapolation problem of distribution. It shows that have a significant bias to the expected value evaluation.Further illustrates that the method using the density ratio even in the case of changing the data size and dimensions are effective.

1. はじめに

人工知能/機械学習における研究やビジネスにおいて、データの蓄積と活用手法の確立がますます重要になっている。解くべき課題の明確化と十分なデータをそろえることが、機械学習を用いた予測モデルを構築するためのスタートラインである。しかしながら、これまでにとったことの無い行動を含むリーンスタートアップやキャンペーン最適化、新素材探索などは、本質的にデータ取得が部分的になる。その様な場合は、機械学習の手法が適用困難であり、適用できたとしても適切な結果を導けない。

データ取得が部分的である場合に生じる問題として、共変量シフトによって生じるバイアスの問題が指摘されている。これは、予測と評価時の入力分布が異なる、つまり非定常な分布によって生じる期待値評価のズレである。密度比推定を用いたアプローチは、非定常な分布によって引き起こされる回帰や分類において有効であることが知られている [Shimodaira 00, Sugiyama 07]。

また、我々が知りたい量としては、データのミクロな分布そのものではない。これまでと異なったアプローチを行った場合の費用対効果や売り上げなどの期待値であるマクロな量である。期待値は、上昇、一定、減少など現状との相対的な比較によって評価できる。

本研究において、データに対する作用によって生じる共変量シフトの問題と密度比推定を用いたバイアス補正の方法について考察する。数値実験において、最適化の作用が実際に分布の非定常/外挿問題を引き起こし、期待値評価に大きなバイアスを与えることを示す。さらに、データサイズや次元を変えた場合においても密度比を用いた方法が有効であることを示す。

2. 問題設定

具体例として、以下の目的関数の期待値評価を考える。

$$l(a, x, y) := xy - ca \tag{1}$$

ここで、a は操作変数、x は入力、y は出力であり、c は定数とする。例えば、a はキャンペーン、x は収入、y は解約であり、$l(a, x, y)$ はキャンペーンの費用対効果の指標と成る。または、a は電圧、 x は電流、y は抵抗とする。操作変数 a に対して、あるアルゴリズムを適用した後の、l の期待値を

$$\mathbb{E}_F[l(a, x, y)] := \sum_{a,y} \int \mathrm{d}x p_F(a, x, y) l(a, x, y) \tag{2}$$

と定める。本問題は、上記の期待値を評価することが目的である。しかし、a に対するアルゴリズム適用前のイニシャルデータセット $\mathcal{D}_I = \{a_n, x_n, y_n\}$ は得られているが、操作後のデータセットは部分的 $\mathcal{D}_F = \{a_n, x_n\}$ であるとする。

2.1 仮定

出力 y の条件付き分布において、以下の仮定を置く。

$$p_I(y|x, a) = p_F(y|x, a) \tag{3}$$

ここで、添え字の I は a の操作前、F は a の操作後とする。つまり、出力結果においては、保存則が成立りつしているとする。1 つの方法としては、過去のデータから $p(y|x, a)$ を推定して、それをデータを生成するシミュレータとみなして a 操作後の期待値を求める方法がある。しかしながら、推定したモデルに対して操作変数を変えて期待値評価を行うと、データの無い部分の外挿問題に対応してしまい、過大、過小評価の結果となる。以下では、密度比を用いたアプローチを示す。

3. 密度比を用いた定式化

操作変数 a によって、$p(a, x, y)$ に対して定常な分布は仮定できない。以下のような状況を考える。

$$p_I(a, x, y) \neq p_F(a, x, y) \tag{4}$$

ここで、両者の比を γ とすると、y の条件付分布の仮定より

$$\gamma(a, x) := \frac{p_F(y|a, x) p_F(a, x)}{p_I(y|a, x) p_I(a, x)} \tag{5}$$

$$= \frac{p_F(a, x)}{p_I(a, x)} \tag{6}$$

となり、y の情報が不要になることがわかる。

連絡先: 比嘉　亮太、NEC データサイエンス研究所、神奈川県川崎市中原区下沼部 1753、email:r-higa@ct.jp.nec.com

密度比 $\gamma(a,x)$ を用いると、(2) は

$$\begin{aligned}\mathbb{E}_F[l(a,x,y)] &= \sum_{a,y}\int \mathrm{d}x p_F(a,x,y)l(a,x,y)\\ &= \sum_{a,y}\int \mathrm{d}x \frac{p_F(a,x,y)}{p_I(a,x,y)} p_I(a,x,y)l(a,x,y)\\ &= \sum_{a,y}\int \mathrm{d}x \gamma(a,x)p_I(a,x,y)l(a,x,y) \quad (7)\\ &= \mathbb{E}_I[\gamma(a,x)l(a,x,y)] \quad (8)\end{aligned}$$

となる。ただし、$\gamma(x,a) < \infty$ とする。つまり、本来知りたい操作後の期待値は、操作前の期待値と γ によって評価できることを示している。これは、y に対して手元に得られているデータの活用方法やシミュレータなどのドメイン知識などの助けを借りることによって、マクロな期待値の評価は可能であることを意味している。

仮定を検証する方法としては、$r(x,a) = 1$ となる場合において、操作前後の期待値の差であるバイアス

$$B = \mathbb{E}_F[l(a,x,y)] - \mathbb{E}_I[\gamma(a,x)l(a,x,y)] \quad (9)$$

がゼロに成ることを確かめればよい。これは、y を生成するモデルに対する改良にも使える。例えば、仮説の再検討において、時間 t を与えた $p_I(y|x,a) = p_F(y|x,a)\exp(-\alpha t)$ として、パラメータ α を決定する問題とする。ミュレータと現実の環境の変化への適用といった、シミュレータ開発者にとっても、データ主導による改良できる可能性を示している。

4. 数値実験

密度比を用いた方法と、仮説を用いて y のモデルを推定する方法の比較を行い、分布のズレによるバイアス補正の効果を実験的に確かめる。

4.1 設定

検証の実験として、以下の様な設定を行う。

$$a \sim Bernoulli(a|\mu_a) \quad (10)$$

$$x|a \sim \mathcal{N}(x|\mu_a, \sigma_a^2) \quad (11)$$

$$y|a,x \sim Bernoulli(y|\mu_a, x) \quad (12)$$

$$(13)$$

操作変数 a に対しては、x 全体の上位 K[%] にたいして $a = 1$、それ以外を $a = 0$ とする操作アルゴリズム (以下、Top of K と呼ぶ) を用いる。図 1 は、操作前後においての $p(a,x)$ 分布の変化である。Top of K の適用後の y は得られないとする。

4.2 結果

設定した人工モデルに対して、データサイズを変更しながら、モンテカルロにより 1000 回の試行によって目的関数の期待値を評価した。共変量シフトを用いたアプローチとの比較手法としては、$p(y|x,a)$ の保存則を用いて、捜査前のデータより、ロジスティック回帰、SVM(RBF), Deep(4 層) により推定した。

結果は、2 で与えられている。黒が操作前、赤が操作後の期待値である。青が共変量シフトを用いた期待値評価であり、データサイズ 100 で Top of K 適用後の期待値評価が出来ている。一方、ロジスティック (緑)、SVM(茶), Deep(橙) は過大、過小に期待値を見積もる傾向にあることが確かめられた。

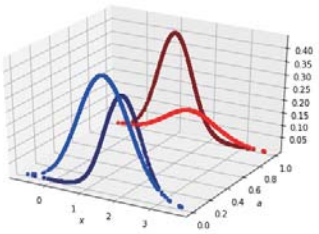


図 1: Top of K による分布の変化。$a = 0$ の x の分布は左側へシフトし、$a = 1$ の x の分布は右側へシフトしている。

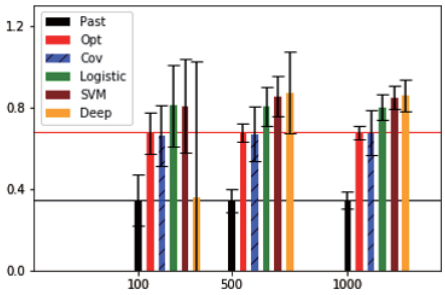


図 2: サンプル数を 100, 500, 1000 と変化させた場合での共変量シフトとロジスティック、SVM, Deep との比較。赤が正しい結果であり、共変量シフトが最もバイアスが補正できている結果である。

4.3 考察

直接 y を推定することは、分布の非定常性に加えデータの偏りなどで生じる外挿問題にダイレクトに挑戦する難しい問題である。一方、密度比を用いた期待値評価は、観測されたデータの内挿問題であり、分布の詳細な情報をあきらめる代わりに予測の難易度は下がる。マクロな量である期待値の評価を行う場合は、分布の普遍的な部分やドメイン知識で補える部分できりわけるアプローチは、既存のデータを活用する上で有効な手法であることが経験的に確かめられた。

5. おわりに

本研究では、密度比を用いたデータの活用が、将来の期待値評価に有効であることを示した。今後は、本研究の一般的な定式化を含め、逐次的な操作を含む期待値評価や、目的関数の推定を含む問題へ拡張する予定である。

参考文献

[Shimodaira 00] H. Shimodaira, “Improving predictive inference under covariate shift by weighting the log-likelihood function,” J. Stat. Plan. Inference, vol. 90, no. 2, pp. 227244, 2000.

[Sugiyama 07] M. Sugiyama, M. Krauledat, and K.-R. Mller, “Covariate shift adaptation by importance weighted cross validation,” J. Mach. Learn. Res., vol. 8, pp. 9851005, 2007.

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

線形可解マルコフ決定過程のためのバッチ強化学習

Batch Reinforcement Learning for Linearly Solvable MDP

西智樹 *1 Tomoki Nishi　大滝啓介 *1 Keisuke Otaki　吉村貴克 *1 Takayoshi Yoshimura

*1豊田中央研究所
Toyota Central R&D Labs., Inc.

Linearly solvable Markov decision process (L-MDP) is an essential subclass of MDP to find a better policy efficiently. We first develop a novel batch reinforcement learning algorithm for L-MDP. The algorithm simultaneously learns a state value function and a predictor of state values at next step by using pre-collected data. We evaluate our method on traffic signal control domain in a single intersection with the traffic simulator SUMO. Our experiment demonstrates that our method finds the policy on the domain efficiently.

1. はじめに

線形可解マルコフ決定過程 (L-MDP) は Todorov によって提案されたマルコフ決定過程 (MDP) の一種である [Todorov 06]．L-MDP はベルマン方程式を，規定の行動を実施時のある状態と次状態に関する線形差分方程式に変形することで，ダイナミクスが既知の場合には最適政策を効率的に求められる．また文献 [Todorov 06] ではさらに，ダイナミクスが未知の場合の強化学習として Z-learning が提案され，Q-learning [Watkins 92] よりも効率的に政策を学習できることが報告されている．

一方で，Fitted Q-iteration [Riedmiller 05] に代表されるバッチ強化学習は，予め収集したデータに基づき，オフラインでより良い行動を学習することができる強力な枠組みの一つである．自動運転・交通制御など学習中に事故や渋滞を引き起こす可能性がある問題では，有用な学習手法である [Riedmiller 07]．筆者は，先に述べた L-MDP に対し，連続状態行動空間におけるエージェントのダイナミクスが既知の場合のバッチ強化学習 passive Actor-Critic を提案し，自動運転の混雑時の高速道合流において有用であることを示した [Nishi 17]．しかしながら，離散行動空間における L-MDP のためのバッチ強化学習はこれまで提案されておらず，交通信号機など行動が離散的に表現される場合には利用することができなかった．

そこで本稿では，離散行動空間における L-MDP のためのバッチ強化学習 Fitted Z-learning を提案する．本手法は，線形化されたベルマン方程式に基づく状態価値の学習と，ある状態である行動を選択した際の遷移先の状態価値の学習とを同時に行うことで政策を学習する．また提案手法の有効性を検証するために，シミュレーションを用いた 1 交差点での信号機制御で評価を行う．

2. 準備

2.1 マルコフ決定過程と Q-learning

MDP は $\langle \mathcal{S}, \mathcal{A}, T, R, \gamma \rangle$ の 5 つの要素の組で表現できる．$\mathcal{S}$ は状態空間，$\mathcal{A}$ は行動空間，$T : \mathcal{S} \times \mathcal{A} \times \mathcal{S} \to [0, 1]$ は状態遷移モデル，$R : \mathcal{S} \times \mathcal{A} \times \mathcal{S} \to \mathbb{R}$ はコストモデル，γ はコストの 1 ステップ毎の割引率を表す．また政策 $\pi : \mathcal{S} \to \mathcal{A}$ は状態 $s \in \mathcal{S}$ の時に行動 $a \in \mathcal{A}$ を出力する関数である．マルコフ決定過程における基本的な問題設定は，状態 s が与えられた時に，目的関数 J を最小化する政策 $\pi^* : \mathcal{S} \to \mathcal{A}$ を発見することである．その時の目的関数は，

$$J \coloneqq \mathbb{E}_\pi \left[\sum_{k=0}^{\infty} \gamma^k r_k \right],$$

で表される無限ホライゾンにおけるコストの累積和の期待値がよく用いられる．ここで，$\mathbb{E}_\pi[\cdot]$ は政策 π の下での期待値，r_k は時刻 k での即時コストを表す．政策 π の下での状態価値関数 V^π，及び行動価値関数 Q^π を下記のように定義すると，

$$V^\pi(s) \coloneqq \mathbb{E}_\pi \left[\sum_{k=0}^{\infty} \gamma^k r_{t+k} | s_t = s \right] \quad s \in \mathcal{S},$$

$$Q^\pi(s, a) \coloneqq \mathbb{E}_\pi \left[\sum_{k=0}^{\infty} \gamma^k r_{t+k} | s_t = s, a_t = a \right] \quad s \in \mathcal{S}, a \in \mathcal{A},$$

時刻 t における最適な政策 $\pi^*(s_t)$ 及び，その下での行動価値関数 $Q^*(s_t, a_t)$，状態価値関数 $V^*(s_t)$ はベルマン方程式

$$Q^*(s_t, a_t) = r(s_t, a_t) + \mathbb{E}_{s_{t+1} \sim p(s_{t+1}|s_t, \pi^*(s_t))} \left[\gamma V^*(s_{t+1}) \right], \tag{1}$$

$$V^*(s_t) = \min_{a_t \in \mathcal{A}} Q^*(s_t, a_t),$$

$$\pi^*(s_t) = \arg\min_{a_t \in \mathcal{A}} Q^*(s_t, a_t), \tag{2}$$

を満たす．

モデルフリー強化学習の最もよく知られた方法である Q-learning は，ベルマン方程式に基づき計算される TD 誤差 $\mathcal{E}$ を減少させるように，行動価値関数 Q の推定値を更新する手法である．

$$\mathcal{E}_t = Q(s_t, a_t) - \left(r(s_t, a_t) + \gamma \max_{a \in \mathcal{A}} Q(s_{t+1}, a) \right).$$

2.2 線形可解マルコフ決定過程と Z-learning

L-MDP は $\langle \mathcal{S}, \mathcal{U}, T, R, \gamma \rangle$ の 5 つの要素の組で表現される．但し $\mathcal{U}$ は L-MDP における行動空間であり，他の要素は通常の MDP と同様である．L-MDP は通常の MDP に下記の 2 つの仮定を追加した MDP である．

連絡先: 西智樹，豊田中央研究所，愛知県長久手市横道 41-1，nishi@mosk.tytlabs.co.jp

1. $p(s_{t+1}|s_t, \mathbf{u}_{s_t}) \coloneqq p(s_{t+1}|s_t, \pi_0)\exp(\mathbf{u}_{s_t})$,
2. $r(s_t, \mathbf{u}_{s_t}) \coloneqq q(s_t) + \lambda \mathrm{KL}(p(s_{t+1}|s_t, \pi_0)||p(s_{t+1}|s_t, \mathbf{u}_{s_t}))$,

但し, $\mathbf{u}_{s_t} \in \mathbb{R}^{|\mathcal{S}|}$ は状態 s_t における行動ベクトル, $p(s_{t+1}|s_t, \pi_0)$ 及び $p(s_{t+1}|s_t, \mathbf{u}_{s_t})$ はそれぞれ予め設計者が決めた政策 π_0 に基づいて行動した時の状態遷移の確率分布，行動 $\mathbf{u}_{s_t}$ をとった時の状態遷移の確率分布，$q(s_t)$ は状態にのみ依存した状態コスト，$\mathrm{KL}(\cdot||\cdot)$ は KL-divergence．また λ は，状態コスト $q(s_t)$ に対する KL-divergence で表される行動コストの，相対的な大きさを調整するためのパラメータである．1 つめの仮定は，L-MDP における行動 $\mathbf{u}_{s_t}$ は，MDP の行動とは異なり，状態 s からある状態 s' への状態遷移確率をどれくらい変化させるかであり，その大きさが $\exp(\mathbf{u}_{s_t})$ で表されるとする仮定である．また 2 つめの仮定は，L-MDP の即時コスト関数 $r(s_t, \mathbf{u}_{s_t})$ は，状態コスト $q(s_t)$ と，$p(s_{t+1}|s_t, \pi_0)$ と $p(s_{t+1}|s_t, \mathbf{u}_{s_t})$ の KL-divergence で表される行動コスト，の 2 つに分解できるとする仮定である．

上記の仮定から，最適な政策 π_L^* は，

$$Z^*(s_t) = \exp(-q(s_t)/\lambda)\mathbb{E}_{s_{t+1}\sim p(s_{t+1}|s_t,\pi_0)}\left[(Z^*(s_{t+1}))^\gamma\right], \tag{3}$$
$$Z^*(s_t) \coloneqq \exp(-V^*(s_t)/\lambda),$$

で表される線形化ベルマン方程式を満たすことが導かれる (詳細は [Todorov 06] を参照のこと)．その時最適な政策 $\pi_L^*(s_t, s_{t+1})$ 及びその政策の下での状態遷移は，

$$\pi_L^*(s_t, s_{t+1}) = \left(V^*(s_t) - q(s_t) - \gamma V^*(s_{t+1})\right)/\lambda, \tag{4}$$
$$p(s_{t+1}|s_t, \pi_L^*) = \frac{p(s_{t+1}|s_t, \pi_0)Z^*(s_{t+1})}{\exp(q(s_t)/\lambda)Z^*(s_t)}, \tag{5}$$

となる．

政策 π_0 に従う際の状態遷移確率 $p(s_{t+1}|s_t, \pi_0)$ と状態コスト $q(s_t)$ が既知である場合には，離散状態行動空間における L-MDP の状態コスト V と最適政策 π_L^* は，式 (3) の Z^* についての固有値問題を解くことで求められる．また連続状態行動空間の場合においても，Z 関数 $Z(s_t)$ を基底関数の線形和により近似することで，効率的に学習できる [Todorov 09]．

また，状態遷移確率 $p(s_{t+1}|s_t, \mathbf{u}_{s_t})$ と即時コスト関数 $q(s_t)$ が未知である場合は，予め決められた政策 π_0 に従って行動した時のデータに基づいて，Z 関数を学習する Z-learning が適用できる．Z-learning は，線形化ベルマン方程式に基づき計算される TD 誤差 $\mathcal{E}_L$ を減少させるように，Z 関数の推定値を更新する．

$$\mathcal{E}_{L,t} = Z(s_t) - \exp(-q(s_t)/\lambda)(Z(s_{t+1}))^\gamma.$$

3. 提案手法 Fitted Z-learning

L-MDP のためのバッチ強化学習として，Fitted Z-learning を提案する．Z-learning は，既定の政策 π_0 に従って行動した際の状態遷移のデータに基づき，Z 関数を学習することができる．また，状態コストを既知とすると，L-MDP における政策 π_L は，式 (4) により学習した Z 関数を用いて求められる．さらに $p(s_{t+1}|s_t, \pi_0)$ を既知とすると，政策の下での状態遷移は，式 (5) により算出できる．しかしながら，L-MDP における行動は状態遷移に与える影響の強さであり，エージェントが具体的に取り得るどの行動（MDP の意味での行動）を取れば，式 (5) から算出される望ましい状態遷移を実現することができるかは自明ではない．

行動価値関数 $Q^*(s_t, a_t)$ が学習出来れば，MDP における政策 π^* は式 (2) により求められる．ここで，即時コスト $r(s_t)$ が状態コスト $q(s_t)$ で近似できると仮定する．これは，λ を小さく設定することで常に実現できる．

$$r(s_t, a_t) = q(s_t) + \lambda \mathrm{KL}(p(s_{t+1}|s_t, \pi_0)||p(s_{t+1}|s_t, \mathbf{u}_{s_t})) \approx q(s_t). \tag{6}$$

この時式 (6) の仮定により行動価値関数は，

$$\begin{aligned} Q^*(s_t, a_t) &= r(s_t, a_t) + \mathbb{E}_{s_{t+1}\sim p(s_{t+1}|s_t,\pi^*)}\left[\gamma V^*(s_{t+1})\right], \\ &\approx q(s) + \mathbb{E}_{s_{t+1}\sim p(s_{t+1}|s_t,\pi^*)}\left[\gamma V^*(s_{t+1})\right], \end{aligned}$$

と近似できる．また近似した行動価値関数に基づく政策 $\hat{\pi}$ は，

$$\begin{aligned} \hat{\pi}(s_t) &= \arg\min_{a_t\in\mathcal{A}}\left(q(s_t) + \mathbb{E}_{s_{t+1}\sim p(s_{t+1}|s_t,\hat{\pi})}\left[\gamma V(s_{t+1})\right]\right), \\ &= \arg\min_{a_t\in\mathcal{A}}\mathbb{E}_{s_{t+1}\sim p(s_{t+1}|s_t,\hat{\pi})}\left[V(s_{t+1})\right], \\ &= \arg\max_{a_t\in\mathcal{A}}\mathbb{E}_{s_{t+1}\sim p(s_{t+1}|s_t,\hat{\pi})}\left[Z(s_{t+1})\right], \end{aligned}$$

と書き直すことができる．この政策は，状態 s_t において，次状態 s_{t+1} での Z 関数の期待値が最大となる行動を選択することを意味している．つまり，即時コスト $r(s_t)$ が状態コスト $q(s_t)$ で近似できる場合には，状態 s_t においてある行動 a_t をとった時の次状態 s_{t+1} での Z 値を予測することで，行動を決定することができる．

提案する Fitted Z-learning は，2 つの関数，

- 現状態 s_t の Z 値を推定する関数 $\hat{Z}(s_t; \boldsymbol{\theta})$,
- 行動 a_t を選択した時の次状態 s_{t+1} での Z 値を予測する関数 $\hat{Z}(s_t; a_t, \boldsymbol{\phi})$,

の学習を通して政策 π を学習する．ただし，$\boldsymbol{\theta}$ 及び $\boldsymbol{\phi}$ は共に関数近似のためのパラメータである．Z-learning と同様に，$\boldsymbol{\theta}$ は，L-MDP におけるベルマン方程式から算出される TD 誤差を小さくするよう学習する．$\boldsymbol{\phi}$ は，時刻 t で行動 a_t を選択した時の次状態 s_{t+1} の $\hat{Z}(s_{t+1}; \boldsymbol{\theta})$ の値と $\hat{Z}(s_t; a_t, \boldsymbol{\phi})$ との最小 2 乗誤差を小さくするように学習する．本稿ではさらに multi-step Q-learning [Peng 96] を参考に，連続した T ステップの状態遷移を考慮してパラメータの更新を行う multi-step Fitted Z-learning を用いた．

詳細なアルゴリズムを Algorithm 1 に示す．

4. 数値実験

本節では 1 交差点における信号機制御タスクにより Fitted Z-learning の有効性を検証する．

4.1 ニューラルネットワークの構成

Fitted Z-learning の $\hat{Z}(s; \boldsymbol{\theta})$ 及び $\hat{Z}(s; a, \boldsymbol{\phi})$ をニューラルネットワークでモデリングし，学習した．ニューラルネットワークの構成を図 1 に示す．$\hat{Z}(s; \boldsymbol{\theta})$ と $\hat{Z}(s; a, \boldsymbol{\phi})$ は，状態 s の Z 値と，状態 s で行動 a を選択した時の次状態の Z 値の推定値であり，この 2 つの Z 値は相互に関連するため，ニューラルネットワークの多くのパラメータは共有出来ると予想される．そこで Dueling Network Architectures [Wang 15] を参考に，図 1 のように下位層のネットワークを共有したフォーク

Algorithm 1 multi-step Fitted Z-learning

procedure 予め収集したデータセット $\mathcal{D}$ から政策を学習
  パラメータ $\boldsymbol{\theta}$ 及び $\boldsymbol{\phi}$ を初期化
  for エピソード $i = 1$ to N **do**
    $\mathcal{D}$ から T ステップ連続したデータをランダムに抽出:
      $\{(i, s_1, a_1, s_2, q_1), ..., (i, s_T, a_T, s_{T+1}, q_T)\} \sim \mathcal{D}$
    パラメータの勾配を初期化: $d\boldsymbol{\theta} \leftarrow \mathbf{0}$
    $R \leftarrow \hat{Z}(s_{T+1}; \boldsymbol{\theta})$
    for ステップ $t = T$ to 1 **do**
      $R \leftarrow \exp(-q_t/\lambda)R^{\gamma}$
      TD 誤差 $\mathcal{E}_{L,t}$ を計算: $\mathcal{E}_{L,t} \leftarrow \left(R - \hat{Z}(s_t; \boldsymbol{\theta})\right)$
      パラメータの勾配 $d\boldsymbol{\theta}$ を更新: $d\boldsymbol{\theta} \leftarrow d\boldsymbol{\theta} + \partial \mathcal{E}_{L,t}^2 / \partial \boldsymbol{\theta}$
      誤差 δ_t を計算:
        $\delta_t \leftarrow \left(\hat{Z}(s_{t+1}; \boldsymbol{\theta}) - \hat{Z}(s_t; a_t, \boldsymbol{\phi})\right)$
      パラメータの勾配 $d\boldsymbol{\phi}$ を更新: $d\boldsymbol{\phi} \leftarrow d\boldsymbol{\phi} + \partial \delta_t^2 / \partial \boldsymbol{\phi}$
    end for
    パラメータ $\boldsymbol{\theta}, \boldsymbol{\phi}$ を $d\boldsymbol{\theta}/T, d\boldsymbol{\phi}/T$ に基づき更新
  end for
end procedure

型のネットワークを用いた．つまり，下位層のパラメータは，$\boldsymbol{\theta}$ 及び $\boldsymbol{\phi}$ で同じ値を用い，$\boldsymbol{\theta}$ 及び $\boldsymbol{\phi}$ の更新時に更新される．また，全ての中間層は，全ノードが結合された全結合層 (Fully Connected Layer, FCL) を用い，最終層以外の活性化関数は全て ReLU$(\cdot) \coloneqq \max(0, \cdot)$ を用いた．出力層の活性化関数は，$Z(s) > 0, \forall s \in \mathcal{S}$ であるため，$\hat{Z}(s; \boldsymbol{\theta})$ 及び $\hat{Z}(s; a, \boldsymbol{\phi})$ 共に，Softplus$(\cdot) \coloneqq \log(1 + \exp(\cdot))$ を用いた．

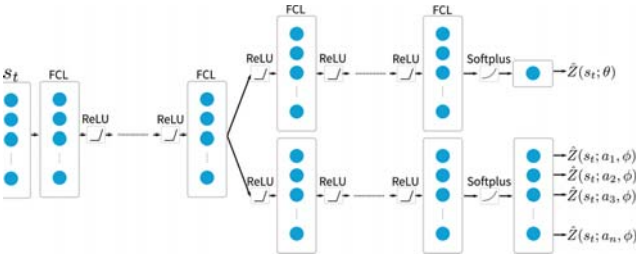


図 1: Fitted Z-learning のためのネットワークの構成

4.2 実験設定

従来手法 Q-learning と提案手法 Fitted Z-learning に対し，学習の安定性，速度，性能の 3 つの観点での比較評価を行った．評価タスクとしては，上下左右に伸びた 4 道路各方向 1 車線ずつ，計 8 車線が結合している道路（図 2）において，交差点の信号機を制御し，全道路の交通量を最大化するタスクを用いた．以下で，評価タスクの詳細を述べる．

各道路は直進のみができ，右左折できない道路とした．また状態は各車線を走行する全車両の平均速度（8 状態変数）及び各車線で信号待ちしている車両の台数（8 状態変数）の計 16 次元のベクトルで表現し，行動は（縦方向，横方向）の道路の信号機の色がそれぞれ（青，赤）または（赤，青）の 2 つとした．各車両の出発地及び目的地はランダムに各車線の端点を選択した．信号を制御した際の交通流をシミュレートするために交通流シミュレータ SUMO [Krajzewicz 02] を用いた．また Fitted Z-learning は，SUMO により生成された固定サイクル長の信号機で制御した 5,000,000 秒（約 1400 時間）のデータを用いて 40,000 回ニューラルネットワークのパラメータを更新した．本実験では，実際の街中で一般に用いられている固定サイクル長の信号機，Q-learning により学習された信号機

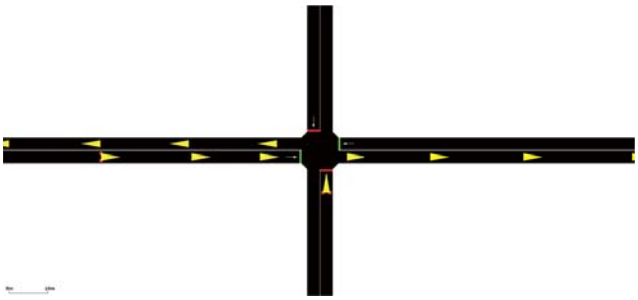


図 2: 1 交差点の信号機制御タスク．上下左右に伸びた 4 道路各方向 1 車線ずつの計 8 車線が結合した交差点の信号機を制御するタスク．三角で示された車両が交差点通過するために待つ時間を最小化するような制御方法を学習する．

と比較実験を行った．Q-learning は Fitted Z-learning で用いたニューラルネットワークと層数が同じになるよう中間層が 4 層のニューラルネットワークを用いた．

4.3 実験結果

4 道路が各方向 1 車線ずつ計 8 車線が結合された交差点の信号機制御を Q-learning, Fitted Z-learning で各 20 回学習した．まず 40,000 ステップ以内に学習初期の政策の平均待ち時間に対して，8 割以下の待ち時間を達成できた場合を学習の成功とし，各手法の成功率を図 3 に示す．この結果から Fitted Z-learning は Q-learning に比べ安定して学習ができることが分かった．これは，Q-learning は状態と行動を入力とする状態行動価値関数を学習する必要があるのに対し，Fitted Z-learning は状態のみを入力とする Z 関数の学習を通して政策を学習するため，学習が容易になり，学習が安定したのではないかと推察される．

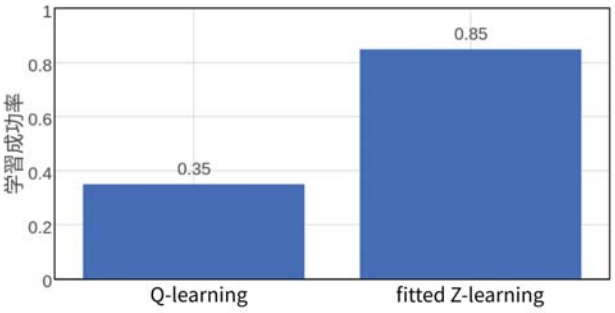


図 3: 学習の成功率

また，学習が成功した時のみの学習曲線の平均，及び最後の繰り返し回数時点での性能の平均値と標準偏差を，それぞれ図 4 に示す．図 4(左図) から Fitted Z-learning は予め収集したデータのみから Q-learning と同等の，固定サイクルに比べ 2 秒以上短い待ち時間を達成する政策を学習できた．また図 4(右図) から，街中で一般に見られる固定サイクルの信号機で制御された交差点のデータを用いることで，Fitted Z-learning は Q-learning に比べ効率的にパラメータを学習できることが分かった．これも上記の学習が安定した理由と同様，Fitted Z-learning の方が学習が容易であったためではないかと推察される．

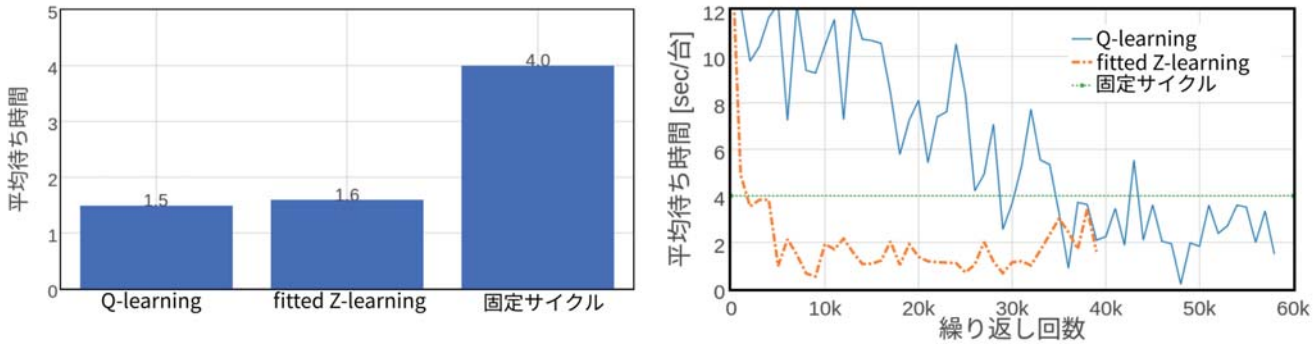


図 4: 1 交差点信号機制御の実験結果．(左図) 学習後の各手法で信号制御した場合の平均待ち時間．Fitted Z-learning は予め収集したデータのみから Q-learning と同等の，固定サイクルに比べ 2 秒以上短い待ち時間を達成する政策を学習できた．(右図)Fitted Z-learning および Q-learning の学習曲線．Fitted Z-learning は Q-learning に比べ少ない繰り返し回数で同等の政策を学習することができた．但し Q-learning は繰り返し回数 4,0000 の時点では収束していなかったため，60,000 まで学習を継続した．

5. 結論

本稿では，離散行動空間における線形可解マルコフ決定過程のためのバッチ強化学習として Fitted Z-learning を提案した．Fitted Z-learning は線形可解マルコフ決定過程から導かれる線形化ベルマン方程式に基づきマルコフ決定過程での状態価値関数に相当する Z 関数と共に，ある行動を選択した時の次状態での Z 関数の値を予測する関数を同時に学習する．提案手法を評価するために 1 交差点の信号機制御で実験を行った．その結果，提案手法はデータのみから固定サイクルに比べ，2 秒以上待ち時間が短い政策を Q-learning より効率的に学習できることが確認できた．

参考文献

[Krajzewicz 02] Krajzewicz, D., Hertkorn, G., Rössel, C., and Wagner, P.: SUMO (Simulation of Urban MObility) An open-source traffic simulation Car-Driver Model, *Proc of the 4th Middle East Symposium on Simulation and Modelling*, pp. 183–187 (2002)

[Nishi 17] Nishi, T., Doshi, P., James, M., and Danil, P.: Actor Critic for Linearly-Solvable Continuous MDP with Partially Known Dynamics, *arXiv preprint:1706.01077* (2017)

[Peng 96] Peng, J. and Williams, R. J.: Incremental multi-step Q-learning (1996)

[Riedmiller 05] Riedmiller, M.: Neural fitted Q iteration - First experiences with a data efficient neural Reinforcement Learning method, in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* (2005)

[Riedmiller 07] Riedmiller, M., Montemerlo, M., and Dahlkamp, H.: Learning to Drive a Real Car in 20 Minutes, in *2007 Frontiers in the Convergence of Bioscience and Information Technologies*, pp. 645–650, IEEE (2007)

[Todorov 06] Todorov, E.: Linearly-solvable Markov decision problems, *Advances in neural information processing systems*, pp. 1369–1376 (2006)

[Todorov 09] Todorov, E.: Eigenfunction approximation methods for linearly-solvable optimal control problems, in *2009 IEEE Symposium on Adaptive Dynamic Programming and Reinforcement Learning, ADPRL 2009 - Proceedings*, pp. 161–168 (2009)

[Wang 15] Wang, Z., Schaul, T., Hessel, M., Hasselt, van H., Lanctot, M., and Freitas, de N.: Dueling Network Architectures for Deep Reinforcement Learning, No. 9 (2015)

[Watkins 92] Watkins, C. J. C. H. and Dayan, P.: Q-learning, *Machine learning*, Vol. 8, No. 3-4, pp. 279–292 (1992)

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

Cappuccino：構造データに対するブートストラッピング手法

Cappuccino: Bootstrapping from Structural Data

花房 諒 *1　　小山田 昌史 *2
Ryo Hanafusa　　Masafumi Oyamada

*1関西学院大学 大学院理工学研究科
Graduate School of Science and Technology, Kwansei Gakuin University

*2日本電気株式会社 データサイエンス研究所
Data Science Research Laboratories, NEC Corporation

We present *Cappuccino*, a bootstrapping method for structural data, which extracts target pairs of words by treating structures in data as patterns that connect pairs of words. The task we tackle in this paper is relation extraction from structural data such as presentation slides and HTML files. In order to exploiting the structures for bootstrapping, we convert structural data to graphs, and apply frequent subgraph mining to the graphs to calculate reliabilities of word pairs and patterns. Experimental results of a relation extraction task show that Cappuccino outperforms a previous method.

1. 概要

本稿は，プレゼンテーションスライドや HTML のような構造データからの関係抽出タスクを扱い，構造データに対するブートストラッピング手法である Cappuccino を提案する．ブートストラッピング法は，目的の関係をもつ単語ペア (インスタンス) の集合と文集合から，従来は人手で作っていたインスタンスの抽出ルール (パターン) を生成することにより，関係抽出タスクにおいて人手による作業のコスト削減を実現する．そのために，与えられたインスタンスを繋ぐパターン集合を信頼度にもとづいて抽出し，同様に，抽出されたパターンに繋がれるインスタンス集合を信頼度にもとづいて抽出する．従来の手法は，テキストデータのみを対象としていたが，Cappuccino は構造データを対象とする．

Cappuccino は，データがもつ構造 (例：リスト構造) をパターンとすることで，インスタンスの抽出を行う．構造をパターンとして扱うために構造データをグラフへ変換し，そのグラフに頻出サブグラフマイニングを適用することにより，インスタンスとパターンの信頼度計算を可能にする．グラフのノードラベルが単語を表し，エッジラベルがパターンの一部分を表す．また，構造データ内に存在する通常の文に対しては，単語ごとに分解し，別々のノードを生成することでインスタンスの抽出を可能にする．

本稿では，実験のために作成した人工的な HTML ファイルを用いて，文字列のパターンだけを用いる従来のブートストラッピング手法と比較を行い，データがもつ構造を利用する Cappuccino が高い性能になることを確認する．本稿の主な貢献を以下にまとめる．

- ブートストラッピング法において，構造データをグラフへ変換し，データがもつ構造をパターンとして扱うことにより，非構造データを対象にした従来のブートストラッピング手法では抽出できないパターンやインスタンスを抽出できる．

連絡先: 花房　諒，関西学院大学　大学院理工学研究科，rhanafusa@kwansei.ac.jp
連絡先: 小山田 昌史 (NEC)，m-oyamada@cq.jp.nec.com

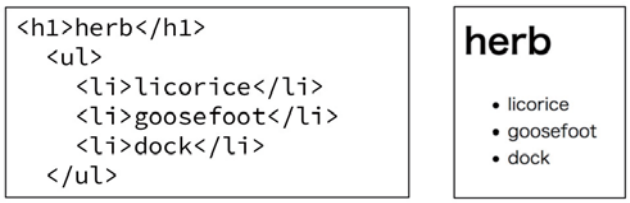


図 1: 構造データの例である HTML．左はソースコードの一部．

- 構造データからの関係抽出において，与えられたインスタンス集合からパターン抽出を行うため，構造のパターンを人手で指定することなく，インスタンスが抽出できる．

2. 背景

テキストデータを対象とした関係抽出は，一般的な自然言語処理のタスクである．例として，(apple, fruit) のような上位下位関係にあるペアの集合をテキストデータから抽出する問題が挙げられる．このような問題に対して，目的の関係をもつペア (インスタンス) をテキストデータから人手により探索することや，ペアを列挙して 1 つずつラベルを付けていくという手段はコストが高い．そのため，自動的にインスタンスを抽出する方法として，ブートストラッピング手法による関係抽出が広く行われており [Hearst 92, Riloff 99, McIntosh 11]，現在は Pantel が考案した Espresso [Pantel 06] が主に評価の基準となっている．これらの従来のブートストラッピング手法では，テキストデータのみを対象としており，発表で用いられるスライドや HTML のような構造データ (図 1) を対象とはしていない．そのため，従来手法を構造データへ適用し，関係抽出を行ったとしても獲得できるインスタンスには限界がある．本稿の提案方式 Cappuccino は，構造データがもつ構造を活用することにより，関係抽出タスクの性能向上を図る．

構造データを対象とした関係抽出としては，Wu が提案した，構造データから知識構築を行う Fonduer [Wu 17] が存在する．ただし，Fonduer を利用してインスタンスを抽出する

ためには，そのインスタンスを繋ぐ構造パターン (例：リスト構造) や条件を人手により指定しなければならない．すなわち，人手を利用するためコストが高いことが問題となる．本稿で提案する Cappuccino は，構造パターンも自動的に抽出するブートストラッピング法であるため，人手による作業のコスト削減に役立てることができる．

本稿では，構造データに対するブートストラッピング手法である Cappuccino を提案し，既存手法である Espresso と比較して Cappuccino が高い性能で関係抽出を行うことを示す．関連研究との違いを以下にまとめる．

- Espresso との違い
  Cappuccino では，構造データのもつ構造を利用して関係抽出を行う．一方，Espresso では構造を利用できないため関係抽出に限界がある．
- Founduer との違い
  Cappuccino では，関係抽出のための構造パターンを指定せず，そのパターンは自動的に抽出される．一方，Founduer では人手により構造パターンを指定しなければならない．

3. 準備

はじめに，提案する Cappuccino のベースとなる Espresso とブートストラッピング法について述べる．

3.1 ブートストラッピング法

本稿では，関係抽出をタスクとして，ブートストラッピング法を説明する．例として，上位下位関係をもつインスタンス (例：(apple, fruit)) の集合をテキストデータから獲得するタスクを考える．ブートストラッピング法は，以下の 3 つのフェーズを繰り返す．

1. シードインスタンス集合 (例: {(apple, fruit), (basketball, sport)}) を与える．
2. パターン抽出：テキストデータの各文を対象に，1 で与えられたシードインスタンスと共起する ”is a” のようなパターンを列挙する．列挙したパターンの各々に対して，信頼度スコアを計算し，そのスコアによってパターンのランキングを行う．ランキングの上位のパターンを選抜する．
3. インスタンス抽出：テキストデータの各文を対象に，2 で選抜されたパターンと共起するインスタンス (例：(dog, animal)) を列挙する．2 と同様にインスタンスを選抜する．選抜されたインスタンスが新たなシードインスタンス集合となる．

繰り返しの停止条件を満たすと，最後に選抜されたインスタンス集合が獲得したインスタンスとなる．信頼度スコアの関数や抽出するインスタンスとパターンの数，繰り返しの停止条件，各反復の途中で抽出したインスタンスも獲得したインスタンスとするかは，手法やタスクによって変化する．

ブートストラッピング法では，意味ドリフトが発生しうる [Curran 07]．意味ドリフトとは，ブートストラッピング法の繰り返しにより，シードインスタンスや目的のインスタンスとは関係のないインスタンスが抽出されるという問題である．これはジェネリックパターンを抽出してしまうことが原因である．ジェネリックパターンとは，目的の関係をもたないインスタンスを多く繋ぐパターン，すなわち，再現率は高いが精度が低いパターンである．Espresso は，意味ドリフトを回避しつつ，再現率と精度を高く保つ手法として提案された [Komachi 10]．

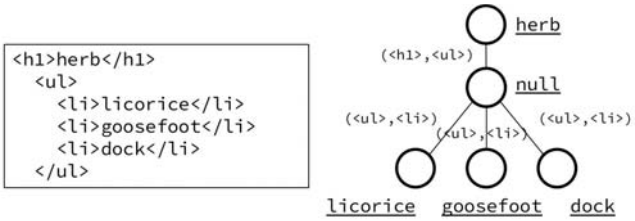


図 2: 構造データである HTML からグラフへの変換の例．

3.2 Espresso

Espresso は，意味ドリフトを回避するために，従来法のようにヒューリスティックにジェネリックパターンを排除するのではなく，自己相互情報量を用いた信頼度スコア関数によってジェネリックパターンを利用することで，バランスのとれた再現率と精度を実現した．パターン p の信頼度スコア関数 $r_\pi(p)$ とインスタンス i の信頼度スコア関数 $r_\iota(i)$ は，それぞれ以下で与えられる．

$$r_\pi(p) = \frac{1}{|I|} \sum_{i \in I} \frac{pmi(i,p)}{\max\ pmi} r_\iota(i), \tag{1}$$

$$r_\iota(i) = \frac{1}{|P|} \sum_{p \in P} \frac{pmi(i,p)}{\max\ pmi} r_\pi(p). \tag{2}$$

ここで，

$$pmi(i,p) = \log_2 \frac{|i,p|}{|i,*||*,p|} \tag{3}$$

とする [*1]．また，P と I はそれぞれ，各繰り返し時のパターンとインスタンスの集合であり，$\max\ pmi$ は，各繰り返し時のすべてのパターンとインスタンスの組み合わせにおいての pmi の最大値，$|i,p|$ は，テキストデータの各文を対象としたインスタンス i とパターン p との共起回数，$(*)$ はワイルドカードを表す．最初に与えるシードインスタンスの信頼度は 1 である．

4. Cappuccino

Cappuccino が Espresso と異なる点は構造データを扱うことである．構造データをブートストラッピング法で扱うための手法と，構造データ内に存在する通常の文の扱いについて述べる．Cappuccino の信頼度スコア関数は，第 3.2 節で述べた Espresso と同様である．

4.1 構造データ

Cappuccino の信頼度スコア関数は Espresso と同様だが，構造データにおいてのインスタンスとパターンの共起回数を求める必要がある．そのために，構造データをグラフとして扱い，頻出サブグラフマイニング [Yan 02] を利用する．構造データの例として HTML で説明する．

*1 自己相互情報量の推定量．自己相互情報量は，$pmi(i,p) = \log_2 \frac{P(i,p)}{P(i)P(p)}$ であるが，Pantel らは実験に実データを用いたため，推定量を利用している．なぜなら，$P(i)$ や $P(p)$ の計算には，インスタンスとパターンそれぞれの全体での個数が必要であるが，実データではこれが与えられないためである．

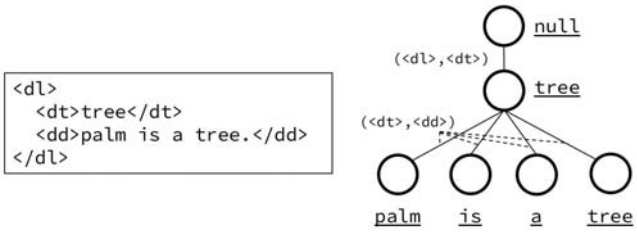


図 3: 通常の文を含むデータからグラフへの変換の例.

はじめに，図 2 で示すように HTML ファイルを頻出サブグラフマイニングで扱うためのグラフに変換する．ここで，ノードのラベルは HTML タグで囲まれる単語を表し，エッジのラベルが HTML タグの組を表す．ただし，(<ul>, <li>) と (<li>, <ul>) のような対称の組は異なるラベルとする．本稿の実験では，タグ名のみをエッジのラベルとして利用したが，属性やメタ情報なども利用することにより，エッジラベルの種類を増加させることが可能である．

次に，構造データを変換したグラフに対して，頻出サブグラフマイニングを適用し，サブグラフを列挙する．列挙したサブグラフの出現回数が，Espresso でのインスタンスとパターンの共起回数にあたる．なぜなら，1 つのサブグラフはインスタンスである特定のノードとノードの組を含み，そのサブグラフを表現するエッジの配置が 1 つのパターンを表すためである．サブグラフを列挙した結果，包含関係にあるようなパターンも存在するが，関係のない余計なエッジが含まれるようなパターンは信頼度スコア関数による信頼度が低くなるため問題ない．実験では，頻出サブグラフマイニングのツールとして DataMining-gSpan [Zhou 17] を利用した．サブグラフに含まれるノードの最大数は 4 とし，少なくとも 1 回出現するサブグラフを列挙して出現回数をカウントした．

4.2 構造データ内に存在する通常の文

構造データでは，リストのように項目として単語が並ぶだけでなく，説明文などの通常の文も存在する．このような文を第 4.1 節で述べた方法で扱うことを考える．通常の文を含むタグに対しては，図 3 で示すように，その文を単語ごとに分割し，ペアとなるノードと各単語との組を生成する．生成された組は，すべて同じ種類のエッジで繋がれる．すなわち，同じパターンで繋がれることになる．このようなパターンは，再現率は高いが精度が低いため，ジェネリックパターンになる可能性が高い．

5. 実験

構造データに対する関係抽出のタスクにおいて，提案手法である Cappuccino と既存手法である Espresso を再現率 (recall) と精度 (precision)，F 値 (F-score) の 3 つの指標で比較する．構造データには，実験のために作成した人工的な HTML ファイルを用いる．データがもつ構造を利用することで，文字列のパターンだけを用いるブートストラッピング手法と比べて高い性能となることを確認する．

関係抽出を行う構造データとして，正しい上位下位関係をもつインスタンス 100 個を含む人工的な HTML ファイルを実験に用いた．WordNet に登録されている植物の種類をインスタンスとして利用した．正しいインスタンスを繋ぐパターンとして 18 種類のパターンを準備した．実験で用いたパターン 18 種類のうち，9 種類は構造のパターン (例：リスト，定義) であり，残りの 9 種類は文字列のパターン (例：”is a”) である．実験で用いたインスタンス 100 個は，構造のパターンと文字列のパターンで繋がれているが，その個数と比率はインスタンス 10 個ずつに対して変化させた．構造のパターンと文字列のパターンとの抽出できるインスタンスの違いを確認するためである．その組み合わせの個数を表 1 に示す．10 個ずつのインスタンスのグループが $I_g,\ g = 1, \ldots, 10,$ であり，$s_j,\ j = 1, \ldots, 9,$ は構造のパターン，$c_k,\ j = 1, \ldots, 9,$ は文字列のパターンである．

表 1: 実験データにおけるインスタンスとパターンの組の数．インスタンス 10 個に対して，パターンが 3 種類あるため 30 個となる．

	I_1	I_2	I_3	I_4	I_5	I_6	I_7	I_8	I_9	I_{10}
s_1, s_2, s_3	30	0	0	0	30	0	0	0	0	0
s_4, s_5, s_6	30	30	0	0	0	30	0	0	0	0
s_7, s_8, s_9	30	30	30	0	0	0	30	0	0	0
c_1, c_2, c_3	0	30	30	30	0	0	0	30	0	0
c_4, c_5, c_6	0	0	30	30	0	0	0	0	30	0
c_7, c_8, c_9	0	0	0	30	0	0	0	0	0	30

構造データへの Espresso の適用について述べる．データは，構造をもつ HTML ファイルであるため，Espresso を適用するには HTML ファイルにおいて，どの部分を文とするかを決める必要がある．以下の 3 つの設定を用意した．

1. ESP1 : 通常の文を扱うためにタグで囲まれた部分を文とする．(例 : Kwansei Gakuin University is an university.)
2. ESP2 : 単語の組を扱うためにタグが間にある部分を文とする．(例 : fruit <li> apple)
3. ESP1 + ESP2 : 1 と 2 を合わせたものを文とする．

ブートストラッピング法では，シードインスタンスの数 S と信頼度のランキングから抽出されるインスタンスの数 K，繰り返し回数 L を決定しなければならない．これらのパラメータは，$S = 2$, $K = 50$, 75, 100, 125, 150, $L = 100$ とした．

実験結果を図 4 に示す．Cappuccino が再現率と精度，F 値のすべてで最も高い．このことから，構造データに対する関係抽出のタスクにおいては，文字列のパターンだけを利用するよりも，構造を利用することで，より多くの正しいインスタンスを抽出できることが示せたと考える．今後，Cappuccino で扱う構造パターンの種類を増やし，実データを用いて実験を行う予定である．

6. 結論

本稿は，発表で用いられるスライドや HTML のような構造データからの関係抽出タスクを扱い，構造データに対するブートストラッピング手法である Cappuccino を提案した．Cappuccino は，データがもつ構造をパターンすることで，インスタンスの抽出を行う．構造をパターンとして扱うために構造データをグラフへ変換し，そのグラフに頻出サブグラフマイニングを適用することにより，インスタンスとパターンの信頼度計算を可能にした．グラフのノードラベルが単語を表し，エッジラベルがパターンを表す．また，構造データ内に存在す

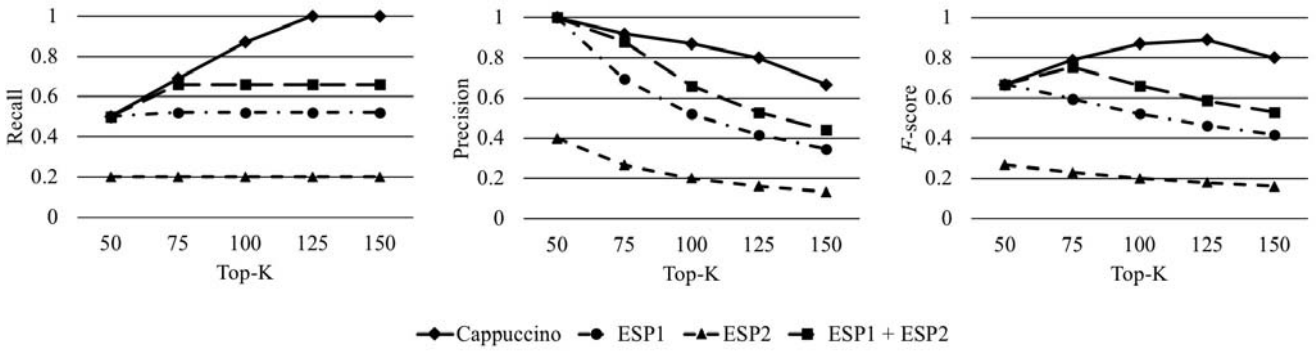


図 4: 上位下位関係の関係抽出タスクにおける実験結果.

る通常の文に対しては，単語ごとに分解し，別々のノードを生成することでインスタンスの抽出を可能にした．実験の結果，構造データに対する関係抽出のタスクにおいて，既存手法である Espresso と比較し，Cappuccino が再現率と精度，F 値のすべてで高い性能となることを確認した．

参考文献

[Curran 07] Curran, J. R., Murphy, T., and Scholz, B.: Minimising semantic drift with mutual exclusion bootstrapping, in *Proceedings of the 10th Conference of the Pacific Association for Computational Linguistics*, Vol. 6, pp. 172–180 (2007)

[Hearst 92] Hearst, M. A.: Automatic acquisition of hyponyms from large text corpora, in *Proceedings of the 14th conference on Computational linguistics-Volume 2*, pp. 539–545 (1992)

[Komachi 10] Komachi, M., Kudo, T., Shimbo, M., and Matsumoto, Y.: Semantic drift in espresso-style bootstrapping: Graph-theoretic analysis and evaluation in word sense disambiguation, *Transactions of the Japanese Society for Artificial Intelligence*, Vol. 25, pp. 233–242 (2010)

[McIntosh 11] McIntosh, T., Yencken, L., Curran, J. R., and Baldwin, T.: Relation guided bootstrapping of semantic lexicons, in *Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics: Human Language Technologies: short papers-Volume 2*, pp. 266–270 (2011)

[Pantel 06] Pantel, P. and Pennacchiotti, M.: Espresso: Leveraging generic patterns for automatically harvesting semantic relations, in *Proceedings of the 21st International Conference on Computational Linguistics and the 44th annual meeting of the Association for Computational Linguistics*, pp. 113–120 (2006)

[Riloff 99] Riloff, E., Jones, R., et al.: Learning dictionaries for information extraction by multi-level bootstrapping, in *Proceedings of the Sixteenth National Conference on Artificial Intelligence*, pp. 474–479 (1999)

[Wu 17] Wu, S., Hsiao, L., Cheng, X., Hancock, B., Rekatsinas, T., Levis, P., and Ré, C.: Fonduer: Knowledge Base Construction from Richly Formatted Data, *arXiv preprint arXiv:1703.05028* (2017)

[Yan 02] Yan, X. and Han, J.: gspan: Graph-based substructure pattern mining, in *Data Mining, 2002. ICDM 2003. Proceedings. 2002 IEEE International Conference on*, pp. 721–724 (2002)

[Zhou 17] Zhou, K.: Jokeren/DataMining-gSpan (2017), https://github.com/Jokeren/DataMining-gSpan

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

アイテムのクラス情報を利用した非負値行列分解 NMF

Non-negative matrix factorization with information expansion using item class information

村上勝彦
Katsuhiko Murakami

東京大学 医科学研究所
The Institute of Medical Science, The University of Tokyo

Non-negative matrix factorization (NMF) is widely used for various problems, such as item recommendation of shopping, image recognition and bioinformatics. However, when the data are sparse, and the row and columns of the items have no association with others, these items tend to be independent resulting poor linking. Here we investigated a method to compensate such too sparse data, by adding information of hierarchical relationships among the items to the matrix analyzed. We show how the additional information helps to make desired new clusters. In addition, too much expansion of class information makes many items into the same clusters, the situation in which is not desired. Some ideas to avoid it are discussed.

1. はじめに

非負値行列分解(Non-negative matrix factorization; NMF)は、顔画像の要素の抽出や単語の分類といったテキストマイニングの方法として提案された[Lee 99]。その後、買い物での商品推薦、画像処理、バイオインフォマティクスなど様々な分野で応用されている。NMF の解析では、1つの非負値の要素からなる行列があたえられ、それを新たな2つの非負値行列の積で近似できるような行列を求める。それによって、もとの行列のなかの、複数行と複数列の中に存在する関連を見出す解析である。

買い物での商品推薦の場合、購入者と商品（アイテム）がそれぞれ行と列になり、購入点数が要素になるデータが解析対象となる。関連付けの根拠は共起頻度にもとづくため、購入事例の少ない個人や商品については、他と関連を見いだせることはあまりない。ほとんど買われない商品が全体の取引の多くを占めるというロングテールという現象でも知られるように、これらの割合は非常に高い。全商品のなかで評価値の予測が可能な商品の割合を被覆率 (coverage) と呼ぶが、ロングテールの状況では被覆率が下がってしまい、多くの商品について推薦ができないという問題があった。

NMF はバイオインフォマティクスの分野でも、遺伝子発現データの解析にも利用されている。NMF は遺伝子発現解析に使われた[Kim 03, Kim 03]。遺伝子とサンプル（細胞や個人を示す）の2次元軸に想定し、各行に遺伝子、各列にサンプルを配置し、行列要素の値が遺伝子発現量である「遺伝子発現行列」がまず作成される。これから行列分解によって、遺伝子セットとその基本発現量を決め、各サンプルはその組み合わせによって説明されるという解釈がされる。これはがん細胞の分類に有効であった[Brunet 04]。ここでは、概要をつかむという目的では有効であったが、他との関連が薄い遺伝子やサンプルを軽視しており、細部の情報を落としているという問題があった。

「遺伝子発現行列」を起点とした場合、この中から協調して発現が近い遺伝子群とサンプル群を取り出すという「バイクラスタリング」[Pontes 15]という手法も発展してきた。この方法に、分解する前後の行列要素に非負という制約を課したものが NMF に対応する。

我々は過去に遺伝子データベースの機能情報同士の関連性を見出すためにNMFを利用した関連抽出を行った [村上 15]。多くの遺伝子と機能の関連が見出されたものの、50％近くを占める多くの用語についてはつながらないままであった。このように NMF ではスパースなデータの場合に、多くの情報が活用できないことが課題である。

本稿では、このような見落としがちな事例の少ないアイテム（用語）についても、他のアイテムの関連を見出すため、アイテムのクラス情報を利用する方法について議論する。各アイテムはなんらかのクラスに属するので、アイテムのオントロジーデータを利用して上位クラスの用語へ一般化していけば、同じクラスとの関連が見いだせると考えられる。以下では、遺伝子と機能の関連性を見出す事例について検討した。

2. データと方法

遺伝子と機能のデータとして、ヒト遺伝子統合データベース H-InvDB (http://h-invitational.jp/) [Takeda 13]を利用した。遺伝子データベースにある記述のうち、遺伝子の機能については統制された用語で基本情報が記述されている。典型的なものとして遺伝子オントロジー（Gene Ontology; GO, GO タームとも呼ばれる）[Blake 2013] がある。ここでは全遺伝子のうち、GO タームが付与されたタンパク質をコードしている遺伝子(12,261遺伝子)を抜き出した。

2.1 遺伝子オントロジー(GO)

GO は用語の集合であり、各用語に少なくとも親子関係（IS-A 関係）が付与されているので、全用語は Directly Acyclic Graph (DAG)構造、階層構造を形成する（図1）。古典的には1遺伝子には1つの機能は1つではなく、複雑な機能を説明するべく、さまざまな観点から関連用語が付与されている。1つの遺伝子には、主要な情報として該当する GO が複数付与されている。あまり調べられていない遺伝子もあり、その場合は何の GO も付与されていない。付与される GO の階層レベルは特に決まりがなく上から下まで使われている。

木構造のルートは 3 種の概念、すなわち機能(molecular function)、生物学的な反応過程（biological process）、および細胞構成要素（cellular component）となっている。本来、生命現象は多くの要素が互いに絡み合っているので、これらの用語や概念は互いに繋がっているはずである。しかし、そのような繋がりはデータベースに陽にはかかれていない。そこで、そのような関係を NMF により発見して補完していく必要がある。

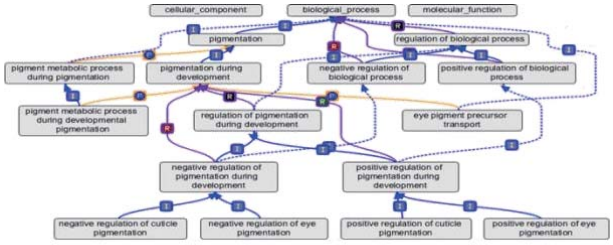


図1　Gene Ontology (GO) の階層構造。GO タームがノード、関係がリンクであり、全体がネットワークで表現されている。

2.2 遺伝子と機能の行列データと行列分解

ヒト遺伝子データベースから取得した、GO タームが付与された 12,261 遺伝子について、縦軸に遺伝子、横軸に用語とする行列を作成し、情報付与の有無を 1,0 で表現する（図2）。

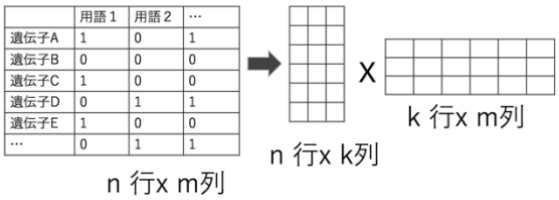


図2　遺伝子と GO タームのデータ構造と行列分解

ユニークな GO ターム回数（異なり数）は 1,741 個であり、延べ数は 40,871 個であった。これに付与されていた 533 個の GO タームを使用した。GO が付与されていた個数は1遺伝子あたり平均 3.3 個であった。通常の文書解析の場合と異なり、1遺伝子にある GO が付与されるのは0回か1回である。

この行列 V を式(1)のように2つの行列の積で近似する。

$$\mathrm{V_{i\mu}} \approx (WH)_{i\mu} = \sum_{a=1}^{k} W_{ia} H_{a\mu} \qquad (1)$$

ここで、V, W, H についてすべての行列要素が非負値である。行列の次元は、V が n×m、W が n×k、H が k×m である。また、k は基底ベクトルの数で、解析の際に固定値として与える。W と H の推定方法としては、以下のようなコスト関数を定義してその最小化を行う。

$$f = \|V - WH\|_F^2 \qquad (2)$$

右辺添字の F はフロベニウスのノルム(V と WH の同じ行と同じ列の要素毎に差をとり、その平方和)である。計算には R ライブラリ Non-Negative Linear Models (NNLM)[Lin 16] を使用した。

3. 関連を見出すための情報の拡張

上記の行列データの間に隠れた関連性を見出すことがここでの目標である。しかし、実際には行列はスパースである。1遺伝子あたりの平均 GO タームの数は3個である[村上 15]。通常の方法では、共起が少ない項目はノイズとして扱われて消えてしまうことになる。

ここでは、各列で要素値の合計（頻度）が t 回以下の低い頻度の GO タームについて、オントロジーの階層情報を参照して階層上位の GO タームを同定する。その GO タームはもともとその遺伝子には付与されていない（下位語が付与されているので上位語は付与する必要がない）。そこで階層が1つ上の上位語について図2の行列のフラグをたてる。こうして背景知識となるオントロジーから関係情報を取得して、データ行列に追加することで上位の GO タームにおける共起頻度が増加し、関連を拾いやすいデータ構造となった。

アイテム推薦の問題においても、商品のカテゴリについての階層データを作成し、同様にデータ拡張が適用できる。

付与した上位の GO タームについても、さらに階層レベルを上げて追加することも考えられるが、階層をあげすぎると、すべての用語について最上位のターム(「molecular function」など)がどの遺伝子にも付与されてしまって意味がない。適切なレベルの階層まで参照することが望ましい。この対策には相互情報量、または最大アイテム数か最大遺伝子数などの基準を設けることが考えられる。

4. おわりに

本稿では、スパースな行列データを NMF で解析する場合に、共起頻度の少ない孤立しがちなアイテム（ここでは GO ターム）について、クラス情報を付与することで、行列データの情報を増やす方法を提案した。これにより、多くの孤立アイテムについて従来は困難であった互いの関連性把握ができるようになった。

今後の課題は、行列要素値から関連遺伝子（および GO ターム）選定の自動化である。係数の大小によって選定するが、閾値を決定する客観的な方法が必要である。将来的には得られた知識データによる推論システムを構築したい。

参考文献

[Blake 13] Blake, J. a, Dolan, M., Drabkin, H., Hill, D. P., Li, N., Sitnikov, D., … Westerfield, M. Gene Ontology annotations and resources. *Nucleic Acids Research*, *41*(Database issue), D530-5. 2013.

[Brunet 04] Brunet, J.-P., Tamayo, P., Golub, T. R., & Mesirov, J. P. Metagenes and molecular pattern discovery using matrix factorization. *Proceedings of the National Academy of Sciences of the United States of America*, *101*(12), 4164–9. 2004.

[Devarajan 08] Nonnegative matrix factorization: An analytical and interpretive tool in computational biology. *PLoS Computational Biology*, *4*(7). 2008.

[Kim 03] Kim, P. M., & Tidor, B. (2003). Subsystem Identification Through Dimensionality Reduction of Large-Scale Gene Expression Data. *Genome Research*, *13*(7), 1706–1718, 2003.

[Lee 99] Lee, D. D., & Seung, H. S. Learning the parts of objects by non-negative matrix factorization. *Nature*, *401*(6755), 788–791.1999.

[Lin 16] Lin, E. X. NNLM: A package For Fast And Versatile Nonnegative Matrix Factorization. (Web) 2016.

[Pontes 15] Pontes, B., Giráldez, R., & Aguilar-Ruiz, J. S. (2015). Biclustering on expression data: A review. *Journal of Biomedical Informatics*, *57*, 163–180.

[Takeda 13] Takeda, J.-I., Yamasaki, C., Murakami, K., Nagai, Y., Sera, M., Hara, Y., … Imanishi, T. H-InvDB in 2013: an omics study platform for human functional gene and transcript discovery. *Nucleic Acids Research*, *41*(Database issue), D915-9. 2013.

[村上 15] 村上勝彦. 行列因子分解による遺伝子データからの潜在的因子の抽出. In *The 29th Annual Conference of the Japanese Society for Artificial Intelligence*, (pp. 40–42), 2015.

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

主成分分析による方策パラメータの低次元化を用いた直接方策探索の提案

Proposal of direct policy search using reduction of policy parameters by principal component analysis

村田 悠稀 Yuuki Murata　宮下 恵 Megumi Miyashita　矢野 史朗 Shiro Yano　近藤 敏之 Toshiyuki Kondo

東京農工大学
Tokyo University of Agriculture and Technology

In the sampling based direct policy search in reinforcement learning, higher dimensional decision variables causes the deterioration of optimal value and the slowing down of the learning speed. We clarified that the variance of the sampling probability distribution affects both for the optimal value and the learning speed. Especially, there exists the tradeoff between the optimal value and the learning speed. In this paper, we propose two trick to improve the learning speed without deteriorating the optimal value. First trick is to employ the small variance sampling distribution for improving the optimal value; It causes slower convergence as a side effect. As the second trick, we employed the dimensionality reduction of the decision variable for improving the learning speed.

1. はじめに

近年, 公共機関, 医療, 軍事的など, 様々な場面で活躍するロボットが開発される時代になってきており, 今では, 自律・自己学習型ロボットも開発されつつある.

強化学習とは, エージェントが試行錯誤を繰り返すことで, 環境からの累積報酬を最大にするような最適な行動指針（方策）を見つけだす機械学習の枠組みである. 最近では, 目的関数が未知の状態で決定変数を一つ決めると, 値が一つ求まるという条件のもとで, 値を最小化するような決定変数を見つける問題クラスであるブラックボックス最適化問題の考えになぞらえて強化学習を理解することが重要であると言われている [4]. ブラックボックス最適化問題における決定変数を方策とみなし, 出力を累積報酬だと見なせば, ブラックボックス最適化の流れにそって強化学習を理解することができる.

本研究では, 強化学習の枠組みの一つであるサンプリングベースの直接方策探索に着目して研究を行った. 直接方策探索とは, 方策を数理モデルで表現し, モデルのパラメータを最適化するものであり, この方策を更新する際に, ある確率分布からのサンプリングによって方策を更新する. G-MDS[1] や TRPO[7] などがこれに相当し, 一般的に確率分布は正規分布であることが多い. このサンプリングベースの直接方策探索には, 2 つの問題点がある. 1 つ目は, 方策を特徴づける方策パラメータを, 累積報酬を最大化することを指標として更新していくことになるが, この方策パラメータの次元が高次元になると, 学習速度や最適値が悪化することである. Funny[5] らが行った実験では, ロボットアームで対象物を掴むことを強化学習させたとき, 主成分分析 [6] を用いて低次元化した方が, 学習速度と最適値が共に向上したという結果を示している. 2 つ目は, サンプリングベースの直接方策探索では, サンプリングするための確率分布の分散によって, 最適値と学習速度に影響を及ぼしてしまうことである (詳細は 2.4 節を参照). 例えば, 分散を大きくすると, 学習速度は速くなるが最適値は悪化する. 分散を小さくすると, 逆の現象が起こる. すなわち, 分散によって, 最適値と学習速度がトレードオフになる.

本研究では, トレードオフをできるだけ解消して, 最適値を悪化させずに学習速度を向上させることを目的とし, 以下の 2 つの操作を行う.

1. 方策パラメータ高次元化による最適値悪化を解消する確率分布への操作
2. 1 の操作を行うことにより悪化した学習速度を向上させるために, 主成分分析による低次元空間を用いて決定変数の削減

今回はサンプリングベースの直接方策探索である G-MDS に提案手法を適用して従来手法との比較実験を行い, 提案手法の有用性を評価した.

連絡先: 村田悠稀，東京農工大学, murata@livingsyslab.org

2. 先行研究

2.1 MDS

強化学習においてコスト最小化問題を考えたとき, 目的関数 $\mathcal{J}$ を次の式 (1) で表せる.

$$\mathcal{J} = \sum_{j=1}^{M} p\left(\boldsymbol{\theta}_j\right) J\left(\boldsymbol{\theta}_j\right) \tag{1}$$

なお, $\boldsymbol{p} = [p(\theta_1), p(\theta_2), ..., p(\theta_M)]$ は方策パラメータ θ が $\theta = \theta_j$ をとる確率分布, $J(\boldsymbol{\theta}_j)$ は方策パラメータ θ_j の報酬であり, 条件は以下に示すとおりである.

$$\boldsymbol{p} \in \mathcal{P} := \left\{ x | x \in \mathbb{R}^M, \sum_{i}^{M} x_i = 1, x_i \geq 0 \right\} \tag{2}$$

ここで, 生起確率 $\boldsymbol{p}$ を決定変数とみなし, $\boldsymbol{p}$ を更新して最適な方策を獲得することを考えると, ブラックボックス最適化の観点から,

$$\boldsymbol{p}^* = \arg\min_{\boldsymbol{p} \in \mathcal{P}} \mathcal{J} \tag{3}$$

というような最小化問題となる.
また, $\boldsymbol{p}$ の更新方法として, 最適化手法の一つである鏡像降下法を用いる. 一般的な鏡像降下法 [8] の式が次の式 (4) である.

$$\beta_t = \arg\min_{\beta \in \mathcal{B}} \left\{ \langle g_t, \beta \rangle + \psi\left(\beta\right) + \eta_t B_\phi\left(\beta || \beta_{t-1}\right) \right\} \tag{4}$$

ここで, $\mathcal{B}$ はパラメータ空間, β はパラメータ, $g_t \in \delta(\beta_{t-1})$, η_t は更新幅を調節するハイパーパラメータである. 式 (4) の β_t を $\beta_t = p_t$ とすると,

$$p_t = \arg\min_{\boldsymbol{p}\in\mathcal{B}} \{\langle g_t, p(\boldsymbol{\theta})\rangle + \eta_t B_\phi\left(p(\boldsymbol{\theta})||p_{t-1}\right)\} \tag{5}$$

となり, $g_t = \nabla_p \mathcal{J} = J(\theta)$ であるため, 元の目的関数を微分しなくても更新を行うことが可能になる. これを MDS(Mirror Desent Search) と呼ぶ.

2.2 G-MDS

2.1 節の MDS をさらに発展させたのが, G-MDS(Gaussian-MDS)[1] である. まず, 式 (4) の鏡像降下法を発展させる. 具体的には, 式 (4) のブレグマン距離を KL 距離とする. つまり, 式 (4) の B_ϕ における ϕ を, $\phi(x_{t,j}) = \sum_{j=1}^{N} x_{t,j}\log(x_{t,j})\left(\boldsymbol{x}\in\mathbb{R}^N, \beta_{t,j} > 0\right)$ とすると, 更新式として式 6 の指数勾配降下法が求まる.

$$p_t(\theta_i) = \frac{\exp\left(-\eta_t g_{t,i}\right) p_{t-1}(\theta_i)}{\sum_{j=1}^{N}\exp\left(-\eta_t g_{t,j}\right) p_{t-1}(\theta_j)} \tag{6}$$

また, ここでは $p_t(\boldsymbol{\theta})$ の確率分布をガウス分布として仮定しており, $p_t(\boldsymbol{\theta})$ は,

$$p_t(\theta) = \mathcal{N}\left(\theta \mid \mu_{t-1}, \Sigma_{\varepsilon_{t-1,i}}\right) \tag{7}$$

となる. さらに, G-MDS では, $p(\theta)$ の平均値の更新についてのみ考えており, 平均値を式 (6) から計算することができる.

$$\mu_t = \sum_{i=1}^{N}\theta_i p_t(\theta_i) = \frac{\mathbb{E}_{p_{t-1}}[\theta_i \exp(-\eta_t g_{t,i})]}{\mathbb{E}_{p_{t-1}}[\exp(-\eta_t g_{t,i})]} \tag{8}$$

式 (8) にモンテカルロ積分を適用して, 推定される μ_t を $\hat{\mu_t}$ とすると, 以下の式となる.

$$\hat{\mu}_t = \frac{\frac{1}{N}\sum_{i=1}^{N}\theta_i \exp(-\eta_t g_{t,i})}{\frac{1}{N}\sum_{i=1}^{N}[\exp(-\eta_t g_{t,i})]} \tag{9}$$

さらに, θ_i を $\varepsilon_{t,i} \sim \mathcal{N}(0, \Sigma_{\varepsilon_{t-1,i}})$ のガウスノイズを用いて表記すると,

$$\theta = \mu_{t-1} + \varepsilon_{t-1,i} \tag{10}$$

と表すことができる. ちなみに, $\Sigma_{\varepsilon_{t-1,i}}$ は初期標準偏差である. 式 (9),(10) より,

$$\begin{aligned}\hat{\mu_t} &= \frac{\sum_{i=1}^{N}(\hat{\mu}_{t-1} + \varepsilon_{t-1,i})\exp(-\eta_t g_{t,i})}{\sum_{i=1}^{N}[\exp(-\eta_t g_{t,i})]} \\ &= \hat{\mu}_{t-1} + \frac{\sum_{i=1}^{N}\varepsilon_{t-1,i}\exp(-\eta_t g_{t,i})}{\sum_{i=1}^{N}[\exp(-\eta_t g_{t,i})]}\end{aligned} \tag{11}$$

となるので, ガウシアンの平均値をガウスノイズの重み付けによって更新が可能になる.

2.3 χ^2 分布に依存する最適値

確率変数 $X_1, ..., X_n$ が独立に標準正規分布に従うとき, その二乗和の確率変数 $X = X_1^2 + \cdots + X_n^2$ は自由度 n の χ^2分布 に従う [2]. G-MDS では, 生起確率 $p(\boldsymbol{\theta})$ の平均値を最適解に向けて更新していく. そして, $p(\boldsymbol{\theta})$ の平均値が最適解に収束するとき, $\mu_{t-1} = \mu_t = \theta^*$ となる. このとき, 方策パラメータ θ の推定二乗誤差を考えると, 式 (10) から

$$(\theta^* - \theta)^2 = \{\mu_t - (\mu_{t-1} + \varepsilon_{t-1,i})\}^2 = \|\varepsilon_{t-1,i}\|^2 \tag{12}$$

となることがわかる. ところで, 方策パラメータ θ は正規分布からのサンプリングなので, $\varepsilon_{t-1,i}$ も正規分布からのサンプリングであり, ノイズの次元は決定変数 $\theta \in \mathbb{R}^n$ に依存している. このことから $\varepsilon_{t-1,i}$ は自由度 n の χ^2 分布に従うことがいえる. χ^2 分布に従う確率変数の期待値は n(自由度 n) であることが知られているため,

$$\mathbf{E}\left[\|\boldsymbol{\varepsilon}_{t-1}\|^2\right] = dim(\boldsymbol{\varepsilon}) = n \tag{13}$$

となる. このことから, 最適化の収束時に決定変数の次元に比例したノイズの残差成分が上乗せされてしまうため, 決定変数の次元に応じて収束コストが悪化すると考えられる.

2.4 サンプリングの確率分布

G-MDS における更新則は式 (6) で表される式を用いており, 事前分布が次の式で表せるものとする.

$$p^t(\theta) \propto \frac{\exp\left(-\lambda^{-2}(\theta-\theta_t)\Sigma^{-1}(\theta-\theta_t)\right)}{Z} \tag{14}$$

ここで, λ^{-2} はガウス分布の分散に相当するものである. ここからさらに, $p^{t+1}(\theta)$ の更新式を求めると,

$$p^{t+1}(\theta) = \frac{\exp(-\eta J(\theta) - \lambda^{-2}(\theta-\theta_t)\Sigma^{-1}(\theta-\theta_t))}{Z} \tag{15}$$

となる. この式 (15) の λ の値が大きい (分散が大きい) と, $\eta J(\theta)$ の影響が強くなるので分布の更新幅が大きくなる. 逆に, λ の値が小さい (分散が小さい) と, 事前分布の影響が強くなるので分布の更新幅が小さくなる. まとめると, 分散が大きい場合は更新幅が大きくなるので, 学習速度が速くなり, 分散が小さい場合は更新幅が小さくなるので, 学習速度が速くなる.

3. 提案手法

3.1 最適値改善操作

2.3 節で説明したノイズの残差を打ち消すことで最適値の改善を図る. χ^2 分布に従う確率変数の期待値は決定変数に依存することがわかっているので, 正規分布からサンプリングされるノイズ ε に対して, $\sqrt{\frac{1}{k}}$ を掛け合わせる. このとき, $k = dim(\boldsymbol{\varepsilon})$ である. このような操作を加えることで, χ^2 分布に従うノイズを以下のように表すことができる.

$$\left(\frac{\varepsilon_1}{\sqrt{k}}\right)^2 + \left(\frac{\varepsilon_2}{\sqrt{k}}\right)^2 + \cdots + \left(\frac{\varepsilon_k}{\sqrt{k}}\right)^2 = \frac{1}{k}\left(\|\varepsilon_1\|^2 + \|\varepsilon_2\|^2 + \cdots + \|\varepsilon_k\|^2\right) \tag{16}$$

ここで, $\left(\|\varepsilon_1\|^2 + \|\varepsilon_2\|^2 + \cdots + \|\varepsilon_k\|^2\right) \to k$ となるので, この操作を加えることにより, 決定変数に依存しない値にできる. つまり, 決定変数の高次元化に伴う最適値の悪化を改善することが可能になる.

ところで, ノイズに対して係数倍する操作を行うことは, 確率分布の再生性 [2] よりガウス分布の分散に係数倍を行っていることと等価になる. よって, ノイズを以下で表すことができる.

$$\varepsilon_{t,i} \sim \mathcal{N}\left(0, \frac{1}{\sqrt{k}}\Sigma_{\varepsilon_{t-1,i}}\right) \tag{17}$$

このときの分散をみると, 最適値改善の操作を加えたときの方が分散がかなり小さくなることがわかり, さらにノイズの次元数が高次元になるにつれて, ガウシアンの分散が小さくなっていく. このことから, 最適値は改善されるが, ノイズの決定変数の高次元化により学習速度は大幅に低下することも引き起こされてしまう (2.4 節を参照).

3.2 低次元空間を用いた直接方策探索

3.1 節の操作を加えると残差成分が決定変数の次元に依存しないものになるが, 学習速度がさらに悪化してしまう. そこで, この悪化した学習速度を改善する操作として, 主成分分析によって獲得した低次元空間を用いて, 方策パラメータを計算する操作を行う.

あらかじめ収集した分析用データに対して主成分分析を行い, 最適方策パラメータについての主成分を算出する. そして, この主成分の上位主成分だけを抽出して低次元空間とする. この低次元空間の主成分とこの主成分をどの程度の比率で用いるのかを決定する決定変数 $\boldsymbol{\omega}$ を混合することにより, 方策パラメータを計算する. これを具体的に示すと以下のようになる.

$$(\boldsymbol{p_1}, \boldsymbol{p_2}, \cdots, \boldsymbol{p_k}) \cdot \boldsymbol{\omega} = \boldsymbol{\theta} \tag{18}$$

ここで, $\boldsymbol{p_j} = (p_{1,j}, p_{2,j}, \cdots p_{k,j})^{\mathrm{T}}$, $\boldsymbol{\omega} = (\omega_1, \omega_2, \cdots \omega_k)^{\mathrm{T}}$, $k = dim(\boldsymbol{\omega})$ であり, 従来の手法 $(G-MDS)$ では方策パラメータ $\boldsymbol{\theta}$ そのものが決定変数であるのに対し, 提案手法では方策パラメータを構成するための混合比 $\boldsymbol{\omega}$ が決定変数であることに注意されたい. 提案手法により, 決定変数の次元を低次元化することで, 学習速度の低下が緩和されることになる.

4. 実験

4.1 実験条件

本実験は, 多自由度アームの最適軌道学習を用いて評価実験を行なった. [3] で述べられている実験内容を引用しているが, シミュレータ内容を簡単に説明する. xy 座標上に描かれたアームに対して, 任意の数の関節を設定することが可能であり, 関節はアーム上に等間隔に設定され, エンドエフェクタは xy 座標上を自由に動くことが可能である. シミュレーションでは, 中継点と呼んでいる赤い点を通過したのち, ゴールに向かうように設定されており, 中継点の通過時間はスタートしてから 300ms 後, ゴール到達時間はスタートしてから 500ms と設定されている. 最終的に, 条件を満たすようなエンドエフェクタの軌道を学習することが目的となる. また, このシミュレータの報酬関数は以下の式で表される.

$$r_t = \frac{\sum_{i=1}^{d}(d-1-i)f^2}{\sum_{i=1}^{d}(d-1-i)} \tag{19}$$

$$r_{300ms} = 10^8((x_{viapoint} - x_{t_{300ms}})^2 + (y_{viapoint} - y_{t_{300ms}})^2) \tag{20}$$

ここで, d はアームの関節数, $(x_{viapoit}, y_{viapoint})$ は中継点の座標, f は各関節の加速度である. また, r_{300ms} は 300ms の時のエンドエフェクタと中継点の二乗誤差に係数倍したペナルティである.

なお, 主成分分析のための分析用データは, 中継点 (0.5, 0.5) を重心とする一片の長さが 0.2 の正方形の範囲からランダムに 100 個の中継点を選択して, それぞれの最適軌道の方策パラメータをあらかじめ学習し, まとめたデータを分析用データとした. そして, この分析用データに主成分分析を適用して獲得された低次元空間を元に再度軌道学習を行った. 実験パラメータは以下の通りである.

表 1: 実験パラメータ

中継点座標	(0.54, 0.44)
更新回数	10 万
ロールアウト	15
初期標準偏差	1

4.2 実験結果

決定変数 1000 次元問題を, 提案手法で決定変数を 500 次元, 100 次元に削減したときの収束速度の比較を行った. 比較したのが以下の図である.

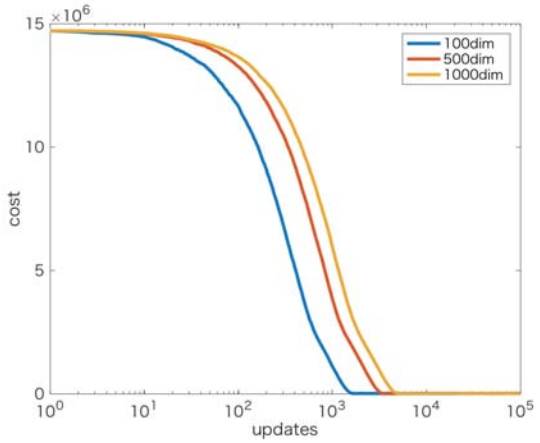


図 1: 学習速度の比較

1000 次元は G-MDS, 500 次元, 100 次元は提案手法を用いている. 学習速度を比較してみると, 1000 次元よりも 500 次元, 500 次元よりも 100 次元の方が学習速度が速くなっていることがわかる.

次に最適値の改善についてである. 最適値を比較したのが次の図である.

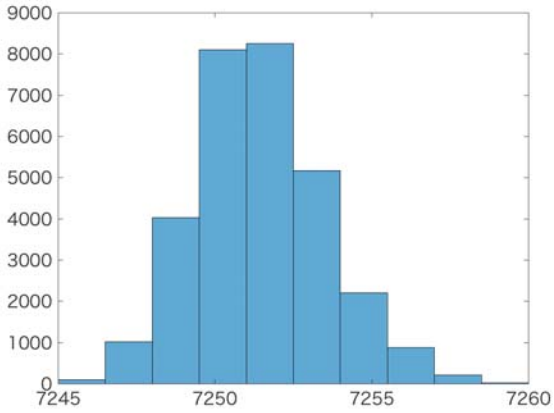


図 2: 終盤コストのヒストグラム (100 次元)

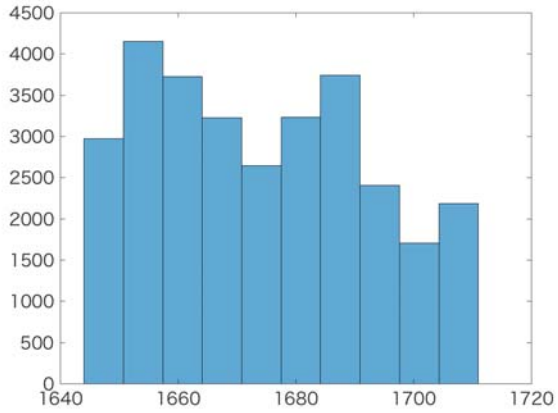


図 3: 終盤コストのヒストグラム (500 次元)

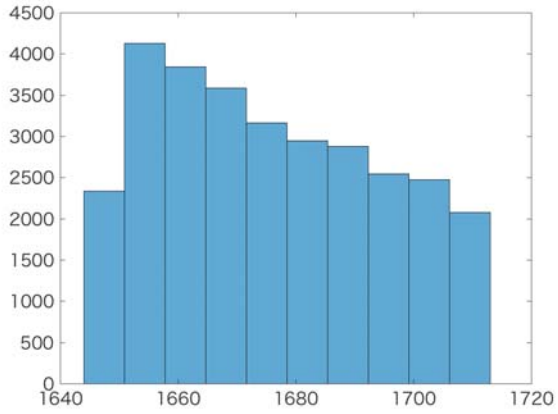


図 4: 終盤コストのヒストグラム (1000 次元)

各学習の更新回数の 7 万回〜最終までを集計してヒストグラムとして比較した. 決定変数 100 次元の場合 (図 2), 1000 次元 (従来手法)(図 4) と比べて明らかに最適値が悪くなってしまっているのがわかる. また, 決定変数 500 次元 (図 3) の場合でも, 従来手法と最適値がほとんど変わらないという結果が示された.

4.3 考察

従来手法で 1000 次元問題を解くのと, 提案手法で全主成分を使用して解くのは解釈がほぼ同じになる. このことから, 用いる主成分を削減した低次元では, 従来手法よりも情報量が少なくなり, 収束できる値に制限ができてしまうために, 最適値が悪化してしまったと考えられる. しかし, 今回の条件では, 決定変数を半分に減らしても最適値が従来手法とほぼ同じになるという結果も得ることができた. 最適値がほぼ同じであるならば, 学習速度が速い方が好ましい. 低次元空間を用いることの有用性に期待がもてる結果である.

5. まとめ

2 つの提案手法を従来手法に適用し, 評価実験を通して, 最適値と学習速度のトレードオフを従来よりも解消することに成功し, 最適値を悪化させずに学習速度を向上させることができた.

今後は, 強化学習と関係のある手法を MDS の観点からまとめ, 本研究の提案手法の適用範囲を広げていく. 低次元空間の拡張であるオンライン PCA などを提案手法に適用することで, 提案手法自体の拡張も行っていきたい.

謝辞

本研究は JSPS 科研費 JP17K12737, JP26120005, JP16H03219 の助成を受けたものです.

参考文献

[1] M. Miyashita, S. Yano, and T. Kondo, “Mirror descent search and acceleration, ” arXiv:1709.02535, 2017.

[2] 藤澤 洋徳 (2016), ”確率と統計.” 朝倉書店

[3] E. Theodorou, J. Buchli, S. Schaal, Reinforcement learning of motor skills in high dimensions: A path integral approach, in: Robotics and Automation (ICRA), 2010 IEEE International Conference on, IEEE, 2010, pp. 2397-2403.

[4] Stulp, Freek, and Olivier Sigaud. ”Policy improvement methods: Between black-box optimization and episodic reinforcement learning.” (2012).

[5] Ficuciello, Fanny, Damiano Zaccara, and Bruno Siciliano. ”Synergy-based policy improvement with path integrals for anthropomorphic hands.” Intelligent Robots and Systems (IROS), 2016 IEEE/RSJ International Conference on. IEEE, 2016.

[6] Bishop, Christopher M. ”パターン認識と機械学習 下.” ベイズ理論による統計的予測 (2008).

[7] Deisenroth, Marc Peter, Gerhard Neumann, and Jan Peters. ”A survey on policy search for robotics.” Foundations and Trends in Robotics 2.1-2 (2013): 1-142.

[8] 鈴木 大慈 (2015), ”確率的最適化.” 講談社

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

類似学習ケースに対するカリキュラム学習

Curriculum Learning for Similar Learning Cases

太田 悠太 *1　　滝 勇太 *1
Yuta Ota　　Yuta Taki

*1株式会社構造計画研究所
KOZO KEIKAKU ENGINEERING Inc.

In appricationsof machine learning, we often need to generate some models for multiple similar cases. In our study, we propose an efficient learning method exploiting the idea of the curriculum learning. Our idea is that we evaluate the effectiveness of a curriculum learning for one problem, then we use the learned curriculum as feedback for learning other cases. We apply our proposal method to two small problems, addition and subtraction of integers, using Sequence-to-Sequence model. Our experimental results show that the method works efficiently for some problem settings.

1. はじめに

機械学習の活用において，複数の類似する対象について，それぞれの学習モデルを構築したいことがある．

例えば，工場設備に対する異常検知モデルを構築したい場合，同じ種類の設備であっても設備の個体差や配備される工場の環境の差が存在するため，共通のモデルを構築するよりも，各設備に対してそれぞれのモデルを構築する方が望ましいことがある．また，生産ライン上の複数のロボットに動作を学習させたい場合，各ロボットの基本的な動作は類似しているが，担う機能によって必要な動作が部分的に異なるため，各ロボットに対してそれぞれの学習を行いたい場合が考えられる．

本研究では，このような一定の類似性を持つ複数の学習対象についてそれぞれのモデルを構築したい場合を考え，各学習を独立に行うのではなく，学習間で学習の効率性に関する情報を共有することで一連の学習を効率的に行う方法を提案する．より具体的には，カリキュラム学習 [Benjio 2009, Zaremba 2014, Wu 2017, Graves 2017, Matiisen 2017] を活用し，ある学習対象に対して行ったカリキュラム学習の効率性を評価し，類似する別の対象に関する学習を行う際に，その評価結果に基づくフィードバックを行う仕組みを提案する．

2. 関連研究

ここでは，カリキュラム学習に関する研究について説明を行う．カリキュラム学習とは，学習期間の短縮やモデルの高精度化のため，学習する事例の順序を工夫する学習アプローチを指す．

2.1 カリキュラム学習に関する研究

Benjio らは学習において相対的に容易な事例を最初に提示し，徐々に事例の難易度を高くすることで，ランダムに事例を提示するよりもモデルの予測精度が高くなることを画像分類，言語モデルのそれぞれの実験により示している [Benjio 2009]．ここでは基本的に難易度が上がっていくように事例を並び替えることでカリキュラムを生成しており，画像分類タスクでは難易度は目視で判断され，言語モデルでは単語数を難易度として並び替えを行なっている．

連絡先: 太田悠太，株式会社構造計画研究所，東京都中野区中央 5-4-3，03-5342-1125，yuta-ota@kke.co.jp

また，Zaremba らは計算プログラムのコードから計算結果を予測する問題を LSTM(long short-term memory) で学習する方法を提案する中で，従来の確率的勾配降下法による学習が困難な問題に対して，適切なカリキュラムによる学習戦略が重要であることを示している [Zaremba 2014]．カリキュラムの生成は，コードの長さと含まれる文法の種類数の 2 種類の難易度パラメータを考え，単純に難易度を上げていく戦略だけでなく，いずれかの難易度を固定する事例や，部分的にランダムに難易度を選択した事例を混ぜる戦略により，予測精度が高くなることを示している．

2.2 カリキュラムの自動生成に関する研究

Graves らは，Zaremba らのカリキュラムによる学習戦略に限界があることを指摘し，カリキュラムを自動生成する仕組みを構築した [Graves 2017]．より具体的には，敵対的バンディットの報酬として，学習の進捗率と学習対象のニューラルネット構造の複雑性の増加率を与え，ニューラルネットに対する学習において，学習エポックごとに提示する事例を選択するという枠組みを提示した．この枠組みを 3 つの実験で検証し、いくつかの設定で同じ精度になる学習時間を半分にできることを示した．また，Matiisen らは非定常バンディットを拡張した方法により，同様にカリキュラムを自動生成する仕組みを構築した [Matiisen 2017]．

これらの研究は，提示した事例に対する学習の進捗に基づき，次に提示する事例を選択するアルゴリズムを用いることで，カリキュラムの自動生成を可能にしている．

3. 提案手法

前節ではカリキュラム学習に関する研究について説明した．ここでは，類似性を持つ複数の学習対象について，各々のモデルを構築する問題設定を考える．そして学習を行うにあたり，ある学習対象に対してカリキュラム学習を行う過程で観測可能な「学習モデルがどのような状態の時に，どの事例を提供したら，どの程度学習が進捗したか」に関する情報を活用し，別の類似する学習対象の学習をより効率的に行う仕組みを提案する．

3.1 概要

本研究で提案する類似学習ケースに対するカリキュラム学習の仕組みを図 1 に示す．1 ケース目の学習は「事前学習」の位

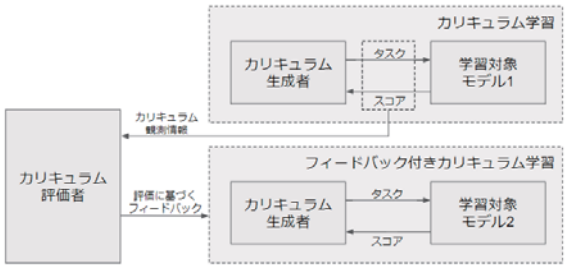


図 1: 類似学習ケースに対するカリキュラム学習の仕組みの概念図

置付けの学習であり，カリキュラムの自動生成 [Graves 2017, Matiisen 2017] により行われる (図 1 のカリキュラム学習)．2 ケース目 (もしあればそれ以降) の学習はターゲットとなる学習であり，カリキュラムの自動生成に加えて，1 ケース目のカリキュラムの効率性の評価に基づくフィードバックを踏まえたカリキュラム学習を行う (図 1 のフィードバック付きカリキュラム学習)．

ここでは，カリキュラムの自動生成機能を提供するクラスを「カリキュラム生成者」と呼び，事前のカリキュラム学習に対する評価機能とフィードバック機能を提供するクラスを「カリキュラム評価者」と呼ぶ．また，1 ケース目のカリキュラムの効率性に関する情報を「カリキュラム観測情報」と呼ぶ．

図 1 では 1 ケースのカリキュラム学習に対するカリキュラム観測情報を，別の類似する 1 ケースの学習に活用する状況を示しているが，3 ケース目以降の学習についても同様に評価とフィードバックを逐次的に行う仕組みを取ることも想定する．また，事前の複数のカリキュラム観測情報を合わせて評価してフィードバックを行う仕組みを取ることも想定する．

次節以降でこの仕組みの詳細を説明する．

3.2 カリキュラム学習

ここでは本研究で用いるカリキュラム学習の仕組みを示す．カリキュラム学習の仕組みは，[Graves 2017, Matiisen 2017] に従い，ここでは教師あり学習を考える．以下にその設定を示す．

目標系列として $Y_1, Y_2, \ldots$ を，入力系列として $X_1, X_2, \ldots$ を考える．系列は N 個のバッチに分割され，これをタスク D_k, $k = 1, \ldots, N$ とする．カリキュラム学習は T 回のバッチ学習により行われ，より少ない学習ステップで学習が収束することを目指して各学習ステップ t におけるタスクの選択を行う．このタスクのアンサンブルをカリキュラムと呼ぶ．

学習の目標として 2 つの設定が考えられる．1 つは全てのタスクが目標タスクである場合であり，この場合は，全てのタスクに対する学習の収束が目標となる．2 つ目は，興味のある任意のタスク $D_{\hat{k}}$ のみが目標タスクである場合である．この場合は $D_{\hat{k}}$ に対する学習の収束が目標となり，通常，$D_{k\neq\hat{k}}$ のタスクは，$D_{\hat{k}}$ に対する効率的な学習を達成するためのより難易度の低いタスクである．

3.3 カリキュラムの自動生成方法

カリキュラム生成者は各学習ステップ t でタスクを選択することで，カリキュラムを生成する．本研究ではカリキュラム生成者のカリキュラム自動生成方法として [Graves 2017] の仕組みを採用する．本節では [Graves 2017] のカリキュラムの自動生成方法を示す．

カリキュラム学習を T 回のタスク選択により総報酬 $\sum_{t=1}^{T} r^{(t)}$ を最大化するバンディット問題として考える．ここで，バンディット問題におけるアームの選択は時点 t におけるタスク D_k の選択，報酬 $r^{(t)}$ はタスク D_k を与えた時の学習の進捗率とする．このとき，各タスクに対する期待報酬は学習の進捗により変化するため，非定常な期待報酬を想定できる敵対的バンディットアルゴリズムの 1 つである Exp3.S アルゴリズム [Auer 2002] を用いる．Exp3.S アルゴリズムでは，報酬 $r^{(t)}$ に基づいて，タスク D_k を採用する確率に関する重みパラメータを学習ステップ t ごとに更新する．

各 t ステップ目の学習における目標タスクに対する損失を $\mathcal{L}^{(t)}$ とした時，報酬 $r^{(t)}$ を以下の式で与える：

$$r^{(t)} = \mathcal{L}^{(t)} - \mathcal{L}^{(t-1)}. \tag{1}$$

式 (1) は学習の進捗により取りうる範囲が変化するため，全期間における共通指標としては不適切である．従って，t ステップまでのすべての $r^{(t)}$ の 20 %四分位点を $q_{lo}^{(t)}$、80 %四分位点を $q_{hi}^{(t)}$ として、正規化を行った以下の指標 $\hat{r}^{(t)}$ を報酬として用いる：

$$\hat{r}^{(t)} = \begin{cases} -1 & \text{if} \quad r^{(t)} < q_{lo}^{(t)} \\ 1 & \text{if} \quad r^{(t)} > q_{hi}^{(t)} \\ \frac{2(r^{(t)} - q_{lo}^{(t)})}{q_{hi}^{(t)} - q_{lo}^{(t)}} - 1 & \text{otherwise.} \end{cases} \tag{2}$$

3.4 フィードバック付きカリキュラム学習

本節ではフィードバック付きカリキュラム学習 (FCL: Feedback-based Curriculum Learning) について説明する．FCL ではカリキュラム生成者によるカリキュラムの自動生成に加えて，カリキュラム観測情報に基づくフィードバックを踏まえた学習を行う．フィードバックの仕組みは以下の通りである．

いま，事前のカリキュラム学習により，カリキュラム観測情報が得られているものとする．式 (2) の報酬 $\hat{r}^{(t)}$ はその定義から $[-1, 1]$ の連続値をとるが，ここでは $\hat{r}^{(t)}$ の値に応じて $[-1, 1]$ を J 分割した離散的なスコア R_j, $j = 1, \ldots, J$ のいずれかをとるものとする．この時，カリキュラム観測情報は一期前に与えたタスク $D_k^{(\tau-1)}$，その時得られたスコア $R_j^{(\tau-1)} (\ni \hat{r}^{(\tau-1)})$，次に与えたタスク $D_l^{(\tau)}$ からなる状態 $S_{k,j,l} \equiv (D_k^{(\tau-1)}, R_j^{(\tau-1)}, D_l^{(\tau)})$, $k = 1, \ldots, N$, $j = 1, \ldots, J$, $l = 1, \ldots, N$ を持つ．カリキュラム学習の各ステップでは，式 (2) で与えられる報酬を得るが，その時の状態は $\{S_{k,j,l}\}$ のいずれかをとる．状態 $S_{k,j,l}$ をとった時の報酬の集合を $\mathcal{R}_{k,j,l} = \{\hat{r}^{(t_1)}, \ldots, \hat{r}^{(t_{T_{k,j,l}})}\}$ と表現する．ただし，$T_{k,j,l}$ は状態 $S_{k,j,l}$ をとった回数を表す．状態 $S_{k,j,l}$ を一度も取らなかった場合には，$\mathcal{R}_{k,j,l} = \phi$ となる．

カリキュラム評価者は，現在状態が $S_{k,j,\hat{k}}$ における価値を報酬集合 $\mathcal{R}_{k,j,\hat{k}}$ を用いて以下の式で計算する：

$$V_{k,j,\hat{k}} \equiv V(\mathcal{R}_{k,j,\hat{k}}) = \frac{1}{|\mathcal{R}_{k,j,\hat{k}}|} \sum_{r \in \mathcal{R}_{k,j,\hat{k}}} r$$

なお，$\mathcal{R}_{k,j,l} = \phi$ の場合は，$\mathcal{I} = \{(k, j, l') | \mathcal{R}_{k,j,l'} \neq \phi\}$ として，$\{V_{k,j,l'} | (k, j, l') \in \mathcal{I}\}$ の平均を用いる．

FCL の各ステップでは，一期前に選択したタスクが D_k，その際の報酬が R_j だった時，次に選択するタスク $D_{\hat{k}}$ の選択確

Algorithm 1 フィードバック付きカリキュラム学習

1: **for** $t = 1, \ldots, T$ **do**
2: カリキュラム生成者によりタスクごとの選択確率 P^G を計算
3: カリキュラム評価者によりタスクごとの選択確率 P^F を計算
4: $P \leftarrow (1-\alpha^{(t)})P^G + \alpha^{(t)}P^F$
5: 選択確率 P に基づいてタスク D_k を選択
6: 選択したタスク D_k により学習対象モデルを訓練
7: 目標タスクに対する損失 $\mathcal{L}^{(t-1)}$, $\mathcal{L}^{(t)}$ から報酬 $\hat{r}^{(t)}$ を計算
8: 報酬 $\hat{r}^{(t)}$ によりカリキュラム生成者の重みパラメータを更新
9: **end for**

率 $P^F_{k,j}(\hat{k})$ をフィードバックとして利用する．$P^F_{k,j}(\hat{k})$ は価値集合 $\{V_{k,j,s}\}_{s=1,\ldots,N}$ を用いて，

$$P^F_{k,j}(\hat{k}) = \frac{\exp V_{k,j,\hat{k}}}{\sum_{s=1}^{N} \exp V_{k,j,s}}, \tag{3}$$

により与える．

最終的にタスク $D_{\hat{k}}$ を選択する確率 $P_{k,j}(\hat{k})$ は，カリキュラム生成者の Exp3.S により得られるタスク選択確率 $P^G_{k,j}(\hat{k})$ および式 (3) により得られるフィードバックを用いて以下により計算する：

$$P_{k,j}(\hat{k}) \quad = \quad (1-\alpha^{(t)})P^G_{k,j}(\hat{k}) + \alpha^{(t)}P^F_{k,j}(\hat{k}).$$

ここで，$\alpha^{(t)}$ はカリキュラム評価者，カリキュラム生成者の各タスクの選択確率の平滑化パラメータである．$\alpha^{(t)}$ が 1 に近いほどカリキュラム評価者を信頼し，0 に近いほどカリキュラム生成者を信頼する．$\alpha^{(t)}$ が常に 0 の時，カリキュラム生成者が算出した確率 $P^G_{k,j}(\hat{k})$ にのみ従い，Graves らが提案した仕組みと一致する．

カリキュラム評価者によるフィードバックは，カリキュラム生成者が報酬に関する情報を充分に受け取っていない学習期間の序盤で，より有効であると考えられる．これを踏まえ，$\alpha^{(t)}$ は以下の式で与える：

$$\alpha^{(t)} = \frac{1}{1+\exp[-a(T_F - t)]},\ T_F > 0,\ a > 0.$$

ここで，T_F はカリキュラム評価者の選択確率をカリキュラム生成者の選択確率よりも重視する期間である．$T_F > t$ の場合は $\alpha^{(t)} > 0.5$ であるため，$P^F_{k,j}(\hat{k})$ が重視される期間となる．この期間をすぎると，徐々に $\alpha^{(t)}$ が減少する．また，a は $\alpha^{(t)}$ の減少の傾きの大きさを決める．a が小さいほど $\alpha^{(t)}$ の減少は緩やかに行われる．

ここまでの議論を踏まえ，FCL のアルゴリズムを Algorithm 1 に示す．

4. 計算機実験

4.1 実験設定

実験は，Sequence-to-Sequence モデル [Sutskever 2014] による加算問題 [Zaremba 2014] を対象とするもの，および，これを応用した減算問題を対象とするものの 2 種類を行う．加算問題は，文字列で与えられる'+' 記号で区分された 2 つの数字列を入力とし，2 つの数字列の和を出力とする．減算問題は'-' を用い，2 つの数字列の差を出力とする．入出力の例を表 1 に示す．

表 1: 入出力データ例

	入力	出力
例 1：加算問題	'29742+315'	'30057'
例 2：減算問題	'15413-8142'	'7271'
例 3：減算問題	'919-2313'	'-1397'

カリキュラムのタスク $\{D_k\}_{k=1}^N$ の設定は [Zaremba 2014, Matiisen 2017] の設定に倣う．加算 (もしくは減算) の入力における 2 つの数字列の最大桁数をタスクの難易度とする．表 1 の例 1, 2 は最大桁数 5 桁，例 3 は最大桁数 4 桁である．最大桁数 1 から 9 の 9 種類のタスクを用いることとし，各タスクにおいて 4,096 サンプルの入出力セットを生成する．各学習ステップでは，この 9 つのタスク $\{D_k\}_{k=1}^9$ から 1 つを選択して，モデルパラメータの更新を行う．タスクとは別に目標タスクとして最大桁数 9 桁の入出力セットを 128 サンプル生成する．モデルの損失 $\mathcal{L}^{(t)}$ はこの目標タスクを対象として算出する．損失は，正解の出力とモデルによる予測値の差として，128 サンプルに対する平均絶対偏差により計算する．

本実験では，提案手法である FCL を含む 4 つの手法，FCL, [Graves 2017] に従うカリキュラム学習 (CL)，各学習ステップにおいてランダムにタスクを選択する方法 (RANDOM)，すべての学習ステップにおいて目標タスクと同じ最大桁数 9 桁のタスクを選択する方法 (MAX)，を適用する．各手法に対して，目標タスクに対する損失の収束に要したステップ数，収束時の損失の大きさを比較する．FCL においてカリキュラム評価者が受け取るカリキュラム観測情報の内容は各実験の節に記載する．

実験において採用した各種パラメータは次の通りである．Sequence-to-Sequence モデルにおいて，encoder，decoder ともに 256 ユニットの LSTM を用い，RMSProp による最適化を行った．カリキュラム生成者が用いる Exp3.S については定式化を [Graves 2017] に従い，各パラメータは $\beta = 0.001$, $e = 0.02$, $\eta = 0.01$ とした．カリキュラム評価者はモデルの学習進捗率の状態を $[-1,\ 1]$ を 0.2 ステップで分割し，平滑化パラメータについては $T_F = 120$, $a = 0.2$ とした．

4.2 加算問題

各学習ステップにおける損失を図 2 に示す．学習はランダムシードを変更して 3 回行った．各学習について 20 ステップ分の移動平均をとった損失を求め，3 回の学習の平均損失の対数値を示している．

FCL におけるカリキュラム観測情報として，減算問題に対するカリキュラム学習をステップ 700 まで行い，損失の減少が大きいステップ 400 までをカリキュラム観測情報として利用した．また，カリキュラム観測情報が多く与えられるほど効率的な学習が達成されることを検証するため，カリキュラム学習 1 回分のカリキュラム観測情報を利用したときの学習を FCL(1)，3 回分のカリキュラム観測情報を利用したときの学習を FCL(3) としてそれぞれを実験対象とした．

結果として，FCL(1), FCL(3) は 100 ステップ目以降で CL と比較して損失減少の傾きが大きくなり，最終的に CL, MAX, RANDOM 手法に比べて，より小さい損失に収束していることが確認できる．このことは，フィードバックが有効であるこ

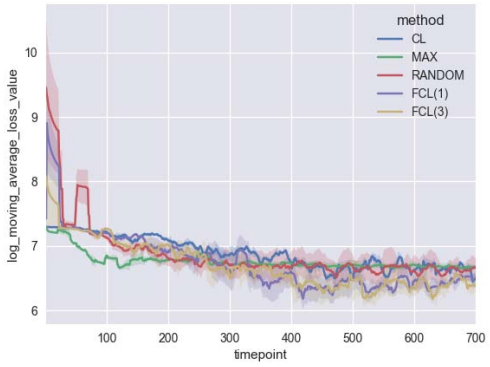


図 2: 加算問題における目標タスクに対する損失

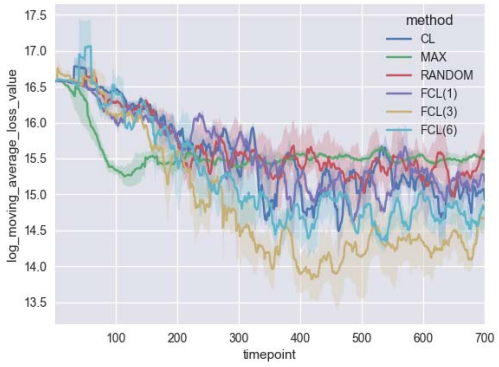


図 3: 減算問題における目標タスクに対する損失

とを示唆している．

なお，FCL(1) と FCL(3) は同程度の値に収束し，その収束にかかるステップ数も同程度であった．本実験からはカリキュラム観測情報の多寡による収束速度および損失への影響は明確に現れなかった．

4.3 減算問題

各学習ステップにおける損失を図 3 に示す．加算問題と同様に，学習はランダムシードを変更して 3 回行った．各学習について 20 ステップ分の移動平均をとった損失を求め，3 回の学習の平均損失の対数値を示している．

FCL におけるカリキュラム観測情報として，加算問題に対するカリキュラム学習をステップ 700 まで行い，損失の減少が大きいステップ 400 までをカリキュラム観測情報として利用した．カリキュラム学習 1 回分のカリキュラム観測情報を利用したときの学習を FCL(1)，3 回分のカリキュラム観測情報を利用したときの学習を FCL(3)，6 回分のカリキュラム観測情報を利用したときの学習を FCL(6) としてそれぞれを実験対象とした．

結果として，FCL(1)，CL は同程度の値に収束し，MAX，RANDOM より小さい損失に収束していることが確認できる．FCL(3) はステップ 150 程度から CL と比較して損失減少の傾きが大きくなり，より小さい損失に収束している．また，FCL(6) は 200 ステップ目以降で CL と比較して損失減少の傾きが大きくなり, 充分な差ではないものの，より小さい損失に収束している．これらはフィードバックが有効であることを示唆している．

この実験では，FCL(3) が最も小さい損失となり，FCL(6)，FCL(1) の順にこれに続く結果となった．前節の加算問題と同様に，カリキュラム観測情報は多く与えれば良いというわけではないことが確認された．従って，対象とするタスクに対して適切な量および質のカリキュラム観測情報を与えることが重要であると考えられる．

5. 結論

本研究では，類似性を持つ複数の学習ケースについてモデルを構築したい場合を考え，カリキュラム学習の仕組みを応用し，カリキュラム観測情報に基づくフィードバックによって類似ケースの学習をより効率的に行う手法を提案した．

実験により，提案手法について一定の効果がある可能性を確認することができた．カリキュラム観測情報の与え方によって収束速度および損失が変化することから，適切なカリキュラム観測情報の選択方法についても検討の必要がある．また，カリキュラム観測情報の結果への影響度合を検証することで,「学習対象の類似性」を明らかにし，フィードバックが有効に作用する条件などについても検証する必要がある．さらに，今回実施した実験設定が充分な規模と言い切れるものでないことから，今後はより大規模な実験設定や異なる問題に対する実験により，提案手法の有効性を検証する必要がある．

参考文献

[Auer 2002] Auer, P., Cesa-Bianchi, N., Freund, Y., and Schapire, R. E.: The nonstochastic multiarmed bandit problem, SIAM Journal on Computing, 32(1):pp. 48-77 (2002)

[Benjio 2009] Bengio, Y., Louradour, J., Collobert, R., and Weston, J.: Curriculum learning, ICML (2009)

[Graves 2017] Graves, A., Bellemare, M., Menick, J., Munos, R., and Kavukcuoglu, K.: Automated curriculum learning for neural networks, arXiv preprint arXiv:1704.03003 (2017)

[Matiisen 2017] Matiisen, T., Oliver, A., Cohen, T., Schulman, J., and Kavukcuoglu, K.: Teacher-Student Curriculum Learning, arXiv preprint arXiv:1707.00183 (2017)

[Sutskever 2014] Sutskever, I., Vinyals, O., and Le, Quoc, V.: Sequence to sequence learning with neural networks, In Advances in neural information processing systems, pp. 3104-3112 (2014)

[Wu 2017] Wu, Y., and Tian, Y.: Training agent for first-person shooter game with actor-critic curriculum learning, In Submitted to Int'l Conference on Learning Representations (2017)

[Zaremba 2014] Zaremba, W., and Sutskever, I.: Learning to execute, arXiv preprint arXiv:1410.4615 (2014)

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

グラフ断片決定木を用いたグラフ特徴抽出手法

Graph Feature Extraction Using Graph Fragment Decision Trees

坂上 陽規 Haruki Sakagami　瀧川 一学 Ichigaku Takigawa　有村 博紀 Hiroki Arimura

北海道大学 大学院情報科学研究科
Graduate School of Information Science and Technology, Hokkaido University

Graph-fragment decision trees are decision trees for graph classification, whose paths are graph operation codes. The GFDT algorithm is a top-down graph fragment decision tree learner without costly graph enumeration. In this paper, we study GFDT in the view of graph feature extraction. We compared GFDT based methods with pattern enumeration based methods in experiments on real-world datasets.

1. はじめに

1.1 背景と研究目的

機械学習を用いたグラフ分類問題について，近年多くの研究がなされている．グラフ分類ではグラフデータの特徴表現としてグラフパターンを用いるのが一般的であり，多くの場合では，学習の前処理として何らかの基準を満たすようなパターンの列挙を行う．例えば，部分グラフ列挙に基づく gSpan アルゴリズム（gS と表記する） [4] と決定木構築を合わせた手法（gS-DT と表記する）が考えられる．これらの前処理は基本的に重く，多様な構造学習応用のボトルネックになっている．本稿ではグラフ分類問題に対する新しいアプローチとして，グラフ断片決定木を用いた手法を考察する．

グラフ断片決定木: グラフ断片決定木 (GF 決定木) [5] は，グラフパターンの表現にグラフの符号化表現であるグラフコード [4] を利用する．決定木の各ノードはテストとしてグラフコードの拡張演算子を持ち，決定木のパスによって一意なグラフパターンに対応したグラフコードが表現される．学習アルゴリズム GFDT では通常の決定木のトップダウン構築法に基づいて決定木の構築を行う．gSpan [4] のように部分グラフの探索空間の網羅的な探索を行わないため，GFDT は，冒頭で述べた gS-DT アルゴリズムに比べて，高速かつメモリ使用量が小さいという利点をもつ．一方で，GFDT 単体の分類精度は，多少 gS-DT アルゴリズムに及ばないという問題がある．

1.2 研究結果

そこで，本稿では，GFDT アルゴリズムをグラフ特徴集合発見として用いて，集約学習手法と組み合わせて，より高精度のグラフ学習アルゴリズムを構成することを目指す．**集約学習** [3]（ensemble leanring）は，与えられた弱学習器と呼ばれるアルゴリズムを用いて多数の分類規則を生成し，それらによる多数の予測を統合して，より高精度な予測を行う枠組みである．集約学習の例として，ランダムフォレスト (random forest, 以降では RF と表記する) やブースティングがあり，広く利用されている [1].

具体的には，GF 決定木学習手法 GFDT を元にして，二つのグラフ分類手法を提案する．一つ目に，一般の RF に関する考察から，ランダム化した GF 決定木学習手法 rGFDT を開発し，これを弱学習器として RF と組み合わせた手法 rGFDT-RF を提案する．二つ目に，グラフ特徴抽出手法として，GFDT が学習した木のパス全体に対応する部分グラフ集合を取り出す手法 gfPath を開発し，これを弱学習器として RF と組み合わせた手法 gfPath-RF を提案する．

実データに対する実験では，これらの提案したグラフ分類の集約学習手法と，従来の gSpan を特徴抽出器として抽出した部分グラフパターンを弱学習器として RF と組み合わせた手法 gS-RF およびその変種と比較した．

実験結果からは，次のことがわかった．精度に関しては，提案の特徴抽出手法と RF を組み合わせた gfPath-RF は少ない特徴数で，頻出部分グラフ特徴を用いた gS[sup]-RF と gS[size]-RF に近い分類精度が得られた（実験 1 の表 4）．さらに，使用する特徴数の条件を揃えて比較した場合では，gfPath-RF の分類精度が大きく上回った（実験 2 の表 6）．

計算時間に関しては，GFDT ベースの提案手法の GFDT と，rGFDT-RF，gfPath-RF のいずれも，一部の例外を除き，gSpan ベースの RF よりも高速であった（実験 2 の表 5）．

まとめると，GFDT を用いたグラフ特徴抽出手法と集約学習の組合せは，軽量で比較的高性能なグラフ分類手法として，有用性があると考えられる．

連絡先: 坂上陽規，sakagami@ist.hokudai.ac.jp

2. 準備

本節では，以降で必要な概念と定義を導入する．可変長の要素のリストを $L = [a_1, \ldots, a_n]$ と表す．リスト L と，添え字 $i \leq n$，要素 b に対して，要素 $L[i] = a_i$ および接頭辞 $L[1..i] = a_1, \ldots, a_i$，連結 $L \cdot b = [a_1, \ldots, a_n, b]$ を定義する．キーと値の組 $a : v$ と書く．ハッシュ表 $H = \{a_1 : v_1, \ldots, a_n : v_n\}$ に対して，キー a_i に対する値を $H[a_i] = v_i$ で表す．以降で説明のない用語については，教科書 [3] を参照されたい．

2.1 グラフデータベース

$\mathcal{L} =$ をラベルの可算集合とする．$\mathcal{L}$ 上の**頂点ラベル付きグラフ**は，組 $G = (V(G), E(G), L_G)$ である．ここに，$V(G)$ は頂点の集合であり，$E(G) \subseteq V^2$ は無向辺の集合，$L_G : V(G) \to \mathcal{L}$ は各頂点にラベルを割り当てるラベル関数である．頂点付きグラフ G' が G の部分グラフに同型であるとき，$G' \sqsubseteq G$ と書く．

$\mathcal{GRAPH}$ と $\mathcal{LABEL} = \{0, \ldots, K-1\}$ で，それぞれ，$\mathcal{L}$ 上のラベル付きグラフ全体と**分類ラベル**全体を表す．サイズ m の**グラフデータベース**は，頂点ラベル付きグラフのリスト $\mathcal{G} = [\, G_i \mid i = 1, \ldots, m \,]$ と分類ラベルのリスト $\mathcal{Y} = [\, y_i \mid i = 1, \ldots, m \,]$ の組 $(\mathcal{G}, \mathcal{Y})$ である．$\mathcal{G}$ の**サンプル**は，任意の添え字集合 $S \subseteq \{1, \ldots, m\}$ である．

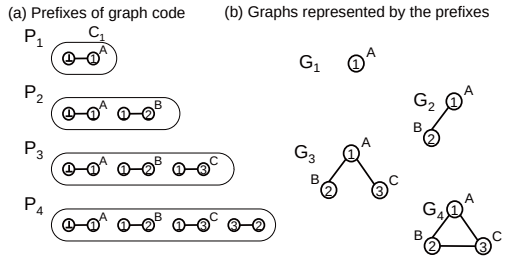


図 1: 例 1 のグラフコード P_4) の接頭辞 $P_i = P[1..i]$ と対応するグラフパターン $G_i = G(P_i)$ を示す $(1 \leq i \leq 4)$.

2.2 グラフコード

長さ K の**グラフコード**（graph code）とは，リスト $code = [op_1, \ldots, op_K]$ である．ここに，各要素 $op_i \in \mathcal{I}$ は**グラフ演算子**（graph operator）であり，与えられたグラフパターンを変更する操作を表し，以下のいずれかの形をとる．

- OP1 $op = (n_0, n_1, l_1)$: 連結頂点追加演算子は，グラフパターンにラベル l_1 を持つノード n_1 を加え，既存のノード n_0 とノード n_1 の間を辺で結ぶ操作を表す．
- OP2 $op = (n_0, n_1)$: 辺追加演算子は，グラフパターン上の既存のノードの対 n_0 と n_1 の間を辺で結ぶ操作を表す．

コード $code$ **が表現するグラフパターン** $H(code)$ は，空のグラフ $(\emptyset, \emptyset, \emptyset)$ に対し，$code$ 中の各演算子を先頭から順に適用して得られる頂点ラベル付きグラフである．

例 1 図 *1* にグラフコード $P = [(\bot, 1, A), (1, 2, B), (1, 3, C), (3, 2)]$ と，その接頭辞に対するグラフパターンの例を示す．

2.3 ランダムフォレスト

ランダムフォレスト（random forest, RF） [1] は，複数の弱学習器の決定木で得られた予測を統合して [*1]，全体の予測を行う集約学習手法である．RF では，弱学習器の集合は互いが多様性をもつことが望ましい．そこで，決定木の場合は次の二つの手法が広く用いられる [1,3].

特徴のランダム選択: 超パラメータを $\beta \in [0, 1]$ とする．弱学習器としての決定木構築において，テストとして用いる可能な特徴全体の集合 $\mathcal{OP}$ から，β の割合の部分集合 $\mathcal{OP}'$ をランダムに選択し，テストに用いる特徴を $\mathcal{OP}'$ の中から選ぶ．

サブサンプリング: 弱学習器として決定木を学習する際に，元の入力訓練データ集合から，定められたサイズの部分集合をランダムにサンプリングし，これらのデータから学習を行う．

3. 提案手法

定義 1（GF 決定木）グラフ断片決定木（graph fragment decision tree，GF 決定木）は，次の条件を満たす完全二分木 T の形をした決定規則である．(i) 根 $root$ は，親を持たない唯一の頂点である．(ii) 内部頂点 v は 1 子 $v.1$ と 0 子 $v.0$ をもち，頂点ラベルとして，グラフ演算子 $op(v) \in \mathcal{I}$ をもつ．(iii) 葉 v は，子をもたず，分類ラベル $y(v) \in \mathcal{LABEL}$ をラベルにもつ．

図 2 に，GF 決定木と，入力グラフに対する分類の例を示す．

*1 本稿では，全予測の多数決を用いる．

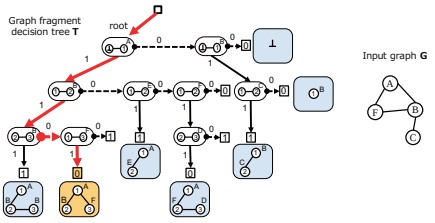


図 2: グラフ断片二分決定木の例

Algorithm 1 学習アルゴリズム GFDT

1: **Algorithm** GFDT($\mathcal{G}, minsup, \alpha, \varepsilon$)
2: Input: サイズ m のグラフデータベース $\mathcal{G}$, 最小支持度 $minsup \geq 0$，飽和しきい値 $\alpha \in [0, 1]$，利得しきい値 $\varepsilon \geq 0$ の組 $\Theta = (minsup, \alpha, \varepsilon)$
3: Output: 決定木の根ノード $root$
4: $S \leftarrow \{1, \ldots, m\}$
5: $OT \leftarrow \{\, i : [\,] \mid 1 \leq i \leq m \,\}$
6: **return** RecGFDT($S, OT, [\,], \mathcal{G}, \Theta$)

GF 決定木のすべての頂点 v に対して，次のように再帰的に，v **のグラフコード** $code(v) \in \mathcal{I}^*$ を対応づける: (i) 根 $root$ には，空列 $code(root) = [\,]$ を対応づける．(ii) もし深さ $k-1$ の内部ノード v にコード $code(v) = [op_1, \ldots, op_{k-1}]$ が対応付けられたならば，深さ k の子である 1 子には $code(v.1) = code(v) \cdot op(v)$ を，0 子には $code(v)$ を対応づける．

定義 2 (予測) GF 決定木 T の**予測アルゴリズム**は，与えられた入力グラフ $G \in \mathcal{GRAPH}$ に対して，T の根からスタートし，各内部ノード v において照合条件"$H(code(v)) \sqsubseteq G$?" をテストする．もしテストが成功すれば 1 子へ進み，失敗すれば 0 子へ進む．この操作を繰り返し，到達した葉ラベル w の持つ分類ラベル $\hat{y} = y(w)$ を予測値とする．以後，$Leaves(T)$ で，T の**葉全体**の集合を表す．

出現リスト: グラフパターン H のグラフデータベース $\mathcal{G}$ におけるマッチングの情報を効率的に保持するために，出現リストと出現テーブルを導入する．

グラフ におけるグラフパターン H の**出現リスト**（occurrence list）は，リスト $occlist = [occ_1, \ldots, occ_\ell]$ である．各 $1 \leq i \leq \ell$ に対して，occ_i は，**出現**と呼ばれる H の各頂点を G の各頂点に対応づける照合写像 $occ_i : V(H) \to V(G)$ である．

グラフデータベース $\mathcal{G}$ における H の**出現リスト表**は，ハッシュ表 $OT = \{\, k : occlist_k \mid k = 1, \ldots m \,\}$ である．

3.1 基本アルゴリズム GFDT

GFDT: GF 決定木の学習は，貪欲法でのトップダウン構築により行う．Algorithm 1 にトップレベルの手続き GFDT を，Algorithm 2 に主要な再帰手続き RecGFDT を示す．

再起手続き RecGFDT は，各ノードで (a) **葉生成演算**，(b) 内部ノードの下に二つの子を生成する**ノード分割演算**，(c) アンバランスなサンプル分割を伴う**枝伸長演算**（**飽和演算**とも呼ぶ）のいずれかを行う．

(a) 葉生成演算: **停止条件**として，(a.i) S の不純度スコアが 0 であるか，(a.ii) S の最良分割での利得が ε 未満であるか，(a.iii) S の最小支持度がしきい値 $minsup$ 未満であるか，のいずれかの条件が満たされたときに，葉を生成する．葉 v の予測ラベルには $S(v)$ の出力ラベル分布で最頻のラベルを用いる．

(b) ノード分割演算: ノードの分割では，親から受け継いだグラフコード $code$ に対し，グラフ演算子 op を用いて拡

Algorithm 2 再帰手続き RecGFDT

```
Algorithm RecGFDT(S, OT, code, G, Θ)
Output: 決定木のノード v
if 停止条件が成立 then {(a) 葉生成演算 }
    return 新しい葉 v
end if
OP(S, code) ← S に適用可能なグラフ演算全ての集合
飽和演算 (c) により OP(S, code) から飽和演算子 op を探す
if 飽和演算子が見つからなかったとき then
    OP(S, code) から分割スコア (b) が最大の演算子 op を探す
end if
S_1, S_0 ← S の code_1 := code · op による分割
OT_1 ← OT を code_1 で更新
v.1 ← RecGFDT(S_1, OT_1, code_1, G, Θ)
v.0 ← RecGFDT(S_0, OT, code, G, Θ)
return 新しい分岐頂点 v
```

張されたグラフコード $code_1 = code \cdot op$ を用いて，サンプル S を $S_1 = \{ i \in S \mid H(code_1) \sqsubseteq GSB[i] \}$ と $S_0 = \{ i \in S \mid H(code_1) \not\sqsubseteq GSB[i] \}$ に分割する．**グラフ演算子 op の探索**は，利得スコア $gainScore(S, S_1, S_0) := g(S) - (|S_1|/|S|) * g(S_1) + (|S_0|/|S|) * g(S_0)$ が最大になるように選ぶ．ここに，$g(S)$ は gini 不順度 [1] である．候補となる演算子 op は，$H(code \cdot op)$ が一つ以上の入力グラフにマッチするような適用可能な全ての演算子の集合 $\mathcal{OP}(S, code)$ から選ぶ．

(c) 飽和演算（枝伸長演算）：**飽和演算**（saturated search）では，与えられた正実数 $\alpha \in [0, 1]$ に対して，$|S_1| \geq \alpha|S|$ を満たす分割を行う演算子 $op \in \mathcal{OP}$ を直ちに選択する．条件を満たすものが複数あれば，ランダムにその中の一つを選択する．飽和演算には長いグラフコードを生成し，パターンの探索範囲を広げる効果が期待される．

3.2 ランダム化アルゴリズム rGFDT

本節では， 4. 節の実験で RF と組み合わせて用いる弱学習器 rGFDT を説明する．これは， 3.1 節の GFDT アルゴリズムを， 2.3 節の二つの方法でランダム化したものである．

特徴のランダム選択として，Algorithm 2 の 9 行目において，適用可能なグラフ演算子集合 $\mathcal{OP}$ の代わりに，部分集合 $\mathcal{OP}' \subseteq \mathcal{OP}$ を用いる．ただし，$\mathcal{OP}'$ は定数 $\beta \in (0, 1]$ に対して $|OP'| = \lceil \beta * |OP| \rceil$ となるように，ランダムに使用する特徴を選択したものを用いる．サブサンプリングに関しては，2.3 節のサブサンプリング法をそのまま用いる．

3.3 GFDT を用いたグラフ特徴抽出

本節では， 3.1 節の GFDT アルゴリズムを，グラフデータからの特徴抽出に使う手法 gfPath（graph fragment path）を説明する．GF 決定木の定義から，アルゴリズム GFDT が学習した GF 決定木の任意の葉は，根から葉までのパス（path）に対応するグラフコードを通して，一つの部分グラフパターンを表す．そこで，提案手法 gfPath では，入力の分類ラベル付きグラフデータベース $(\mathcal{G}, \mathcal{Y})$ から，GFDT を用いて，部分グラフ特徴からなる集合 $\mathcal{H}(\mathcal{G}, \mathcal{Y})$ を次のように抽出する．Θ を，GFDT の学習の超パラメータの組とする．

手続き gfPath$(\mathcal{G}, \mathcal{Y}, \Theta)$:

1. 入力の分類ラベル付きグラフデータベース $(\mathcal{G}, \mathcal{Y})$ に対し，$(\mathcal{G}, \mathcal{Y})$ から GF 決定木 T を GFDT で学習する
2. GF 決定木 T の全ての葉 $w \in Leaves(T)$ が表す部分グラフ $H(code(w))$ を特徴として抽出する．以上を繰り返して得られた部分グラフの集合を $\mathcal{H}(\mathcal{G}, \mathcal{Y})$ として返す．

表 1: 実験に用いたデータセット.

データセット	MUTAG	NCI1	ENZYMES
データ数	188	4110	600
クラス数	2	2	6
平均頂点数	17.93	29.87	32.63
平均辺数	19.79	32.30	62.14
頂点ラベルの種類数	7	36	3
最頻クラスの割合 (%)	66.49	50.05	16.67

GFDT アルゴリズムは，gSpan と異なり同型性判定を行っていないので，特徴集合 $\mathcal{H}(\mathcal{G}, \mathcal{Y})$ には互いに同形なグラフパターンが含まれる可能性があり，冗長である．

4. 実験

提案の GF 決定木を用いる手法と，既存手法 (頻出グラフ特徴を用いる手法) の比較を，実データ上の実験によって行う．

4.1 データ

表 1 に示した MUTAG, NCI1, ENZYMES の 3 つのベンチマークデータを，サイト [2] からダウンロードして用いた．

4.2 実験方法

実験では，次に示したグラフ特徴抽出器（グラフの弱学習器）と集約学習手法を組み合わせて，グラフ分類学習器を構成したものを用いた．以下では，記法 *A*-*B* で，グラフに対する弱学習器 A と集約学習手法 B を組み合わせて得られるグラフ分類学習器を表す．

グラフ特徴抽出器は，次の通りである．

- GFDT: 3.1 節のグラフ断片決定木 (GF 決定木) 学習手法の Python による実装.
- rGFDT: 3.2 節の GFDT のランダム化学習手法の Python による実装.
- gfPath: 3.3 節の GF 決定木を用いたグラフ特徴抽出アルゴリズムの Python による実装.
- gS: 頻出グラフ発見手法 gSpan [4] の C++による高速な実装 gBolt [*2]. ただし，並列処理は使用していない.

集約学習手法は次の通りである．

- RF: python の機械学習ライブラリ scikit-learn によるランダムフォレストの実装.

特徴抽出器 gSpan のパラメータである，グラフパターンの最小支持度 s と最大サイズ z を，それぞれのデータセットごとに表 2 に示した値に設定した．[*3] ここに，$gS[sup]$ と書かれた群は，z は制限せず，s を変化させたものを表し，一方で $gS[size]$ と書かれた群は，s は制限せず，z を変化させたものを表す．

gfPath と rGFDT-RF のパラメータは，飽和しきい閾値を $\alpha = 1$，終了条件しきい値を $\varepsilon = 0$, 特徴のランダム選択割合を $\beta = 0.5$ に設定した．集約学習手法について，RF の弱学習器の数は 50 とし，木の深さなどの制限は用いなかった．

分類精度は，異なる 5CV を 5 回繰り返した平均値を計測した．計算機環境として，PC (CPU Intel Corei7 3.3GHz，Memory 64GB, OS Ubuntu 16.04) と Python 3.5.2 を用いた．

*2 https://github.com/Jokeren/DataMining-gSpan

*3 パラメータ s および z は，手作業で，gSpan の計算時間が 200(sec) 以下で生成される特徴が 150 万個を超えないように選択した.

表 2: 実験で使用した gSpan の設定パラメータ．s と z は，それぞれ最小支持度と最大サイズを表す．

手法	MUTAG	NCI1	ENZYMES
gS[sup]	s=5, z=∞	s=205, z=∞	s=360, z=∞
gS[size]	s=1, z=17	s=1, z=10	s=1, z=7

表 3: グラフ特徴抽出器による生成した特徴数の比較．

手法	MUTAG	NCI1	ENZYMES
gfPath	38.3	1010.0	237.3
gS[sup]	782816.8	94995.6	276.6
gS[size]	1094054.4	727001.8	106802.8

表 4: 各手法と分類精度の比較．

手法	MUTAG	NCI1	ENZYMES
GFDT	81.10	75.02	39.13
rGFDT-RF	81.30	83.22	53.93
gfPath-RF	84.73	83.08	45.70
gS[sup]-RF	89.28	83.09	37.60
gS[size]-RF	87.04	83.94	51.83
baseline	66.49	50.05	16.67

4.3 実験 0： 各手法の分類性能の評価

gSpan と gfPath は，生成する特徴数に大きな差がある．予備実験として，二つのアルゴリズムを各データセットに対して実行し，生成した特徴数を計測した．

表 3 に得られた結果を示す．全データセットにおいて，gS[sup] と gS[size] は，非常に多くの特徴を生成している一方で，gfPath は少数の特徴を生成していることがわかった．これは，gfPath の利点でもあり，欠点でもある．

4.4 実験 1：各手法の分類性能の評価

グラフ特徴抽出アルゴリズム GFDT, rGFDT, gfPath, gSpan と集約学習手法 RF の組み合わせ手法による分類精度を，各データセットに対して計測した．ただし，GFDT は RF と組み合わせず，単一の学習器を用いる．表 4 に計測した分類精度を，表 5 に計測した実行時間を示す．

表 4 から，ENZYMES に対しては rGFDT-RF が最も精度が高く，MUTAG に対してはグラフ特徴抽出手法に gSpan を用いた gS[sup]-RF と gS[size]-RF の精度が高かった．gfPath-RF は gS[sup]-RF および gS[size]-RF と比較して全体的にやや精度を下回った．NCI1 では各集約学習手法内で大きな精度の差はなかった．表 5 からは，実行時間に関して属性抽出手法 GFDT と rGFDT，gfPath が高速であることが観察される．

4.5 実験 2：パターン特徴集合の評価

次に，gSpan で列挙されたグラフ特徴の数を，gfPath と同数に特徴数を削減して実験を行った．具体的には，gSpan で列挙されたグラフ特徴集合から，gfPath の特徴数との誤差が最小となるような整数 K を選択し，3 通りの特徴削減手法 (i) 訓練データに対する利得スコアが高い順に K 個選択する方法 (score)，(ii) 支持度が高いものから順に K 個選択する方法 (support)，(iii) ランダムに K 個選択する方法 (random) を用いた．gSpan の制約パラメータ $\mu \in \{\mathsf{sup}, \mathsf{size}\}$ と特徴選択法 $\nu \in \{\mathsf{score}, \mathsf{support}, \mathsf{random}\}$ の組み合わせを記法 gS[μ-ν] で表す．

特徴抽出に gfPath を用いた手法である gfPath-RF と，gSpan の特徴数を削減した手法である gS[μ-ν]-RF の各データセットに対する精度を比較した．表 6 に実験結果を示す．

表 5: 各手法の実行時間 (秒) の比較．括弧内の値は，グラフ特徴発見部分のみの実行時間を示す．

手法	MUTAG	NCI1	ENZYMES
GFDT	0.2	9.0	3.4
rGFDT-RF	10.1	557.6	215.9
gfPath-RF	0.3(0.2)	14.4(13.8)	26.3(26.3)
gS[sup]-RF	129.6(128.1)	222.1(197.4)	142.4(142.2)
gS[size]-RF	118.1(116.7)	123.5(32.8)	112.8(111.1)

表 6: 使用する特徴数を合わせた条件での各手法と分類精度の比較．

手法	MUTAG	NCI1	ENZYMES
gfPath-RF	84.73	83.08	45.70
gS[sup-score]-RF	78.11	73.06	37.17
gS[sup-support]-RF	66.38	80.73	36.93
gS[sup-random]-RF	64.99	79.03	32.83
gS[size-score]-RF	78.11	76.38	41.27
gS[size-support]-RF	66.28	81.21	37.33
gS[size-random]-RF	66.59	72.60	33.17
baseline	66.49	50.05	16.67

実験の結果，gfPath-RF の分類精度が，全てのデータセットについて最も高かった．この結果から，少数のグラフ属性しか用いない場合に，gfPath は高い識別能力をもつ特徴集合を発見していると考えられる．これは，解釈しやすい分類器の学習に有用と思われる．

5. おわりに

本稿では，グラフ断片決定木学習手法 GFDT の拡張として，集約学習器 rGFDT-RF と，グラフ特徴抽出アルゴリズム gfPath，集約学習器 gfPath-RF を提案し，実データに対する実験で評価した．実験結果から，GFDT ベースの手法の，頻出部分グラフ列挙による手法に対する一定の有用性が観察された．GFDT のグラフ特徴発見手法としての改良は今後の課題である．

謝辞

本研究は，JSPS 科研費 基盤研究 JPA16H01743，挑戦的萌芽研究 JP15K12022 と，北大 GI-CoRE GSB 拠点の助成と支援を部分的に受けました．ここに謝意を表します．

参考文献

[1] Leo Breiman. Random forests. *Machine learning*, 45(1):5–32, 2001.

[2] Kristian Kersting, Nils M. Kriege, Christopher Morris, Petra Mutzel, and Marion Neumann. Benchmark data sets for graph kernels, 2016.

[3] Mehryar Mohri, Afshin Rostamizadeh, and Ameet Talwalkar. *Foundations of Machine Learning*. The MIT Press, 2012.

[4] Xifeng Yan and Jiawei Han. gspan: Graph-based substructure pattern mining. In *Proceedings 2002 IEEE International Conference on Data Mining.*, pages 721–724. IEEE, 2002.

[5] 坂上 陽規, 栗田 和宏, 瀧川 一学, and 有村 博紀. 決定化されたグラフパターントライの学習アルゴリズム. *SIG-FPAI*, B5(02):63–68, Jan 2018.

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

エントロピー正則化付方策改善のための目的関数の補正

Objective Correction for Policy Improvement under Entropy Regularization

岩城 諒 *1　　浅田 稔 *1
Ryo Iwaki　　Minoru Asada

*1大阪大学大学院工学研究科 知能・機能創成工学専攻
Department of Adaptive Machine Systems, Graduate School of Engineering, Osaka University

Reinforcement learning aims to find a policy which maximizes long term future reward by interacting with unknown environment through trial and error. In this study, we propose an objective correction method for entropy regularized Markov decision process. After deriving a policy gradient under the regularization by the entropy and relative entropy, we propose an on-policy objective correction method for off-policy policy improvement under entropy regularization.

1. はじめに

強化学習は，未知の環境と試行錯誤的に相互作用しながら，意思決定則である方策を最適化することを目的とする．多くの場合，学習の目的関数は，設計者が報酬関数として定義した報酬の割引累積和である．環境と相互作用し学習サンプルを生成する挙動方策が，最適化したい推定方策と異なるとき，方策オフと呼ぶ．方策オフで学習可能であれば，過去の学習データの再利用が可能であり，サンプル効率よく学習できる [Lin 92, Mnih 15, Sugimoto 16]．

近年，エントロピーもしくは双対エントロピーによって目的関数を正則化する学習則が数多く研究されている．エントロピー正則化は，方策勾配法の興りとともに提案され [Williams 92]，深層強化学習においても有用性が示された [Mnih 16]．さらに近年，価値ベースの手法と方策ベースの手法が統一的に扱えることが示されてきた [O'Donoghue 16, Haarnoja 17, Nachum 17a, Schulman 17]．また，双対エントロピーによる正則化についても，様々な学習則が提案されてきた [Todorov 06, Todorov 10, Peters 10, Azar 12, Fox 16, Nachum 17b, Kozuno 17]．

一方で，(双対) エントロピーによる正則化を導入すると，目的関数と最適方策が元となるマルコフ決定過程と異なってしまうという問題がある．本研究では，エントロピーの正則化を利用した方策オフ型の学習則の一つである Path Consistency Learning (PCL) とその派生である trust-PCL[Nachum 17b] に着目し，これらの学習則を利用して元となるマルコフ決定過程の最適方策を求める手法を提案する．

2. 背景

2.1 マルコフ決定過程

マルコフ決定過程 (Markov Decision Process, MDP) における最適方策を獲得する問題を扱う．MDP は $(\mathcal{S}, \mathcal{A}, \mathcal{P}, \mathcal{R}, \rho_0, \gamma)$ の組によって特定される．$\mathcal{S}, \mathcal{A}$ はそれぞれ可能な状態と行動の集合である．離散時刻 $t \in \mathbb{N}_{\geq 0}$ において，エージェントは環境の状態 $s_t \in \mathcal{S}$ を観測し，行動 $a_t \in \mathcal{A}$ を選択する．環境の状態は，マルコフ性を有する状態遷移確率 $\mathcal{P} : \mathcal{S} \times \mathcal{A} \times \mathcal{S} \to \mathbb{R}$ に従って次状態 s_{t+1} に遷移する．エージェントは，有界な報酬関数 $\mathcal{R} : \mathcal{S} \times \mathcal{A} \to \mathbb{R}$ に従って環境から報酬を得る．ρ_0 は初期状態の分布，$\gamma \in [0, 1]$ は割引率である．エージェントの意思決定は，方策 π に従う．方策が決定論的であるとき，π は状態から行動への写像 $\pi : \mathcal{S} \to \mathcal{A}$ であり，方策が確率的であるとき，π はある状態である行動をとる確率 $\pi : \mathcal{S} \times \mathcal{A} \to \mathbb{R}$ である．方策 π と初期状態の分布 ρ_0 に対し，将来の割引き状態分布 $\rho^\pi(s) = \sum_{t=0}^{\infty} \gamma^t \Pr(s_t = s | \rho_0, \pi)$ が存在する．状態価値関数 $V^\pi(s) \triangleq \mathbb{E}_{\pi,\mathcal{P}}\left[\sum_{t=0}^{\infty} \gamma^t r_t \middle| s_0 = s\right]$ は，方策 π のもとである状態 s に期待される割引収益である．同様に，行動価値関数 $Q^\pi(s, a) \triangleq \mathbb{E}_{\pi,\mathcal{P}}\left[\sum_{t=0}^{\infty} \gamma^t r_t \middle| s_0 = s, a_0 = a\right]$ は，ある状態 s において行動 a をとり，その後方策 π に従った場合に期待される割引収益である．さらに，アドバンテージ関数を $A^\pi(s, a) \triangleq Q^\pi(s, a) - V^\pi(s)$ によって定義する．強化学習は，目的関数

$$\eta(\pi) = \sum_{s \in \mathcal{S}} \rho_0 V^\pi(s) = \sum_{s \in \mathcal{S}} \rho^\pi(s) \sum_{a \in \mathcal{A}} \pi(a|s) \mathcal{R}(s, a) \tag{1}$$

を最大化する決定論的な最適方策

$$\pi^* \in \arg\max_{\pi} \eta(\pi), \tag{2}$$

を獲得することである．方策の最適化としては様々な手法が提案されているが，パラメータ θ によって表現された方策 π_θ を考えるとき，方策勾配 $\nabla_\theta \eta(\pi)$ は以下のように与えられる [Sutton 99]:

$$\begin{aligned} \nabla_\theta \eta(\pi) &= \sum_{s \in \mathcal{S}} \rho^\pi(s) \sum_{a \in \mathcal{A}} \nabla_\theta \pi_\theta(a|s) Q^\pi(s, a) \\ &= \sum_{s \in \mathcal{S}} \rho^\pi(s) \sum_{a \in \mathcal{A}} \nabla_\theta \pi_\theta(a|s) A^\pi(s, a). \end{aligned} \tag{3}$$

2.2 エントロピー正則化付マルコフ決定過程

本研究ではさらに，エントロピー正則化付マルコフ決定過程 (Entropy-Regularized Markov Decision Process, ERMDP) を扱う．§2.1 で導入した MDP に加え，$\tau \geq 0, \lambda \geq 0$ として，エントロピー正則化付状態価値関数を定義する:

$$\begin{aligned} V^\pi_{\tau,\lambda}(s) \triangleq \mathbb{E}_{\pi,\mathcal{P}}\Bigg[\sum_{t=0}^{\infty} \gamma^t \Big(\mathcal{R}(s_t, a_t) - \tau \ln \pi(a_t|s_t) \\ - \lambda \ln \frac{\pi(a_t|s_t)}{\bar{\pi}(a_t|s_t)} \Big) \Bigg| s_0 = s \Bigg]. \end{aligned} \tag{4}$$

連絡先: 岩城諒，ryo.iwaki@ams.eng.osaka-u.ac.jp

ただし，$\bar{\pi}$ は参照方策である．エントロピー正則化付状態価値関数は以下のベルマン方程式を満たす:

$$V^{\pi}_{\tau,\lambda}(s) = \sum_{a\in\mathcal{A}} \pi(a|s)\Big(\mathcal{R}(s,a) + \gamma(\mathcal{P}V^{\pi}_{\tau,\lambda})(s,a) - \tau\ln\pi(a|s) - \lambda\ln\frac{\pi(a|s)}{\bar{\pi}(a|s)}\Big). \quad (5)$$

ただし，

$$(\mathcal{P}V^{*}_{\tau,\lambda})(s,a) = \sum_{s'\in\mathcal{S}} \mathcal{P}(s'|s,a)V^{*}_{\tau,\lambda}(s')$$

とした．ERMDP での目的関数は，以下で与えられる:

$$\eta_{\tau,\lambda}(\pi) = \sum_{s\in\mathcal{S}} \rho_0(s)V^{\pi}_{\tau,\lambda}(s) = \eta(\pi) + \tau H_{\gamma}(\pi) - \lambda D_{\gamma}(\pi,\bar{\pi}). \quad (6)$$

ただし，

$$H_{\gamma}(\pi) = -\sum_{s\in\mathcal{S}} \rho^{\pi}(s)\sum_{a\in\mathcal{A}} \pi(\cdot|s)\ln\pi(\cdot|s),$$
$$D_{\gamma}(\pi,\bar{\pi}) = \sum_{s\in\mathcal{S}} \rho^{\pi}(s) D_{\mathrm{KL}}(\pi(\cdot|s),\bar{\pi}(\cdot|s))$$

である．

ERMDP において，最適価値 $V^{*}_{\tau,\lambda}(s)$ と最適方策 $\pi^{*}_{\tau,\lambda}$ に対し，以下の命題が成立する．

命題 1. [Nachum 17a, Nachum 17b, Kozuno 17] 目的関数 (6) の元で，最適価値 $V^{*}_{\tau,\lambda}(s)$ と最適方策 $\pi^{*}_{\tau,\lambda}$ は，全ての状態行動の組に対し以下の方程式を満たす:

$$\begin{aligned} V^{*}_{\tau,\lambda}(s) &= \mathcal{R}(s,a) + \gamma\sum_{s'\in\mathcal{S}} \mathcal{P}(s'|s,a)V^{*}_{\tau,\lambda}(s') - (\tau+\lambda)\ln\pi^{*}_{\tau,\lambda}(a|s) + \lambda\ln\bar{\pi}(a|s) \\ &= \mathbb{E}_{s'\sim\mathcal{P}}\big[\mathcal{R}(s,a) + \gamma V^{*}_{\tau,\lambda}(s') - (\tau+\lambda)\ln\pi^{*}_{\tau,\lambda}(a|s) + \lambda\ln\bar{\pi}(a|s)\big]. \end{aligned} \quad (7)$$

すなわち，最適方策は以下で与えられる:

$$\pi^{*}_{\tau,\lambda}(a|s) = \frac{\bar{\pi}(a|s)^{\frac{\lambda}{\tau+\lambda}}\exp\left(\left(\mathcal{R}(s,a) + \gamma(\mathcal{P}V^{*}_{\tau,\lambda})(s,a)\right)/(\tau+\lambda)\right)}{\exp\left(V^{*}_{\tau,\lambda}(s)/(\tau+\lambda)\right)}. \quad (8)$$

さらに，全ての状態行動の組に対し，価値関数 V と方策 π が方程式 (7) を満たすとき，その価値関数と方策はそれぞれ最適価値と最適方策である: $\pi = \pi^{*}_{\tau,\lambda}, V = V^{*}_{\tau,\lambda}$.

さらに，命題 1 は次のように複数ステップ予測 (multi-steps prediction) に拡張できる．

系 2. [Nachum 17b] $n\in\mathbb{N}_{\geq 1}$ とする．目的関数 (6) の元で，最適価値 $V^{*}_{\tau,\lambda}(s)$ と最適方策 $\pi^{*}_{\tau,\lambda}$ は，任意の状態 s_t から開始される全ての状態行動系列に対し以下の方程式を満たす:

$$V^{*}_{\tau,\lambda}(s_t) = \mathbb{E}_{s_{t+i}\sim\mathcal{P}}\Big[\gamma^n V^{*}_{\tau,\lambda}(s_{t+n}) + \sum_{i=0}^{n-1}\gamma^i\big(\mathcal{R}(s_{t+i},a_{t+i}) - (\tau+\lambda)\ln\pi^{*}_{\tau,\lambda}(a_{t+i}|s_{t+i}) + \lambda\ln\bar{\pi}(a_{t+i}|s_{t+i})\big)\Big]. \quad (9)$$

式 (7), (9) ともに，期待値は状態遷移確率に従う後続状態のサンプリングのみに対して定義されていて，方策に依存しない．よって，Path Consistency Learning (PCL)[Nachum 17a] と Trust-PCL[Nachum 17b] は，Q 学習 [Watkins 89, Watkins 92] と同様に，式 (9) の両辺の残差を誤差信号としてそれを最小化するよう学習する．すなわち，それぞれパラメータ θ と ϕ で表現された方策 $\pi_{\theta}(a|s)$ と価値関数 $V_{\phi}(s)$ に対し，以下のようにパラメータを更新する:

$$\begin{aligned} \delta_{t:t+n}(\theta,\phi) &= -V_{\phi}(s_t) + \gamma^n V_{\phi}(s_{t+n}) + \sum_{i=0}^{n-1}\gamma^i\big(\mathcal{R}(s_{t+i},a_{t+i}) - (\tau+\lambda)\ln\pi_{\theta}(a_{t+i}|s_{t+i}) + \lambda\ln\bar{\pi}(a_{t+i}|s_{t+i})\big), \\ \Delta\theta &\propto -\frac{1}{2}\nabla_{\theta}\delta^2_{t:t+n}(\theta,\phi) = \delta_{t:t+n}(\theta,\phi)\sum_{i=0}^{n-1}\gamma^i\nabla_{\theta}\ln\pi_{\theta}(a_{t+i}|s_{t+i}), \quad (10) \\ \Delta\phi &\propto -\frac{1}{2}\nabla_{\phi}\delta^2_{t:t+n}(\theta,\phi) = \delta_{t:t+n}(\theta,\phi)\left(\nabla_{\phi}V_{\phi}(s_t) - \gamma^n\nabla_{\phi}V_{\phi}(s_{t+n})\right). \end{aligned}$$

ただし，$\tau\neq 0\wedge\lambda = 0$ のときが PCL，$\tau\neq 0\wedge\lambda\neq 0$ のときが Trust-PCL である．

3. エントロピー正則化付方策勾配

エントロピー正則化付行動価値関数を，以下のように定義する:

$$Q^{\pi}_{\tau,\lambda}(s,a) \triangleq \mathbb{E}_{\pi,\mathcal{P}}\left[\sum_{t=0}^{\infty}\gamma^t\left(\mathcal{R}(s_t,a_t) - \tau\ln\pi(a_t|s_t) - \lambda\ln\frac{\pi(a_t|s_t)}{\bar{\pi}(a_t|s_t)}\right)\middle| s_0 = s, a_0 = a\right]. \quad (11)$$

エントロピー正則化付行動価値は以下のベルマン方程式

$$Q^{\pi}_{\tau,\lambda}(s,a) = \mathcal{R}(s,a) + \gamma\sum_{s'\in\mathcal{S}}\mathcal{P}(s'|s,a)\sum_{a'\in\mathcal{A}}\pi(a'|s')Q^{\pi}_{\tau,\lambda}(s',a') - \tau\ln\pi(a|s) - \lambda\ln\frac{\pi(a|s)}{\bar{\pi}(a|s)} \quad (12)$$

を満たし，エントロピー正則化付状態価値との間に以下の関係が成立する:

$$V^{\pi}_{\tau,\lambda}(s) = \sum_{a\in\mathcal{A}}\pi(a|s)Q^{\pi}_{\tau,\lambda}(s,a), \quad (13)$$

$$Q^{\pi}_{\tau,\lambda}(s,a) = \mathcal{R}(s,a) + \gamma(\mathcal{P}V^{\pi}_{\tau,\lambda})(s,a) - \tau\ln\pi(a|s) - \lambda\ln\frac{\pi(a|s)}{\bar{\pi}(a|s)}. \quad (14)$$

さらに，エントロピー正則化付アドバンテージを以下のように定義する:

$$A^{\pi}_{\tau,\lambda}(s,a) = Q^{\pi}_{\tau,\lambda}(s,a) - V^{\pi}_{\tau,\lambda}(s).$$

MDP におけるアドバンテージ A^π と同様に，方策 π についての $A^\pi_\tau(s,a)$ の期待値は 0 である:

$$\begin{aligned}\sum_{a\in\mathcal{A}}\pi(a|s)A^\pi_{\tau,\lambda}(s,a) &= \sum_{a\in\mathcal{A}}\pi(a|s)\left(Q^\pi_{\tau,\lambda}(s,a)-V^\pi_{\tau,\lambda}(s)\right)\\ &= \sum_{a\in\mathcal{A}}\pi(a|s)Q^\pi_{\tau,\lambda}(s,a)-V^\pi_{\tau,\lambda}(s)\\ &= 0.\end{aligned}$$

最後の等号は (13) によって成立する．さらに，式 (5) に基づき，エントロピー正則化付 Temporal Difference (TD) 誤差 δ^π_τ を，以下のように定義する:

$$\begin{aligned}\delta^\pi_{\tau,\lambda}(s,a,s') = \mathcal{R}(s,a)-\tau\ln\pi(a|s)-\lambda\ln\frac{\pi(a|s)}{\bar\pi(a|s)}\\ +\gamma V^\pi_{\tau,\lambda}(s')-V^\pi_{\tau,\lambda}(s).\end{aligned}$$

TD 誤差 δ^π_τ の期待値は，アドバンテージ $A^\pi_\tau(s,a)$ に一致する:

$$\begin{aligned}\bar\delta^\pi_{\tau,\lambda}(s,a) &\triangleq \mathbb{E}_{s'\sim\mathcal{P}(\cdot|s,a)}\left[\delta^\pi_{\tau,\lambda}|s,a\right]\\ &= \mathcal{R}(s,a)-\tau\ln\pi(a|s)-\lambda\ln\frac{\pi(a|s)}{\bar\pi(a|s)}\\ &\quad+\gamma\mathbb{E}_{s'\sim\mathcal{P}(\cdot|s,a)}\left[V^\pi_{\tau,\lambda}(s')\right]-V^\pi_{\tau,\lambda}(s_t)\\ &= Q^\pi_{\tau,\lambda}(s,a)-V^\pi_{\tau,\lambda}(s)\\ &= A^\pi_{\tau,\lambda}(s,a).\end{aligned}$$

以下の命題は，ERMDP における目的関数 (6) を最大化するための最急勾配方向を与える．

命題 3. ERMDP における目的関数 (6) についての方策勾配は以下で与えられる:

$$\nabla_\theta\eta_{\tau,\lambda}(\pi)=\sum_{s\in\mathcal{S}}\rho^\pi(s)\sum_{a\in\mathcal{A}}\nabla_\theta\pi_\theta(a|s)\left(Q^\pi_{\tau,\lambda}(s,a)-b(s)\right).$$

命題 3 は，MDP における方策勾配定理 [Sutton 99] と同様の手順で，式 (12)-(14) を利用して証明できる．さらに，従来の方策勾配法と同様に，$b(s)=V^\pi_{\tau,\lambda}(s)$ とおくことで以下を得る:

$$\begin{aligned}\nabla_\theta\eta_{\tau,\lambda}(\pi) &= \sum_{s\in\mathcal{S}}\rho^\pi(s)\sum_{a\in\mathcal{A}}\nabla_\theta\pi_\theta(a|s)\left(Q^\pi_{\tau,\lambda}(s,a)-V^\pi_{\tau,\lambda}(s)\right)\\ &= \sum_{s\in\mathcal{S}}\rho^\pi(s)\sum_{a\in\mathcal{A}}\nabla_\theta\pi_\theta(a|s)A^\pi_{\tau,\lambda}(s,a)\\ &= \sum_{s\in\mathcal{S}}\rho^\pi(s)\sum_{a\in\mathcal{A}}\nabla_\theta\pi_\theta(a|s)\bar\delta^\pi_{\tau,\lambda}(s,a).\end{aligned}\tag{15}$$

4. 目的関数の補正

エントロピーによって正則化する場合，PCL などの方策オフ学習が可能である一方で，目的関数 (6) は元の MDP の目的関数 (1) と異なる．さらに得られる最適方策 (8) はソフトマックス関数であるため，元の MDP の決定論的な最適方策 (2) とは異なり，ERMDP での最適方策の”良さ”は，参照方策 π の選び方に依存する．本節では，ERMDP で定式化される学習則を MDP での目的関数最大化に利用する方法について議論する．

命題 4. MDP における方策勾配 (3) は，ERMDP におけるエントロピー正則化付方策勾配を利用して以下のように表現できる:

$$\begin{aligned}&\nabla_\theta\eta(\pi)\\ &=\sum_{s\in\mathcal{S}}\rho^\pi(s)\sum_{a\in\mathcal{A}}\nabla_\theta\pi_\theta(a|s)\bar\delta^\pi_{\tau,\lambda}(s,a)\\ &\quad+\sum_{s\in\mathcal{S}}\rho^\pi(s)\sum_{a\in\mathcal{A}}\nabla_\theta\pi_\theta(a|s)\big((\tau+\lambda)\ln\pi_\theta(a|s)-\lambda\ln\bar\pi(a|s)\big)\\ &=\mathbb{E}_{\pi,\rho^\pi}\left[\nabla_\theta\ln\pi_\theta(a|s)\bar\delta^\pi_{\tau,\lambda}(s,a)\right]\\ &\quad+\mathbb{E}_{\pi,\rho^\pi}\left[\nabla_\theta\ln\pi_\theta(a|s)\big((\tau+\lambda)\ln\pi_\theta(a|s)-\lambda\ln\bar\pi(a|s)\big)\right].\end{aligned}\tag{16}$$

命題 4 は，式 (6) の両辺を θ について偏微分し，命題 4 を利用することで容易に示される．式 (16) の初項はエントロピー正則化における方策勾配 (15) であり，第二項は ERMDP における方策勾配を MDP における方策勾配へと補正する．さらに，初項の $\nabla_\theta\ln\pi_\theta(a|s)\bar\delta^\pi_{\tau,\lambda}(s,a)$ は PCL による方策の更新方向 (10) において，状態価値関数を現在の方策に関するエントロピー正則化付状態価値 $V^\pi_{\tau,\lambda}$ に置き換え，さらに $n=1$ とした場合と等価である．

β を挙動方策とする．$\bar\delta^\pi_{\tau,\lambda}$ を $\delta_{t:t+1}(\theta,\phi)$ で置き換え，PCL と同様に，式 (16) の初項の期待値を β によって生成されたサンプルから計算することで，以下の方策オフと方策オンのサンプリングが混合した方策勾配を得る:

$$\begin{aligned}&\nabla_\theta\eta_\beta(\pi)\\ &=\mathbb{E}_{\beta,\rho^\beta}\left[\nabla_\theta\ln\pi_\theta(a|s)\delta_{t:t+1}(\theta,\phi)\right]\\ &\quad+\mathbb{E}_{\pi,\rho^\pi}\left[\nabla_\theta\ln\pi_\theta(a|s)\big((\tau+\lambda)\ln\pi_\theta(a|s)-\lambda\ln\bar\pi(a|s)\big)\right].\end{aligned}\tag{17}$$

このとき，式 (17) 右辺初項は，ERMDP での最適方策へ向かう勾配を計算している．式 (17) に基づき，方策オフのサンプルからエントロピー正則化付目的関数を最適化し，方策オンのサンプルから目的関数を補正することで，サンプル効率よく元の MDP における最適方策を学習できる．

5. おわりに

本研究では，エントロピー正則化付方策勾配定理を導出し，さらに MDP での目的関数を ERMDP での更新則を利用して最大化することを提案した．今後の課題として，複数ステップ予測（$n>1$）への拡張，提案法の実験的な評価，収束性に関する議論などが挙げられる．

謝辞

本研究は，JST，CREST，JPMJCR17A4 の支援を受けたものである．

参考文献

[Azar 12] Azar, M. G., Gómez, V., and Kappen, H. J.: Dynamic Policy Programming, *Journal of Machine Learning Research*, Vol. 13, (2012)

[Fox 16] Fox, R., Pakman, A., and Tishby, N.: Taming the Noise in Reinforcement Learning via Soft Updates, in *Uncertainty in Artificial Intelligence* (2016)

[Haarnoja 17] Haarnoja, T., Tang, H., Abbeel, P., and Levine, S.: Reinforcement Learning with Deep Energy-Based Policies, in *International Conference on Machine Learning* (2017)

[Kozuno 17] Kozuno, T., Uchibe, E., and Doya, K.: Unifying Value Iteration, Advantage Learning, and Dynamic Policy Programming, in *arXiv* (2017)

[Lin 92] Lin, L.-J.: Self-improving reactive agents based on reinforcement learning, planning and teaching, *Machine Learning*, Vol. 8, No. 3/4, pp. 69–97 (1992)

[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., et al.: Human-level control through deep reinforcement learning, *Nature*, Vol. 518, No. 7540, pp. 529–533 (2015)

[Mnih 16] Mnih, V., Mirza, A. P. B. M., Graves, A., Harley, T., Lillicrap, T. P., Silver, D., and Kavukcuoglu, K.: Asynchronous methods for deep reinforcement learning, in *International Conference on Machine Learning*, pp. 1928–1937 (2016)

[Nachum 17a] Nachum, O., Norouzi, M., Xu, K., and Schuurmans, D.: Bridging the Gap Between Value and Policy Based Reinforcement Learning, in *Advances in Neural Information Processing Systems* (2017)

[Nachum 17b] Nachum, O., Norouzi, M., Xu, K., and Schuurmans, D.: Trust-PCL: An Off-Policy Trust Region Method for Continuous Control, in *International Conference on Learning Representations* (2017)

[O'Donoghue 16] O'Donoghue, B., Munos, R., Kavukcuoglu, K., and Mnih, V.: Combining Policy Gradient and Q-Learning, in *International Conference on Learning Representations* (2016)

[Peters 10] Peters, J., Mülling, K., and Altün, Y.: Relative Entropy Policy Search, in *AAAI* (2010)

[Schulman 17] Schulman, J., Chen, X., and Abbeel, P.: Equivalence Between Policy Gradients and Soft Q-Learning, in *arXiv* (2017)

[Sugimoto 16] Sugimoto, N., Tangkaratt, V., Wensveen, T., Zhao, T., Sugiyama, M., and Morimoto, J.: Trial and Error: Using Previous Experiences as Simulation Models in Humanoid Motor Learning, *IEEE Robotics & Automation Magazine*, Vol. 23, No. 1, pp. 96–105 (2016)

[Sutton 99] Sutton, R. S., McAllester, D., Singh, S., and Mansour, Y.: Policy Gradient Methods for Reinforcement Learning with Function Approximation, in *Advances in Neural Information Processing Systems*, Vol. 12, pp. 1057–1063 (1999)

[Todorov 06] Todorov, E.: Linearly-solvable Markov decision problems, in *Advances in Neural Information Processing Systems* (2006)

[Todorov 10] Todorov, E.: Policy gradients in linearly-solvable MDPs, in *Advances in Neural Information Processing Systems* (2010)

[Watkins 89] Watkins, C. J. C. H.: *Learning from Delayed Rewards*, PhD thesis, King ' s College, Cambridge, England (1989)

[Watkins 92] Watkins, C. J. C. H. and Dayan, P.: Q-learning, *Machine Learning*, Vol. 8, pp. 279–292 (1992)

[Williams 92] Williams, R. J.: Simple statistical gradient-following algorithms for connectionist reinforcement learning, *Machine Learning*, Vol. 8, pp. 229–256 (1992)

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

ベンチマークデータを用いた 時系列勾配ブースティング木の実験評価

Experimental evaluation of Time-Series Gradient Boosting Tree with Time-Series Benchmark datasets

今村 光良 *1*2 Mitsuyoshi Imamura
中川 慧 *1*3 Kei Nakagawa
吉田 健一 *3 Kenichi Yoshida

*1野村アセットマネジメント株式会社
Nomura Asset Management Co., Ltd

*2筑波大学大学院 システム情報工学研究科
University of Tsukuba Graduate School of Systems and Information Engineering

*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

In this paper, We evaluated the time-series gradient boosting decision tree method using benchmark data. Our time-series gradient boosting tree has weak learners with time-series and cross-sectional attribute in its internal node, and split examples based on dissimilarity between a pair of time-series or impurity between a pair of cross-sectional attributes. It has been empirically observed that the method induces accurate and comprehensive decision trees in time-series classification, which has gaining increasing attention due to its importance in various real-world applications.

1. はじめに

本論文では、別報 [中川 18] で提案された時系列勾配ブースティング木について、様々な時系列データセットに対して分析を行い、その有効性を評価する。別報 [中川 18] では時系列およびクロスセクションの属性を持つデータセットに対する時系列勾配ブースティング決定木を提案した。勾配ブースティング木などのツリーモデルは一般に可読性に優れており、説明責任という観点から実務への適用がしやすい。勾配ブースティング木は決定木を多段に組み合わせることで確率的な予測値を導出する手法であり、非常に高い精度を実現できる。しかしながら従来の決定木学習手法は時系列属性を想定していないため、時系列データを含むデータ集合に適用する場合、データの前処理が必要となる。最も単純な前処理の方法として、時系列データを計測値の平均値や標準偏差などの時系列データのモーメントで置き換える方法が考えられる。ただし、この方法は時系列データの構造、すなわち形状を無視しており、例えば形が大きく異なる時系列データを同一視してしまう欠点がある。そこで、勾配ブースティング・アルゴリズムに用いる弱学習器として、以上の問題点を克服した時系列データの形を陽に扱い時系列データ全体を対象とする [Yamada 03] の基準例分割テストによる分割を用いた時系列決定木を使用する。時系列決定木は相違度基準として動的時間伸縮法 (DTW) を用いているが、時系列ペアに対し距離が定義されていることから、[Nakagawa 17] のように決定木学習手法ではなく、最近傍法 (k-NN や k^*-NN[Anava 16]) を用いることも考えられる。ただし、最近傍法は怠惰学習 (lazy learning) であるために分類モデルが存在せず、学習結果が分かりにくいという欠点がある。本論文では、85 種類の異なる時系列データセットである UCR データセット [Chen 15] を用いて、DTW を距離尺度とした 1-Nearest Neibor(NN) と先行研究である [Yamada 03] の時系列決定木をベンチマークに、時系列勾配ブースティング木の性能を評価する。

連絡先: 今村 光良，野村アセットマネジメント株式会社，〒103-8260 東京都中央区日本橋一丁目 12 番 1 号

2. 先行研究

勾配ブースティングは、ブースティング・アルゴリズムの一種である。ブースティングとは、集団学習の枠組みの一つで、複数の弱学習器を統合して全体の学習器を構成する手法である。弱学習器としては、決定木が使われることが多い。ブースティングにおける弱学習器として決定木を用いることは、データの外れ値に強い、数値変数と離散変数や欠損値などを扱いやすいなどの利点がある。本研究では弱学習器として、[Yamada 03] の時系列決定木に、時系列以外の通常の特徴量も追加した決定木を使用することを提案する。そこで、以下では時系列決定木および勾配ブースティング木についてレビューする。

2.1 時系列決定木

時系列決定木は、内部ノードに基準となる属性時系列を持つ決定木であり、基準例分割テストまたはクラスター分割テストによってサンプルを分割していく [Yamada 03]。[山田 03] の実験からクラスター分割テストより基準例分割テストの結果が良好であることから、本稿では基準例分割テストを分割手法として用いる。

データセット D は、n 個のサンプル $\{x_i, i = 1, ..., n\}$ を含み、各サンプル x_i はそれぞれ m 個の属性 $\{a_j, j = 1, ..., n\}$ とクラスラベルまたは目的変数 $\{y_i, i = 1, ..., n\}$ を持つ。各属性 a_j は、時間順に値を並べた時系列データ又は系列を持たない通常の連続値、名目属性を持つ。ここで $x(a_j)$ は一つのサンプルであり、基準例と呼ぶ。基準例分割テストは、サンプル x_i の属性 a_j に関する時系列データを $x_i(a_j)$ で表すと、データセット全体を、$DTW(x(a_j), ex_i(a)) < \theta_i$ を満たすデータセットから構成される集合 $L(x, a_j, \theta_i) = \{(y, x)|DTW(x(a_j), x_i(a_j)) < \theta_i\}$ とそれ以外の集合 $R(x, a_j, \theta_i) = \{(y, x)|DTW(x(a_j), x_i(a_j)) \geq \theta_i\}$ に分割する。ここで $DTW(x, y)$ は、動的時間伸縮法 (DTW) に基づいた類似度を表す。DTW は時系列データにおける一点のデータをもう片方の時系列データにおける複数点

のデータに対応づけられるため、時間方向の非線形な伸縮を許容する。このため、長さが異なる時系列データのペアに適応できる上に、結果が人間の直観により合致する。具体的なアルゴリズムは、Algorithm1 の通り。

基準例分割テストはサンプルが基準例 $x(a_j)$ と DTW で計測して、類似しているか、あるいは類似していないかという基準で閾値 θ を変えながら分割する。当該分割の評価基準としては、利得比基準など通常の決定木で用いられている方法が使える。

Algorithm 1 DTW distance

procedure DTW(x, y)
▷ Initialize matrix D
  Var $D[N, M]$
  $D[1, 1] = 0$
  for $i = 2$ to N **do**
    for $j = 2$ to M **do**
      $D[i, j] = \infty$
    end for
  end for
▷ Calculate DTW distance
  for $i = 2$ to N **do**
    for $j = 2$ to M **do**
      $D[i, j] = d(x[i-1], y_[j-1]) + min(D[i, j-1], D[i-1, j], D[i-1, j-1])$
    end for
  end for
  return $D[N, M]$
end procedure

2.2 勾配ブースティング木

[Friedman 01] は、ブースティングの各ステップで構築するモデルに回帰ツリーを用いる勾配ブースティング木（gradient boosting tree）という手法を考案した。これは特徴量 (入力) を x、ラベルを y として、弱学習器 $f_m(x), m = 0, ..., M$ に対して全体の学習器 $F(x)$

$$F(x) = f_0(x) + f_1(x) + ... + f_M(x) \quad (1)$$

を損失関数 $L(y, F(x))$ が最小になるように弱学習器 $f_m(x)$ を逐次的に学習し統合する。つまり、最初に学習器 $F_0(x) = f_0(x)$ が与えられるとし、m ステップ目の学習では m 個の学習器からなる全体の学習器を損失関数 $L(y, F(x))$ が最小になるように弱学習器を決める。

$$F_m(x) = F_{m-1}(x) + f_m(x) \quad (2)$$

具体的なアルゴリズムは以下の通りである。勾配ブースティング木の特徴は、その時点でのモデルの予測値と結果の残差を目的変数とした回帰ツリーを構築し、そのツリーモデルの予測値による値を加算することにある。

3. 提案手法 - 時系列勾配ブースティング木

前章で確認した [Yamada 03] の基準例分割テストによる時系列決定木において、時系列属性以外の属性、通常の連続値、名目属性も追加する。属性が時系列データの場合には基準例分割テストによって分割を行い、時系列以外の場合には、通常の決定木と同様の基準で分割を行う。具体的なアルゴリズム (StandardExSplit with Cross-Sectional Data) は、Algorithm3 の通り。$H(\bullet)$ は不純度を表す関数で、本稿では、よく使用される Gini 係数を用いる。

Algorithm 2 Gradient Boosting Tree

procedure GRADIENT BOOSTING TREE(y, x)
▷ Initialize F_0 with a constant
  $F_0(x) = \sum_{i=1}^{N} \arg\min_c(y_i, c)$
  for $m = 1$ to M **do**
    $r_{im} = -[\frac{L(y_i, F(x_i))}{F(x_i)}]_{F(x)=F_{m-1}(x_{i-1})}$
▷ Fit a decision tree to predict targets r_{im}
    f(x) = FitTree(r_{im},x)
    $\rho_m = \arg\min_\rho \sum_{i=1}^{N} L(y_i, F_{m-1}(x) + \rho f(x))$
    $F_m(x) = F_{m-1}(x) + \gamma\rho_m f(x)$
  end for
  return $F(x) = \sum_{m=1}^{M} F_m(x)$
end procedure

Algorithm 3 StandardExSplit with Cross-Sectional Data

procedure SPLIT($\{y_1, ..., y_n\}, \{x_1, ..., x_n\}$)
  for each samples x_i **do**
    for each attribute a_j **do**
      if attribute a_j is time-series **then**
        for each samples x_k **do**
          $L(x, a_j, \theta_i)$
          $= \{(y, x) | DTW(x_i(a_j), x_k(a_j)) < \theta_k\}$
          $R(x, a_j, \theta_i)$
          $= \{(y, x) | DTW(x_i(a_j), x_k(a_j)) \geq \theta_k\}$
          $G(L, R, \theta_i)$
          $= \frac{|L|}{|L+R|} H(L) + \frac{|R|}{|L+R|} H(R)$
        end for
      else
        $L(x, a_j, \theta_i) = \{(y, x) | x(a_j) < \theta_i\}$
        $R(x, a_j, \theta_i) = \{(y, x) | x(a_j) \geq \theta_i\}$
      end if
      $G(L, R, \theta_i) = \frac{|L|}{|L+R|} H(L) + \frac{|R|}{|L+R|} H(R)$
    end for
  end for
  $\theta^* = \arg\min_\theta G(L, R, \theta_i)$
  return best split θ^*
end procedure

この分割アルゴリズムを用いた時系列決定木を勾配ブースティング木の弱学習器として利用する。ただし、本論文の分析においては、データセットにクロスセクションのデータが存在しないため、クロスセクションのデータは用いない。

4. 実験

提案手法の有効性を確認するために、実データを用いた分析を行う。85 種類の異なる時系列データセットである UCR データセット [Chen 15] を用いて、時系列勾配ブースティング木の性能を評価する。UCR データセットは平均 0、分散 1 に正規化されているため、特別な前処理は行っていない。各データセットはそれぞれ、Image Outline(IO)、Motion Classification(MC)、

Sensor Readings(SR)、Synthetic(Syn) という 4 つのカテゴリーに分類できる。表 1 にベースラインである DTW 距離を用いた 1-NN(1-NN DTW) と先行研究で提案された時系列決定木 (TST)、そして提案手法である時系列勾配ブースティング木 (TSGBT) の各データセット毎の Error Rate をまとめた。31 のデータセットについてベンチマークである 1-NN DTW に対して改善がみられた。

勾配ブースティング木は、怠惰学習 (Lazy Learning) である k-NN とは異なり、学習が必要であるため、学習にはある程度のサンプル数が必要であると考えられる。そこで、別報 [中川 18] の金融時系列データの分析と同程度である 400 以上のサンプルが確保できるデータセット 21 個についての各カテゴリーの平均 Error Rate を示したのが表 1 である。14 のデータセットについて改善がみられた。

5. まとめ

本論文では、別報 [中川 18] で提案された時系列勾配ブースティング木について、85 種類の異なる時系列データセットである UCR データセット [Chen 15] を用いて、時系列勾配ブースティング木の性能を評価した。ベースラインである DTW 距離を用いた 1-NN(1-NN DTW) と先行研究で提案された時系列決定木 (TST)、そして提案手法である時系列勾配ブースティング木 (TSGBT) の各データセット毎の Error Rate を評価した結果、31 のデータセットについてベンチマークである 1-NN DTW に対して改善がみられた。

また、勾配ブースティング木は、怠惰学習 (Lazy Learning) である k-NN とは異なり、学習が必要であるため、学習にはある程度のサンプル数が必要であると考えられる。そこで、400 以上のサンプルが確保できるデータセット 21 個についての各カテゴリーの平均 Error Rate を評価したところ、14 のデータセットについて改善がみられた。

表 1: Error Rate of UCR Time-series Datasets

Name	Category	1-NN DTW	TST	TSGBT
50Words	IO	0.31	0.68	0.40
Adiac	IO	0.40	0.80	0.51
ArrowHead	IO	0.30	0.34	0.39
Beef	SR	0.37	0.63	0.57
BeetleFly	IO	0.30	0.30	0.30
BirdChicken	IO	0.25	0.25	0.30
Car	SR	0.27	0.43	0.40
CBF	Syn	0.00	0.11	0.01
ChlorineConcentration	SR	0.35	0.45	0.41
CinCECGtorso	SR	0.35	0.54	0.44
Coffee	SR	0.00	0.11	0.11
Computers	SR	0.30	0.38	0.32
CricketX	MC	0.25	0.62	0.36
CricketY	MC	0.26	0.61	0.39
CricketZ	MC	0.25	0.66	0.36
DiatomSizeReduction	IO	0.03	0.17	0.14
DistalPhalanxOutlineAgeGroup	IO	0.21	0.24	0.21
DistalPhalanxOutlineCorrect	IO	0.23	0.25	0.23
DistalPhalanxTW	IO	0.29	0.36	0.23
Earthquakes	SR	0.26	0.29	0.23
ECG	SR	0.23	0.21	0.21
ECG5000	SR	0.08	0.08	0.07
ECGFiveDays	SR	0.23	0.32	0.32
ElectricDevices	SR	0.40	0.36	0.25
Face (all)	IO	0.19	0.66	0.28
Face (four)	IO	0.17	0.11	0.35
FacesUCR	IO	0.10	0.54	0.18
Fish	IO	0.18	0.43	0.28
FordA	SR	0.44	0.36	0.26
FordB	SR	0.41	0.36	0.24
Gun-Point	MC	0.09	0.27	0.21
Ham	SR	0.53	0.49	0.33
HandOutlines	IO	0.20	0.19	0.17
Haptics	MC	0.62	0.63	0.60
Herring	IO	0.47	0.41	0.39
InlineSkate	MC	0.62	0.74	0.70
InsectWingbeatSound	SR	0.65	0.69	0.58
ItalyPowerDemand	SR	0.05	0.09	0.09
LargeKitchenAppliances	SR	0.21	0.27	0.19
Lightning-2	SR	0.13	0.26	0.25
Lightning-7	SR	0.27	0.51	0.42
MALLAT	Syn	0.07	0.36	0.16
Meat	SR	0.07	0.10	0.12
MedicalImages	IO	0.26	0.45	0.28
MiddlePhalanxOutlineAgeGroup	IO	0.25	0.26	0.25
MiddlePhalanxOutlineCorrect	IO	0.35	0.37	0.31
MiddlePhalanxTW	IO	0.42	0.40	0.40
MoteStrain	SR	0.17	0.18	0.19
Non-Invasive Fetal ECG Thorax1	SR	0.21	0.71	0.24
Non-Invasive Fetal ECG Thorax2	SR	0.14	0.88	0.18
OliveOil	SR	0.17	0.17	0.20
OSU Leaf	IO	0.41	0.52	0.43
PhalangesOutlinesCorrect	IO	0.27	0.31	0.20
Phoneme (readme)	SR	0.77	0.80	0.77
Plane	IO	0.00	0.21	0.00
ProximalPhalanxOutlineAgeGroup	IO	0.20	0.16	0.18
ProximalPhalanxOutlineCorrect	IO	0.22	0.20	0.17
ProximalPhalanxTW	IO	0.26	0.28	0.23
RefrigerationDevices	SR	0.54	0.53	0.50
ScreenType	SR	0.60	0.57	0.62
ShapeletSim	Syn	0.35	0.45	0.46
ShapesAll	IO	0.23	0.90	0.29
SmallKitchenAppliances	SR	0.36	0.27	0.22
SonyAIBORobot Surface	SR	0.28	0.29	0.13
SonyAIBORobot SurfaceII	SR	0.17	0.21	0.21
StarLightCurves	SR	0.09	0.07	0.05
Strawberry	SR	0.06	0.13	0.09
Swedish Leaf	IO	0.21	0.48	0.18
Symbols	IO	0.05	0.24	0.10
Synthetic Control	Syn	0.01	0.05	0.03
ToeSegmentation1	MC	0.23	0.28	0.26
ToeSegmentation2	MC	0.16	0.27	0.27
Trace	SR	0.00	0.09	0.06
Two Patterns	Syn	0.00	0.03	0.00
TwoLeadECG	SR	0.10	0.20	0.20
uWaveGestureLibraryX	MC	0.27	0.31	0.23
uWaveGestureLibraryY	MC	0.37	0.39	0.31
uWaveGestureLibraryZ	MC	0.34	0.35	0.29
UWaveGestureLibraryAll	MC	0.11	0.39	0.10
Wafer	SR	0.02	0.03	0.02
Wine	SR	0.43	0.48	0.35
WordSynonyms	IO	0.35	0.63	0.47
Worms	IO	0.54	0.48	0.51
WormsTwoClass	IO	0.34	0.34	0.34
Yoga	IO	0.16	0.24	0.19

参考文献

[Anava 16] Anava, O. and Levy, K.: k*-nearest neighbors: From global to local, in *Advances in Neural Information Processing Systems*, pp. 4916–4924 (2016)

[Chen 15] Chen, Y., Keogh, E., Hu, B., Begum, N., Bagnall, A., Mueen, A., and Batista, G.: The UCR Time Series Classification Archive (2015), `www.cs.ucr.edu/~eamonn/time_series_data/`

[Friedman 01] Friedman, J. H.: Greedy function approximation: a gradient boosting machine, *Annals of statistics*, pp. 1189–1232 (2001)

[Nakagawa 17] Nakagawa, K., Imamura, M., and Yoshida, K.: Stock Price Prediction using k*-Nearest Neighbors and Indexing Dynamic Time Warping, in *Artificial Intelligence of and for Business (AI-Biz 2017)* (2017)

[Yamada 03] Yamada, Y., Suzuki, E., Yokoi, H., and Takabayashi, K.: Decision-tree induction from time-series data based on a standard-example split test, in *Proceedings of the 20th International Conference on Machine Learning (ICML-03)*, pp. 840–847 (2003)

表 2: Average Error Rate of UCR Time-series Datasets by Category

Category	1-NN DTW	TST	TSGBT
Image Outline	0.23	0.49	0.24
Motion Classification	0.27	0.36	0.20
Sensor Readings	0.24	0.37	0.19
Synthetic	0.00	0.03	0.00

[山田 03] 山田悠, 鈴木英之進, 横井英人, 高林克日己 他：動的時間伸縮法に基づく時系列データからの決定木学習, 情報処理学会研究報告知能と複雑系 (ICS), Vol. 2003, No. 30 (2002-ICS-132), pp. 141–146 (2003)

[中川 18] 中川慧, 今村光良, 吉田健一：時系列勾配ブースティング木による分類学習金融時系列予測への応用, 人工知能学会全国大会論文集 2018 年度人工知能学会全国大会 (第 32 回) 論文集社団法人 人工知能学会 (2018)

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

Batch Random Walk for GPU-Based Classical Planning (Extended Abstract)

Ryo Kuroiwa Alex Fukunaga

Graduate School of Arts and Sciences, The University of Tokyo

Graphical processing units (GPUs) have become ubiquitous because they offer the ability to perform cost and energy efficient massively parallel computation. We investigate forward search classical planning on GPUs based on Monte-Carlo Random Walk(MRW). We first propose Batch MRW (BMRW), a generalization of MRW which performs random walks starting with many seed states, in contrast to traditional MRW which used a single seed state. We evaluate a sequential implementation of BMRW on a single CPU core and show that a sequential, satisficing planner based BMRW performs comparably with Arvand, the previous MRW-based planner. Then, we propose BMRW$_G$, which uses a GPU to perform random walks. We show that BMRWG achieves significant speedup compared to BMRW and achieves competitive performance on a number of IPC benchmark domains. This is an extended abstract of an ICAPS2018 paper [Kuroiwa 18].

1. Introduction

The use of Graphics Processing Units (GPUs) for general-purpose computing has become ubiquitous in many areas including AI, but their use in domain-independent planning has been quite limited. This seems largely due to the fact that there is a significant mismatch between the architecture of GPUs and forward heuristic search based algorithms commonly used for planning. For satisficing, classical planning, the most widely studied forward search strategy in recent years have been approaches such as Greedy Best First Search (GBFS), as well as many improvements which seek to avoid/escape local minima and plateaus.

In standard GBFS, Enhanced Hill-Climbing, and weighted A* approaches, each node expansion involves accessing global open/closed sets, which poses a challenge for efficient parallelization. Methods for efficiently distributing work in parallel best-first search (BFS) based planners on multi-core machines as well as clusters have been studied [Burns 10, Kishimoto 13], but these previous approaches for parallel BFS can not be straightforwardly applied to GPUs. One major issue is that GPUs provide thousands of cores/threads, but the amount of GPU RAM available per thread is quite limited. For example, a state-of-the-art Nvidia GTX1080 has 8GB global RAM, which must be shared by 2560 physical CUDA cores. This will be exhausted within a few seconds by a parallel BFS algorithm if the open/closed lists are stored on the GPU, as in GA*, a delayed duplicate detection based A* for the GPU [Zhou 15]. There is also a tiny amount of fast RAM per core ($\sim$375 bytes/core on a GTX1080), and although previous work has investigated performing domain-specific IDA* search using only this local memory [Horie 17], this is too small to hold even a single state for most domain-independent planning domains. Sulewski et al. ([Sulewski 11]) used a GPU to parallelize the successor generation step for breadth-first search in cost-optimal planning, with duplicate detection and open/closed list management performed on the CPU. A forward *heuristic* search method for satisficing planning which effectively uses the GPU has remained an open problem.

One approach to heuristic-driven forward search which encourages explorative search behavior and is suited for GPU parallelization is Monte Carlo Random Walk Planning (MRW) [Nakhost 09]. At each step, MRW starts at some state s (initially the initial state), performs a set of random walks from s, and then sets s to the best endpoint (according to a heuristic function) found by the random walks. State-of-the-art MRW-based planners have been shown to be competitive with GBFS-based approaches on some domains [Nakhost 13]. MRW appears to be suited for GPU parallelization because each random walk can be executed independently by a GPU thread.

In this paper, we first propose BMRW, a simple generalization of MRW-based search which combines an open list based search strategy with MRW. In BMRW, the search is driven by an open list, as in GBFS. In each iteration, a batch of nodes is selected from the open list, and random walks are performed starting with these nodes. Promising states found by the random walks are then inserted into the open list, and this cycle repeats until a goal is found or time runs out. We experimentally show that BMRW is a promising search strategy, and show that a planner using BMRW search on a single CPU core is competitive with Arvand13, the previous, state-of-the-art MRW based sequential planner.

Next, we propose BMRW$_G$, an efficient, parallel implementation of BMRW for GPUs. BMRW$_G$ maintains the open list in CPU memory, but uses the GPU for the random walks. We show that BMRW$_G$ achieves significant speedup compared to BMRW, and that BMRW$_G$ achieves competitive performance on a number of standard IPC benchmark domains.

2. Monte-Carlo Random Walk Planning

Monte-Carlo Random Walk Planning (MRW) was first proposed in the Arvand planner [Nakhost 09]. The state-of-the-art Arvand13 MRW-based planner, which performs significantly better than the original Arvand planner, works as follows: Given a state s, a basic *random walk* repeatedly generates successors of s, chooses one of the successors s' of s and transitions to s' ($s \rightarrow s'$). From the current node s (initially set to the start state), the Arvand13 MRW algorithm perform a set of random walks. Each state on the walk is evaluated according to a heuristic evaluation function h (the FF heuristic [Hoffmann 01] was used), and the walk returns

either when (a) it encounters a state with a better h-value than the random walk start state, in which case that state becomes the start point for the next random walk, or (b) with some probability (i.e., local restart). A global restart is triggered when h does not improve after some number of random walks. Arvand13 used an enhanced random walk which, instead of uniformly randomly choosing a successor, biased successor choice according to *helpful actions* identified by the FF heuristic. In addition, local and global start thresholds are set adaptively.

3. Batch Monte-Carlo Walk (BMRW)

We now propose BMRW, a generalization of MRW. BMRW, shown in Alg. 1, maintains a priority queue $openList$, initially containing the successors of the initial state s_0. In each iteration of the main loop (lines 21–36), BMRW first checks if $openList$ is empty, and if so, initializes it with the successors of the start state s_0, i.e., it performs a *global restart*. Then, a *batch* of $batchSize$ nodes is selected from $openList$. A random walk (Alg. 1, Walk function) of up to l steps is peformed from each start point in $batch$, and the results are stored in $walkres$.

The main differences between BMRW and MRW are: (1) MRW performs random walks from the same start state, while BMRW performs a set of random walks based on a batch of start states selected from $openList$. (2) MRW only keeps and updates a single "current state" (which is used as the start point for random walks), while BMRW maintains an $openList$, similar to GBFS-based approaches. Thus, BMRW can be viewed as a hybrid between MRW and GBFS. (3) In MRW, every random walk is followed by a possible update of the current state (jump to the state returned by the walk), whereas BMRW performs an entire batch of walks at a time.

In addition to the above basic scheme, BMRW uses an *elite insertion* policy (lines 32-36), where for the best n results (according to h-value) of the random walk return, the successors of those nodes are inserted into $openList$ instead of the nodes themselves. This is intended to strongly encourage further exploration of these "elite" nodes by pushing its many successors into $openList$ (because these successors also have good h-values, they are likely to be expanded soon).

Furthermore, a $closedList$ is used in order to prevent duplicate states from being pushed into the open list (lines 30-31). This ensures that each random walk starts from a different start state, promoting exploration of the search space.

MRW can be viewed as a special case of BMRW with batch size $b = 1$ and a special $openList$ limited to size 1.

3.1 BMRW$_G$: BMRW on a GPU

In principle, BMRW can be efficiently implemented on a GPU, due to the independence of each random walk. In Alg. 1 lines 25-26, the for loop is executed in parallel on the GPU. After each node in the batch selected in line 24 is copied to the GPU, each node in the batch is assigned to a GPU thread, and each random walk is performed by a single GPU thread, after which the result of the walk is copied back to the CPU. Everything else is performed on the CPU.

The main bottleneck in implementing BMRW on a GPU is the relatively small amount of GPU RAM available per thread. Although GPUs have a substantial amount of global memory available on the GPU, (the GTX1080 we used has 8GB), this global RAM must be shared among all threads. The GTX1080 has 2560 CUDA cores (20 Streaming Multiprocessors, 128 cores/SM), roughly 3125KB/thread. Although a random walk does not require much memory for state information, as there is no open/closed list during the walk, it is necessary to maintain data structures for fast, incremental computation of heuristic values during the walk. For example, to compute the FF heuristic using the generalized Dijkstra method [Liu 02, Keyder 08], the cost and unsatisfied preconditions of each ground action is required. On the GTX1080, if we use 2560 threads, each thread can handle approximately 390,000 ground actions – this is sufficient for most IPC benchmark domains. However, this implies that we currently can not run BMRW with tens of thousands of threads to take even better advantage of the ability of GPUs to overlap communication and memory access. Note that larger domains can be handled by reducing the number of threads, at the cost of leaving some cores idle.

We used the Landmark Count (LMC) heuristic [Hoffmann 04] for BMRW$_G$. The landmark graph is built on the CPU once at the beginning of search, transferred to the GPU global RAM, and shared by all GPU threads. Computing the LMC value only requires incrementally updating the number of unreached landmarks for the state. This requires $O(\#facts)$ memory. As shown below, BMRW with the LMC heuristic significantly outperforms BMRW with the FF heuristic.

Algorithm 1 Batch MRW

```
1: function WALK(s, goals, l)
2:     s_best ← s
3:     for i ← 1 to l do
4:         if s ∈ goals then return s
5:         if DeadEnd(s) then s ← s_best
6:         else s ← RANDOMSELECT(successors(s))
7:         if h(s) < h(s_best) then s_best = s
8:     return s_best
9:
10: function FILLBATCH(openList, batchSize, batch)
11:     offset ← 0
12:     for i ← 1 to batchSize do
13:         if openList is Empty then
14:             if offset = 0 then State offset = i
15:             batch[i] ← batch[i − offset]
16:         else
17:             batch[i] ← POP(openList)
18:
19: function BATCHMRW(s_0, goals, l, batchSize, n)
20:     openList, closedList, batch, walkres ← φ
21:     loop
22:         if openList is Empty then
23:             openList ← successors(s_0)
24:         FILLBATCH(openList, batchSize, batch)
25:         for i ← 1 to batchSize do
26:             walkres[i] ← WALK(batch[i], goals, l)
27:         i ← 1
28:         for all s ∈ walkres do
29:             if s ∈ goals then return s
30:             if s ∈ closedList then continue
31:             INSERT(closedList, s)
32:             if i ≤ n then
33:                 PUSH(openList, successors(s), h(s))
34:                 i ← i + 1
35:             else
36:                 PUSH(openList, s, h(s))
```

4. Experimental Results

In our experimental evaluation (please see the full paper [Kuroiwa 18]), we evaluated a sequential implementation of BMRW on a single CPU core and showed that a sequential, satisficing planner based BMRW performs comparably with Arvand, the previous MRW-based planner. Then, we showed that BMRW$_G$ achieves significant speedup compared to BMRW and achieves

competitive performance on a number of IPC benchmark domains.

5. Conclusion

In order to exploit GPUs in domain-independent planning, we first proposed BMRW, a generalization of MRW which combines GBFS and random walk by performing a GBFS-like, $openList$-driven search, which at each iteration performs batches of random walks in order to explore the search space. *We showed that BMRW is competitive with previous random walk strategies, including Arvand13. We then showed that BMRW$_G$, a heterogeneous CPU/GPU implementation of BMRW, achieves significant speedup compared to BMRW and a straightforward parallelizatoin of MRW13.*

We have shown that random walk using the relatively lightweight Landmark Count heuristic can be efficiently implemented *entirely on the GPU*. In fact, MRW13, the baseline parallelization of Arvand13, runs almost entirely on the GPU, except for the top level loop, and in BMRW$_G$, only the global $openList$ and $closedList$ management are performed by the CPU. Our primary objective was to demonstrate the feasibility of GPU-based forward heuristic search, so we focused on efficient implementation on the GPU side, and the current implementation only uses a single CPU core. Effective, simultaneous usage of multiple CPU cores along with the GPU in a more heterogeneous algorithm is an avenue for future work. For example, $openList$ and $closedList$ management can be parallelized, as in [Sulewski 11].

While we focused on a relatively simple search strategy which is basically GBFS with (batched) random walk lookahead, random walk has been embedded as an exploration mechanism in other forward heuristic search variants such as RW-LS (ArvandLS) [Xie 12] and GBFS-LE [Xie 14]. It should be possible to combine these more complex algorithms with the basic idea of applying batches of random walks on the GPU with a diverse set of start points and a lightweight heuristic.

References

[Burns 10] Burns, E., Lemons, S., Ruml, W., and Zhou, R.: Best-first heuristic search for multicore machines, *Journal of Artificial Intelligence Research*, Vol. 39, pp. 689–743 (2010)

[Hoffmann 01] Hoffmann, J. and Nebel, B.: The FF Planning System: Fast Plan Generation through Heuristic Search, *J. Artif. Intell. Res.(JAIR)*, Vol. 14, pp. 253–302 (2001)

[Hoffmann 04] Hoffmann, J., Porteous, J., and Sebastia, L.: Ordered Landmarks in Planning, *J. Artif. Intell. Res.*, Vol. 22, pp. 215–278 (2004)

[Horie 17] Horie, S. and Fukunaga, A.: Block-Parallel IDA* for GPUs, in *Proceedings of the Tenth International Symposium on Combinatorial Search*, pp. 134–138 (2017)

[Keyder 08] Keyder, E. and Geffner, H.: Heuristics for Planning with Action Costs Revisited, in *ECAI 2008 - 18th European Conference on Artificial Intelligence, Patras, Greece, July 21-25, 2008, Proceedings*, pp. 588–592 (2008)

[Kishimoto 13] Kishimoto, A., Fukunaga, A., and Botea, A.: Evaluation of a simple, scalable, parallel best-first search strategy, *Artificial Intelligence*, Vol. 195, pp. 222–248 (2013)

[Kuroiwa 18] Kuroiwa, R. and Fukunaga, A.: Batch Random Walk for GPU-Based Classical Planning, in *Proceedings of International Conference on Automated Planning and Scheduling (ICAPS)* (2018)

[Liu 02] Liu, Y., Koenig, S., and Furcy, D.: Speeding Up the Calculation of Heuristics for Heuristic Search-based Planning, in *Eighteenth National Conference on Artificial Intelligence*, pp. 484–491, Menlo Park, CA, USA (2002), American Association for Artificial Intelligence

[Nakhost 09] Nakhost, H. and Müller, M.: Monte-Carlo Exploration for Deterministic Planning, in *Proceedings of the 21st International Jont Conference on Artifical Intelligence*, IJCAI'09, pp. 1766–1771, San Francisco, CA, USA (2009), Morgan Kaufmann Publishers Inc.

[Nakhost 13] Nakhost, H. and Müller, M.: Towards a Second Generation Random Walk Planner: An Experimental Exploration, in *Proceedings of the Twenty-Third International Joint Conference on Artificial Intelligence*, IJCAI '13, pp. 2336–2342, AAAI Press (2013)

[Sulewski 11] Sulewski, D., Edelkamp, S., and Kissmann, P.: Exploiting the Computational Power of the Graphics Card: Optimal State Space Planning on the GPU., in *Proceedings of the International Conference of Automated Planning and Scheduling(ICAPS)* (2011)

[Xie 12] Xie, F., Nakhost, H., and Müller, M.: Planning via random walk-driven local search, in *Proceedings of the International Conference of Automated Planning and Scheduling(ICAPS)* (2012)

[Xie 14] Xie, F., Müller, M., and Holte, R.: Adding Local Exploration to Greedy Best-First Search in Satisficing Planning, in *Proceedings of the Twenty-Eighth AAAI Conference on Artificial Intelligence, July 27 -31, 2014, Québec City, Québec, Canada.*, pp. 2388–2394 (2014)

[Zhou 15] Zhou, Y. and Zeng, J.: Massively Parallel A* Search on a GPU, in *Proceedings of the Twenty-Ninth AAAI Conference on Artificial Intelligence, January 25-30, 2015, Austin, Texas, USA.*, pp. 1248–1255 (2015)

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

時系列生成モデルのためのリサンプリング学習

Learning to resample for time-series generative model

金子 貴輝 *1　大澤 昇平 *2　松尾 豊 *3
Takaaki Kaneko　Shohei Ohsawa　Yutaka Matsuo

*1*2*3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

Sequential Monte Carlo (SMC) is a typical sampling method that can be sampled in order from a sequential probabilistic model. However, due to degeneration of the sample, SMC may produce samples with low likelihood with a small number of particles. In our study, we focus on the fact that the same resampling targets of SMC for each sample cause degenerating samples. We want to relax this constraint, but analytically deriving asymmetric sequential resampling targets is difficult. Therefore, we expand resampling strategy of SMC asymmetrically by learning the sequential resampling target from the target of the whole series approximated to the lower bound. By this, by learning to resample, it is expected that accurate estimation of latent variable can be realized with the same particle number as SMC.

1. はじめに

深層学習において，観測変数 x の背後の依存関係を表現するために，潜在変数 z で同時分布 $p(x,z)$ をモデル化すると，推論分布 $p(z|x)$ の扱い方がモデルの学習のために重要になる．例えば変分オートエンコーダ（VAE）[Kingma 13] では，モデルの学習基準である周辺尤度を表現するために，この分布を必要とする．そのためエンコーダで定義される別の分布に置き換えて基準を近似し，KL divergence 最小化を用いてその分布を推論分布に近づける．

特にマルコフ性を持つ時系列の潜在変数における推論分布 $p(z_{1:T}|x_{1:T})$ は，その扱い方が時間の長さ T にスケールするかが問われる基本的な例であり，汎用なアルゴリズムを目指す上で重要である．潜在変数の状態が離散的で計算機で扱えないほど多くなければ，隠れマルコフモデルのような解析的な扱いが可能な場合もある．しかし動画や音声情報を潜在変数に含める場合，密な表現として出現する状態の数は特徴の数に対して指数的に多くなりうる．この場合，解析的に扱うことも直接全体をエンコーダで置き換えることも，時間の長さにスケールしない．このような推論分布の深層学習による近似は研究途上の課題である．

時系列の推論分布に関する問題として，各時刻の潜在変数を推定する逐次推定の問題（2 章）があり，従来のアプローチとして代表的なものに Sampling Importance Resampling（SIR）の逐次適用を行う，逐次モンテカルロ（SMC）[Gordon 93] がある．SIR とは，粒子と呼ばれる確率変数の値の候補を複数持ち，途中までの尤度を使って粒子を選び直す手法である．SMC は将来的に得られるサンプルの尤度が予測できない問題を SIR で解決する手法であり，粒子フィルタとも呼ばれる．SMC によって時系列の推論分布の近似的なサンプルが得られるので，期待値をモンテカルロ近似することができる．3 章で述べるように，SMC の提案分布にニューラルネットを用いて推論分布を近似する研究も出てきている．

しかし SMC では途中までの分布での尤度が低い粒子は捨てられやすく，後から尤度が大きくなる粒子を本来より低い確率でサンプリングしてしまう．これは縮退問題として知られている．特に明らかな問題だと思われるのは，同程度の尤度の粒子を選び直すことで一部無くしてしまう傾向である．これは図 1（左）で示されるように，2 粒子 2 状態の単純な例（5.2 章参照）で顕著である．これは潜在変数が連続値でも起こりうる．

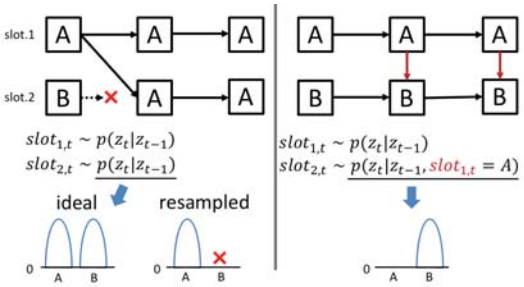


図 1: SMC と提案手法のリサンプリング方式の比較．観測変数は省略している．黒矢印はリサンプリングの流れを，アルファベットは潜在変数の値を表す．(左）SMC でのリサンプリング．独立同分布を用いてサンプルしている．(右）提案手法でのリサンプリング．リサンプリング結果を順に依存させて次のリサンプリングを行うことができる．

本研究では縮退問題のうち，この同程度の粒子をなくす問題に注目する．原因の一つは，リサンプリング目標がどの粒子でも同じであること，つまりリサンプリング目標の対称性である．多様なサンプルを保持できるように，本研究では図 1（右）のように，複数の粒子のリサンプリング目標を非対称にする．

最適な非対称リサンプリング目標は，未来の変数についての期待値の式になるため，一般には解析的に計算できない．学習によって逐次目標を獲得する方針は，計算時間などの有用性が乏しいため注目されてこなかった．しかし潜在変数系列の推論分布に対する新たなアプローチとして重要なアルゴリズムであると考えたため，本研究では逐次目標を学習によって獲得する新しい逐次リサンプリング手法を検討する．

提案手法では，非対称なリサンプリング目標を実現するため，リサンプリング重みに学習パラメータを追加して拡張する．これは従来の SIR のリサンプリング重みに，過去のサンプルを引数に取る新たな重みを掛け合わせることで実現できる．

さらに拡張した重みが縮退を軽減させる適切な値になるよ

連絡先: kaneko@weblab.t.u-tokyo.ac.jp

うに，最終目標 $p(z_{1:T}|x_{1:T})$ との KL 誤差の上界を学習基準として，勾配法を用いて重みを学習する．本研究では，この学習とそれによって獲得された非対称なリサンプリング目標によるリサンプリングのアルゴリズム（4 章）を提案手法とする．学習基準は上界であるため，必ず良い方向に学習が進むとは限らないのは問題であるが，5.1 章で示すように，過去の情報の解釈が未来の尤度に大きく寄与するのに，長期に渡って複数の解釈が尤もらしい状況を簡略化した問題においては，SMC よりも提案手法が正確なサンプリングを目指す学習基準になることを保証できる．

時系列確率モデルでの縮退の軽減を検証するため，本研究では前述の問題設定で実験（5 章）を行い，学習基準と正答率が連動し，SMC より提案手法が正確なリサンプリングが行えることを示した．

2. 問題設定

時系列マルコフモデルの同時分布を以下の式で定義する．

$$p(z_{1:T}, x_{1:T}) = \prod_{t=1}^{T} p(z_t, x_t|z_{t-1}),$$
$$p(z_1, x_1|z_0) = p(z_1, x_1)$$

このモデルからサンプルされた系列 $(x_{1:T}, z_{1:T})$ の $x_{1:T}$ から $z_{1:T}$ を推定し，その誤差の期待値を最小化する問題を考える．

$$\mathbb{E}_{p(z_{1:T}, x_{1:T})}\left[L(z_{1:T}, \hat{z}_{1:T})\right]$$

ただし L は適当な損失関数，$\hat{z}_{1:T}$ は $x_{1:T}$ を用いた推定値とする．

3. 関連研究

2 章の問題には，SMC を基本とした様々なアルゴリズムが提案されてきたが，近年，時系列生成モデルの学習の文脈から，深層学習と SMC を組み合わせる新しい手法が提案されている．SMC とこの新しい手法の二つについて説明する．

3.1 SMC

SMC は時刻 $t = 1$ から $t = T$ まで以下の式で表されるサンプリングを繰り返すアルゴリズムである．

$$\begin{aligned}
&propose && z_t^j \sim r(z_t|z_{1:t-1}^{a_{t-1}^j}),\\
&append && z_{1:t}^j = \{z_{1:t-1}^{a_{t-1}^j}, z_t^j\},\\
&reweight && w_t^j = \frac{p(z_t^j, x_t|z_{t-1}^{a_{t-1}^j})}{r(z_t^j|z_{1:t-1}^{a_{t-1}^j})},\\
&resample && a_t^i \sim \mathrm{Categorical}(w_t^i / \sum_l w_t^l)
\end{aligned}$$

$z_{1:t-1}^{a_{t-1}^j}$ は $t-1$ での j 番目の粒子であり，提案分布 r によって t での潜在変数の値 z_t^j が加わり $z_{1:t}^j$ となる．これを SIR のリサンプリング重み w_t^j にしたがってリサンプリングを行い t での i 番目の粒子 $z_{1:t}^{a_t^i}$ を得る．

SMC では，粒子間でリサンプリング重みを比較し a_t^i をリサンプリングすることで，尤度 $p(z_{1:t}, x_{1:t})$ を正規化して推論分布 $p(z_{1:t}|x_{1:t})$ を計算することなく，近似的なサンプリングを可能としている．しかし全体での目標分布は $p(z_{1:T}|x_{1:T})$ であるため，このリサンプリングが最適であるとは限らない．

3.2 Variational SMC

Variational SMC（VSMC）[Naesseth 17] は VRNN[Chung 15] のような時系列生成モデルを拡張して，SMC と組み合わせたエンコーダとそれに対応した学習基準からなる．SMC における提案分布をニューラルネットで定義できるので，長期的な依存関係を学習することができ，エンコーダで推論分布をさらにうまく近似できるようになった．

本研究の式導出はこれらの研究を参考にしているが，学習させるパラメータは異なる．これらの研究ではエンコーダのパラメータを学習することが目標であり，リサンプリング重みにパラメータは置いていない．

4. 非対称逐次リサンプリング

SMC を非対称なリサンプリングに拡張した提案手法について説明する．まず重みの定義とリサンプリングアルゴリズムを定義したのち，パラメータを学習するための同時分布と学習目標の定義，学習のための勾配法の利用について説明する．

4.1 非対称逐次リサンプリングの定義

時刻 t での，SMC でのリサンプリングを以下の拡張したリサンプリング重みの式で置き換える．

$$\begin{aligned}
&reweight && w_t^{i,j} = \frac{p(z_t^j, x_t|z_{t-1}^{a_{t-1}^j})}{r(z_t^j|z_{1:t-1}^{a_{t-1}^j})} \cdot w_{t,i}^{\Delta}(z_t^j; z_{1:t-1}^{a_{t-1}^j}, z_t^{a_t^{<i}}),\\
&resample && a_t^i \sim w_t^{i,\cdot} / \sum_l w_t^{i,l}
\end{aligned}$$

拡張重み $w_{t,i}^{\Delta}$ は多段のニューラルネットを用いてモデル化する．$z_t^{a_t^{<i}}$ は i 番目より前のリサンプリングされた粒子の組 $\{z_t^{a_t^k}|0 \le k < i\}$ を表す．リサンプリングの計算順序は図 2 のグラフで示すようになる．

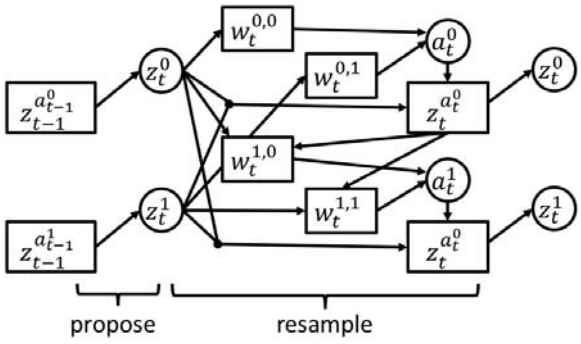


図 2: 提案手法の各時間ステップの計算グラフ．円形のノードが確率変数を，正方形のノードが決定論的な変数を表す．SMC と同様に提案分布（propose）からのサンプリングの後，拡張したリサンプリング重み $w^{i,*}$ と選ばれる粒子 z^{a^i} を粒子のスロット i ごとに繰り返し計算してリサンプリングを行う（resample）．

4.2 同時分布

棄却される粒子も含めた全ての同時分布 ϕ は以下の式で表される．

$$\phi(z, b, a) = \left[\prod_i r(z_1^i)\right] \prod_{t=2}^{T} \prod_i \left[\frac{w_{t-1}^{i,a_{t-1}^i}}{\sum_l w_{t-1}^{a_{t-1}^i}} r(z_t^i|z_{t-1}^{a_{t-1}^i})\right] \left[\frac{w_T^{1,b_T}}{\sum_l w_T^{1,l}}\right]$$

ここで $z = \{z_t^i | t = 1 \dots T, i = 1 \dots N\}, a = \{a_t^i | t = 1 \dots T, i = 1 \dots N\}, b = b_T$ とした．これを周辺化することで提案手法のサンプリング分布が表される．

$$q(z_{1:T}) = q(z_{1:T}^{b_{1:T}}) = \sum_{b_{1:T}} \sum_{a_{1:T}^{\neg b_{1:T}}} \sum_{z_{1:T}^{\neg b_{1:T}}} \phi(z, b, a)$$

ただし $b_t = a_t^{b_{t+1}}, z_{1:T}^{\neg b_{1:T}} = \{z_t^{\neg b_{t+1}} | 1 \leq t \leq T\}, z_t^{\neg b_{t+1}} = \{z_t^i | i \neq b_{t+1}\}, a_{1:T}^{\neg b_{1:T}} = \{a_t^{\neg b_{t+1}} | 1 \leq t \leq T\}, a_t^{\neg b_{t+1}} = \{a_t^i | i \neq b_{t+1}\}$ とする．

4.3 学習基準の導出

目標分布とサンプリング分布で定義される次の KL divergence を最小化することを考える．

$$\mathbb{E}_{p(x_{1:T})}\left[D_{\mathrm{KL}}(q \| p)\right] = \mathbb{E}_{p(x_{1:T})q(z_{1:T}|x_{1:T})}\left[\log \frac{q(z_{1:T}|x_{1:T})}{p(z_{1:T}|x_{1:T})}\right]$$

サンプリング分布に含まれる周辺化計算が解析的に行えないため，以下でイェンセンの不等式を用いた学習基準の近似を行う．

KL divergence の最小化は VAE のエビデンス下界 [Kingma 13] の最大化と一致する．

$$\begin{aligned}
&- \mathbb{E}_{p(x_{1:T})}\left[D_{\mathrm{KL}}(q \| p)\right] \\
&= \mathbb{E}_{p(x_{1:T})q(z_{1:T}|x_{1:T})}\left[\log \frac{p(z_{1:T}, x_{1:T})}{q(z_{1:T}|x_{1:T})}\right] - \mathbb{E}_{p(x_{1:T})}\left[\log p(x_{1:T})\right]
\end{aligned}$$

この式のサンプリング分布の対数尤度を計算し，真の対数尤度と残りに分解する．

$$\begin{aligned}
\phi(z, b, a) =& \prod_{t=1}^{T}\left[\frac{w_t^{b_{t+1}, b_t}}{\sum_l w_t^{b_{t+1}, l}}\right] \prod_{i \neq b_1} r(z_1^i) \\
& \cdot \prod_{t=2}^{T} \prod_{i \neq b_t} \left[\frac{w_{t-1}^{i, a_{t-1}^i}}{\sum_l w_{t-1}^{i,l}}\right] \prod_{t=1}^{T}\left[r(z_t^{b_t} | z_{t-1}^{b_{t-1}})\right] \\
=& \prod_{t=1}^{T}\left[\frac{w_t^{b_{t+1}, b_t}}{\sum_l w_t^{b_{t+1}, l}} r(z_t^{b_t} | z_{t-1}^{b_{t-1}})\right] \cdot \phi(x^{\neg b}, a^{\neg b} | x^b, b)
\end{aligned}$$

ただし，以下のように置いた．

$$\phi^{\neg b} = \phi(z^{\neg b}, a^{\neg b} | z^b, b) = \prod_{i \neq b_1} r(z_1^i) \prod_{t=2}^{T} \prod_{i \neq b_t} \left[\frac{w_{t-1}^{i, a_{t-1}^i}}{\sum_l w_{t-1}^{i,l}}\right]$$

SIR のリサンプリング重みから目標分布の尤度を取り出して，次のように式変形する．

$$\begin{aligned}
&\phi(z, b, a) \\
&= \prod_t \left[\tilde{p}(z_t^{b_t}, z_{1:t-1}^{b_{t-1}})\right] \cdot \prod_t \left[\frac{w_{t, b_{t+1}}^{\Delta}(z_t^{b_t}; x_t, z_{t-1}^{b_{t-1}}, z_t^{a_t^{<b_{t+1}}})}{\sum_l w_t^{b_{t+1}, l}}\right] \\
&\quad \cdot \phi(x^{\neg b}, a^{\neg b} | x^b, b) \\
&= p(z^b, x) \cdot W \cdot \phi(z^{\neg b}, a^{\neg b} | z^b, b)
\end{aligned}$$

ただし，以下のように置いた．

$$W = \prod_t \left[\frac{w_{t, b_{t+1}}^{\Delta}(z_t^{b_t}; x_t, z_{t-1}^{b_{t-1}}, z_t^{a_t^{<b_{t+1}}})}{\sum_l w_t^{b_{t+1}, l}}\right]$$

すると $q(z_{1:T}) = p(z) \sum_{b_{1:T}} \mathbb{E}_{\phi^{\neg b}}\left[W\right]$ となるので，真の対数尤度がキャンセルする．

$$\begin{aligned}
&\mathbb{E}_q\left[\log p - \log q\right] \\
&= \sum_z q(z)(\log p - \log p - \log \sum_b \mathbb{E}_{\phi^{\neg b}}\left[W\right]) \\
&= - \sum_z p(z) \sum_b \mathbb{E}_{\phi^{\neg b}}\left[W\right] \log \sum_b \mathbb{E}_{\phi^{\neg b}}\left[W\right]
\end{aligned}$$

次に期待値と対数尤度に使われているサンプリング分布の b についての周辺化を人工的な一様分布 $p(b_{1:T}) = \frac{1}{N^T}$ で置き換え，式に含まれる凸関数 $f(x) = -x \log(x)$ に対してイェンセンの不等式を適用する．

$$\begin{aligned}
&\mathbb{E}_q\left[\log p - \log q\right] \\
&= - \sum_z p(z) \sum_b \frac{1}{N^T} \mathbb{E}_{\phi^{\neg b}}\left[N^T W\right] \log \sum_b \frac{1}{N^T} \mathbb{E}_{\phi^{\neg b}}\left[N^T W\right] \\
&\geq \mathbb{E}_{p(z)}\left[\mathbb{E}_{p(b)}\left[\mathbb{E}_{\phi^{\neg b}}\left[N^T W \log(N^T W)^{-1}\right]\right]\right] \\
&= \sum_z \sum_b \sum_{a^{\neg b}, z^{\neg b}} p(z) W \phi^{\neg b} \cdot \left[\log(N^T W)^{-1}\right]
\end{aligned}$$

すると得られる下界はサンプリングの同時分布の期待値と，計算可能なその中身によって成り立っているため，モンテカルロ近似で算出可能な学習目標となる．

$$L(\lambda) = \mathbb{E}_\phi\left[\log(\frac{1}{N} W^{-1})\right]$$

この学習目標は重みが対称なとき VSMC の学習基準と一致する．ただし VSMC ではこの学習基準は提案分布の学習に用いられるのに対し，本手法では SMC を拡張する重みの学習に用いられている．またこの学習目標は下界であるため，この最大化は KL divergence を最小化することを保証しないが，長期的な依存関係が重視される場合においては，下界を高めることが KL divergence を下げることに繋がることが言える．(5.3 章で後述)

4.4 勾配法

分布にパラメータを含むため，勾配を計算すると方策勾配の項が導出される．VSMC では，この項は高分散であるとして実装上は無視されていた．しかし今回の導出ではリサンプリング目標を学習する上で，離散な確率変数 a_t^i が重要になるため，項を無視しなかった．

5. 実験

提案手法を調べるため，実世界の一部の問題を簡略化したトイプロブレムを構成する．

この構成とそれが簡略化していると考えたものについてまず説明し，次に SMC を使用すると起きる問題について説明する．このとき提案手法の学習基準はより良いパラメータを測ることができることを確認し，実際の実験設定について説明する．得られた結果から，提案手法がトイプロブレムで SMC より正確に潜在変数を推定できることを主張する．

5.1 保留期間の長いトイプロブレム

潜在変数も観測変数も 2 状態しかない時刻 $1 \leq t \leq T$ の隠れマルコフモデルを考える．$t = 1$ で潜在変数は一様な確率で 2 状態を取り，時刻 T まで観測変数は潜在変数と独立して決まり，潜在変数は確率 ε_τ で別状態に変化して遷移し，時刻 T で確率 $1 - \varepsilon$ で潜在変数の状態に対応する観測変数が得られる生成モデルを考える．このモデルでの時刻 T までを保留期間とし，時刻 1 で保留された 2 状態を T まで縮退せずに保持できるかを見ることができる．

保留されるべき 2 状態は，動画や音声情報などを潜在変数に符号化した場合の扱いきれない状態数のうち，ある時刻で同程度の尤度を持つものの簡略表現とした．また，確率 ε_τ と ε が小さいほど潜在変数は確定的に遷移して T で観測されることは，同程度の尤度を持つ候補の情報が T ステップ後の状態推定に重要な意味を持つ状況の表現とした．最後に時刻 T まで潜在変数と観測変数が独立していることは，保留期間中に候補が同程度の尤度を持つ状況が変化しない状況の表現とした．

5.2 SMC による縮退問題

SMC を用いてこの 2 状態を保持した粒子をリサンプリングすると，各リサンプリングごとに 1/2 の確率で片方を取りこぼす．これはサンプルごとに対称なリサンプリング目標を使う限り避けられない．取りこぼした片方が時刻 T に観測された場合，ε_τ と ε が小さいほど，尤度の低いサンプルとなる．

5.3 下界での評価

このトイプロブレムでは，ε を限りなく 0 に近づければ，誤ったサンプルに対する対数尤度は $-\infty$ に発散する．すると提案手法の学習基準は，非対称なリサンプリングが最後が誤ったサンプルを生成する確率を低くする限り，下界を限りなく上昇させる．そしてそのような非対称なリサンプリングを実現するパラメータは拡張重み w^Δ に十分な自由度があれば，存在することがわかる．よって，学習過程でそのようなパラメータにたどり着ける限り，下界評価によって学習の進捗を評価できる．

5.4 実験設定

このトイプロブレムを使って提案手法が長期的なサンプリング目標に備えて SMC より縮退を減少させられることを確認した．状態数が多く，取りこぼした粒子の情報を回復できない状況を表すため，トイプロブレムの遷移分布 $p(z_t|z_{t-1})$ を提案分布として固定した．トイプロブレムのパラメータは $T = 4, \varepsilon_\tau = \varepsilon = 0.0005$ とした．保留期間中は観測変数から潜在変数を推定できないため，時刻 T での真の潜在変数と推定した潜在変数を比較し，正答率を評価基準とした．比較対象として毎回リサンプリングを行う SMC と，時刻 T 以外はリサンプリングを行わない SMC を比較対象とした．

モデルのパラメータは，拡張重みのネットワークは 2 層で 1 層目の活性化関数は ELU，2 層目は線形のままにした．2 層目のユニット数は 2 とした．勾配法には Adam を使用した．バッチサイズは 32，学習率は 0.001 とした．粒子数=2 とした．

5.5 実験結果

学習ステップの間の正答率の変化をグラフにすると図 3 のようになった．初期のパラメータでは拡張重み $w^\Delta \approx 1$ なので SMC と同じ正答率だが，学習を進めるにつれてリサンプリングしない場合の正答率に近づいた．このトイプロブレムにおいて提案手法が非対称なリサンプリング目標を学習によって獲得し，SMC よりも正確に潜在変数を推定できることを示した．

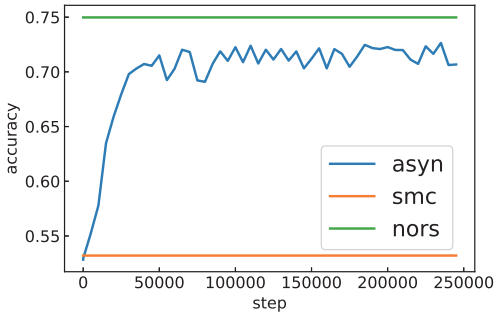


図 3: 学習に伴う最終時間でのサンプル状態の正答率の変化．橙線は SMC，緑線は最終時間のみリサンプリングした場合，青線が提案手法，のそれぞれの正答率．縮退を抑えるよう学習できている．

6. まとめ

本研究では，SMC において粒子を縮退させる原因としてリサンプリングの目標の対称性に注目し．下界によってこのリサンプリング目標を近似して学習することで，SMC のリサンプリング戦略を非対称に拡張し，トイプロブレムでの縮退の軽減を検証した．これにより SMC と同じ粒子数で，正確な潜在変数の推定を実現できる場合が存在することが示された．

一方，今後の課題として，縮退の軽減によるサンプル効率が計算効率に繋がるかの解明が挙げられる．非対称なサンプリングの内，リサンプリング結果に依存する部分は並列化できないため，計算効率が上がるとは限らないからである．今回は明示的に非対称性を学習するためにリサンプリング結果を引数としたが，これは非対称性からの必要条件かは不明である．これについては今後検証していきたい．

謝辞

本研究は JSPS 科研費 JP15H05327,JP16H06562 の助成を受けたものです。

参考文献

[Chung 15] Chung, J., Kastner, K., Dinh, L., Goel, K., Courville, A. C., and Bengio, Y.: A Recurrent Latent Variable Model for Sequential Data, in Cortes, C., Lawrence, N. D., Lee, D. D., Sugiyama, M., and Garnett, R. eds., *Advances in Neural Information Processing Systems 28*, pp. 2980–2988, Curran Associates, Inc. (2015)

[Gordon 93] Gordon, N. J., Salmond, D. J., and Smith, A. F. M.: Novel approach to nonlinear/non-Gaussian Bayesian state estimation, *IEE Proceedings F - Radar and Signal Processing*, Vol. 140, No. 2, pp. 107–113 (1993)

[Kingma 13] Kingma, D. P. and Welling, M.: Auto-encoding variational bayes, *arXiv preprint arXiv:1312.6114* (2013)

[Naesseth 17] Naesseth, C. A., Linderman, S. W., Ranganath, R., and Blei, D. M.: Variational Sequential Monte Carlo, *ArXiv e-prints* (2017)

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

テキストチャットにおけるクエリ終了タイミングの検出

End-of-Query Detection in Text Chat System

田中 駿
Shun Tanaka

株式会社サイバーエージェント
CyberAgent, Inc.

I propose a prediction model for end-of-query detection. It is a common practice that a chatbot system responds an answer when they get a single utterance from the user. A problem arises when a human breaks their query into multiple utterances and a chatbot system can not respond appropriately, leading to lower user experience. In this paper, I propose a prediction method based on LSTM for end-of-query detection.

1. はじめに

近年，コールセンターにおける人件費削減などを目的として，顧客からの問い合わせに自動応答を行う対話システムを提供する事業者が増えている．事業者が提供する多くの対話システムでは，ユーザから送られた発話 *1 に対して適切な返答を用例から検索，もしくは生成し応答する，一問一答形式の対話システムが採用されている．その一方で，人間の発話には 1 つの会話のまとまり (クエリ) を複数発話に分けて送信する現象が見られる場合があり，複数発話に分割されたクエリに対して，一問一答形式の対話システムでは適切な応答を返せない場合がある．

表 1 にブログサービスのコールセンターにおける，オペレータとユーザの対話例を挙げる *2．ユーザからの発話，#2，#3 は「以前記事を投稿していたブログに記事を投稿しようとしたところ，ログインができなかった (故にログイン ID，パスワード等の再設定を行いたい)」という趣旨の一つのクエリであるが，ユーザはこのクエリを 2 つの発話に分割して発話している．理想的には，#2，#3 を合わせて一つのクエリと捉え，「ログインできない場合のアカウントの再設定方法」などの回答を提示することが適切と考えられるが，現状の対話システムでは，#2 の発話を受信した時点で，用例との類以度検索を行い，「ブログへの記事投稿の方法」などの回答を提示してしまう可能性がある．このように複数発話に分割されたクエリを適切に扱えないことは，応答精度の低下に伴うユーザ満足度 (ユーザエクスペリエンス) の低下や顧客流出を招く要因になると考えられる．

そこで本研究では，対話システムがより適切に応答できるよう，ユーザから送信された発話に対して，その発話でクエリとして完結するか否かを予測する手法を提案する．

表 1: ユーザとオペレータの対話例

#	発話者	発話内容
1	オペレータ	ログインできないとのことですが、現在どのような状態でしょうか？ ID・登録メールアドレスのアカウント情報と、ログインできない詳細をお教えください。
2	ユーザ	以前に記事を投稿していましたが
3	ユーザ	久しぶりに投稿しようとしたらログインできませんでした。

2. 先行研究

Lala ら [Lala 17] は人と音声対話を行うロボットが適切なタイミングであいづちを打てるようにするため，ロジスティック回帰を用いて直近 500ms 以内にあいづちをすべきかどうかを予測するモデルを提案した．CRF を用いて特徴的な単語に対してフォーカスする手法，決定木を用いてフォーカスした単語に対して質問を返すべきか，単語を復唱するべきかを決定する手法，ロジスティック回帰を用いたロボットが返答すべきタイミングかどうかを判別する手法を提案した．それぞれの手法に対する個別の評価と，それらを併せてアンドロイド Erica に導入した際の評価を行った．

Skantze ら [Skantze 17] は，音声対話において，音声データから素性 (音声区間，ピッチ，パワー，品詞など) を抽出し LSTM の入力とすることで連続的に発話の交代を予測する 3 つのモデルを提案した．タスク指向型の音声対話データである HCRC MapTaskCorpus [Thompson 93] を使用し，発話が止まった際に次の話者を予測するタスクと，発話開始時に一連の発話の長さを予測するタスクで実験・評価を行い，従来のルールベースなどの手法と比べ精度が向上することを示した．

これらの研究は，系列情報をモデル化できる CRF や LSTM などを用いて，ユーザの音声発話データに含まれる情報をもとに発話の転換点を推定するというものであり，言語情報だけでなく，ピッチやパワーなどのいわゆる non-verbal な情報を多く用いて解析を行っている．その一方でテキストチャットにおいては，会話相手の表情や音声など，non-verbal な情報を取得することができず，verbal な情報のみで推定を行う必要があり，言語情報のみを対象にして発話の転換点を推定するタスクは今までに行われていない．

連絡先: 株式会社サイバーエージェントアドテク本部 AI Lab, tanaka_shun_xa@cyberagent.co.jp

*1 本稿では，テキストチャットにおいて送信ボタンを押した際に送信される文字列の単位を発話，ユーザとボット・オペレータの一連の発話の集合を対話と呼んでいる．

*2 情報保護の観点から，実際の対話ログをもとに類似する対話を作成した．

表 2: データセットの内訳

データセット	対話数	ユーザ発話数	ラベル 1 の割合	ラベル 0 の割合
学習	22,160	140,170	0.79	0.21
開発	2,770	17,476	0.80	0.20
評価	2,770	17,808	0.78	0.22

3. データ作成

本研究では，弊社の子会社でチャットボット事業を展開している，株式会社 AI メッセンジャー (AIM)[*3] での対話ログを用いてデータセット作成を行った．AIM の提供するサービスでは，ユーザから発話が送信された際，基本的にはボットが一問一答形式での応対を行うが，ユーザの問題を解決できなかった場合や，ユーザがオペレータとの会話を希望した際は人間のオペレータが応対を行うことができるサービスとなっている．

ユーザとオペレータの会話は人間同士の会話であるため，対話相手の発話にまだ続きがありそうだと判断した際は対話相手の発話の続きを待つという行動が見られる．そこで，ユーザとオペレータの応答ログをもとに，特定の発話に続きがあるか否かの 2 値ラベル (end-of-query ラベル) を付与しデータを作成する．end-of-query ラベルは，ユーザからの発話に続きがある場合に 0，発話に続きがなくオペレータに話者が交代している場合に 1 を付与した [*4]．

2016 年 9 月 25 日から 2017 年 9 月 24 日までの 1 年分のデータを収集した結果，計 27,700 対話のデータが得られた．それらのデータから学習，開発，評価データセットを作成するために対話数が 8:1:1 となるようにランダムにデータを分割しデータセットの作成を行った．データセットの内訳を 2，ラベル付けされた対話データの例を 5 に示す．

4. 予測モデル

本研究ではベースラインとしてロジスティック回帰 (L2LR) を用い，LSTM を用いた手法との比較を行う．それぞれの手法の概要を以下に示す．

- L2LR :
  単語 unigram(表層形) に対するベクトルを素性としロジスティック回帰を学習したもの
- LSTM :
  単語 unigram(表層形) に対して分散表現ベクトルを求め，LSTM の入力としたもの

なお，LSTM は対話におけるユーザが発した直前の発話情報は保持せず，各発話毎に end-of-query の予測を行うものとした．

5. 実験

5.1 実験設定

形態素解析器として MeCab[Kudo 05]，形態素解析用辞書として mecab-ipadic-neologd[Sato 15] を用いた．ロジスティック回帰の学習には LIBLINEAR[Fan 08] を使用した．提案手法における単語分散表現は日本語 Wikipedia のダンプデータから予め word2vec[Mikolov 13] を学習したものを使用した．提案手法のモデル学習には Adam[Kingma 14] を用いた．なお，モデルの学習の際，単語の分散表現は学習対象外とした．モデルの隠れ層の次元 $n = \{32, 64, 128\}$ でそれぞれ実験し，単語分散表現の次元を 300，イテレーション数 $i = 150$ を上限として実験を行った．

*3 https://www.ai-messenger.jp/

*4 適切なクエリのまとまりが取れない場合もあるが，アノテーションコストと比較した結果，自動構築できる方策を取った．

表 3: 実験結果

手法	Accuracy	F 値
L2LR	0.778	0.875
LSTM	**0.786**	**0.878**

表 4: L2LR において重みの多くかかった単語例

単語	重み
何	0.01797
言わ	0.01202
か	0.01017
また	0.007
ページ	0.00592
まし	0.0059
ログイン	0.00484
ん	0.0046
ませ	0.00449
しよ	0.00298

5.2 評価方法

手法の評価方法として，予測ラベルと正解ラベルの一致率である Accuracy と，Recall と Precision の調和平均である F 値を用いる．

5.3 パラメータチューニング

L2LR, LSTM ともに，開発データセットを用いて最も高い F 値を出すパラメータを検証した．その結果, L2LR では，正則化パラメータのコスト $c = 2^{-5}$，閾値 $\theta = 0.39$，LSTM では，隠れ層の次元 $n = 128$，イテレーション数 $i = 146$ となった．

5.4 実験結果と考察

それぞれの手法における評価データセットに対する実験結果を 3 に示す．

ベースラインである L2LR と提案手法である LSTM を比較すると，Accuracy，F 値のどちらにおいても LSTM が L2LR を上回る結果となった．対話例全文に対する各手法による予測結果を表 5，対話例中に出現する 115 単語において L2LR での重みの大きい上位 10 単語を表 4 に示す．L2LR では，“ます”の活用形である “まし”などに重みがかかっていることが分かるが，時系列を考慮できるモデルではないため，#2「以前に記事を投稿していましたが」の発話に対しても end-of-query の確率が高くなっていることが伺える．その一方で，LSTM では単語の系列を考慮することができるため，#2 の発話に対して end-of-query の確率を低く予測することができていることが分かる．

6. まとめと今後

本研究では，ユーザとオペレータの対話ログを用いて，テキストチャットにおけるユーザの発話がクエリとして完結してい

るか否かの予測に取り組んだ．実験の結果，ロジスティック回帰を用いたモデルより LSTM を用いた提案手法の精度が高くなり，発話に含まれる単語の系列をモデルに組み込むことでわずかながらも精度が向上することがわかった．

今後はこのモデルを改良し，ユーザ毎の発話特徴やユーザの一連の発話，オペレータの直前の発話内容の情報などを加味したモデルを実現したいと考えている．また，実システムへの導入を行った結果の UX の評価や，雑談対話のデータにおける実験も行いたいと考えている．

参考文献

[Fan 08] Fan, R.-E., Chang, K.-W., Hsieh, C.-J., Wang, X.-R., and Lin, C.-J.: LIBLINEAR: A Library for Large Linear Classification, *Journal of Machine Learning Research*, Vol. 9, pp. 1871–1874 (2008)

[Kingma 14] Kingma, D. P. and Ba, J.: Adam: A Method for Stochastic Optimization, *CoRR*, Vol. abs/1412.6980, (2014)

[Kudo 05] Kudo, T.: MeCab : Yet Another Part-of-Speech and Morphological Analyzer, *http://mecab.sourceforge.net/* (2005)

[Lala 17] Lala, D., Milhorat, P., Inoue, K., Ishida, M., Takanashi, K., and Kawahara, T.: Attentive listening system with backchanneling, response generation and flexible turn-taking, in *Proceedings of the 18th Annual SIGdial Meeting on Discourse and Dialogue*, pp. 127–136 (2017)

[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)

[Sato 15] Sato, T.: Neologism dictionary based on the language resources on the Web for Mecab (2015)

[Skantze 17] Skantze, G.: Towards a General, Continuous Model of Turn-taking in Spoken Dialogue using LSTM Recurrent Neural Networks, in *Proceedings of the 18th Annual SIGdial Meeting on Discourse and Dialogue*, pp. 220–230 (2017)

[Thompson 93] Thompson, H. S., Anderson, A., Bard, E. G., Doherty-Sneddon, G., Newlands, A., and Sotillo, C.: The HCRC Map Task Corpus: Natural Dialogue for Speech Recognition, in *Proceedings of the Workshop on Human Language Technology*, HLT '93, pp. 25–30, Stroudsburg, PA, USA (1993), Association for Computational Linguistics

表 5: オペレータとユーザの対話例

#	発話者	発話内容	end-of-query ラベル	LSTM	L2LR
1	オペレータ	ログインできないとのことですが、現在どのような状態でしょうか？ ID・登録メールアドレスのアカウント情報と、ログインできない詳細をお教えください。	-	-	-
2	ユーザ	以前に記事を投稿していましたが	0	0.320	0.516
3	ユーザ	久しぶりに投稿しようとしたらログインできませんでした。	1	0.571	0.673
4	オペレータ	アカウント情報をお教えいただけますか？ ID または、ブログ URL ・登録メールアドレス ※現在登録メールアドレスがご利用できない場合は、その旨もお教えください。	-	-	-
5	ユーザ	ID もパスワードも忘れてしまっていて	0	0.433	0.593
6	ユーザ	ID を忘れたときのページで自分のメールアドレスを入力しても	0	0.554	0.565
7	ユーザ	メールアドレスが違うと言われます。	1	0.676	0.641
8	オペレータ	ログインしたいアカウントを確認しますので、 ・ブログ URL ・ブログタイトルとニックネーム ・その他登録覚えのあるメールアドレス 上記をお教えいただけますか？	-	-	-
9	ユーザ	https:// ID / アカウント名	1	0.643	0.573
10	オペレータ	ご連絡ありがとうございます。 ご連絡のアカウントは、ドメイン（ メールドメイン名 ）で登録がございます。 登録メールアドレスにお心あたりはございませんか？	-	-	-
11	ユーザ	メールアドレス でしょうか？	1	0.697	0.814
12	オペレータ	一致いたしました。 登録メールアドレスの変更を行いますので、ご利用可能なメールアドレスをお教えいただけますか？	-	-	-
13	ユーザ	メールアドレス でお願いします。	1	0.905	0.925
14	オペレータ	お待たせしました。 登録メールアドレスの変更を行いましたので、パスワード再設定をお願いいたします。 パスワード再設定: 再設定 URL	-	-	-
15	ユーザ	ありがとうございます！ 書き込む事が出来ました！	0	0.645	0.888
16	ユーザ	また何かありましたら、宜しくお願いします。本当にありがとうございました。	1	0.896	0.957
17	オペレータ	無事解決のご連絡ありがとうございます！	-	-	-

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

ディベート型人工知能によるサポート性推定に基づく反論生成

Debating AI: Counterargument Generation Based on Textual Supportiveness Recognition

佐藤 美沙 Misa Sato　柳井 孝介 Kohsuke Yanai　柳瀬 利彦 Toshihiko Yanase　是枝 祐太 Yuta Koreeda　黒土 健三 Kenzo Kurotsuchi

日立製作所 研究開発グループ
Research & Development Group, Hitachi, Ltd.

We will demonstrate a counterargument generation system in debating, which aims to utilize newswire articles for decision-making support. Users can specify a claim such as “We should legalize casinos because they promote economy.” and then the system outputs counterargument scripts against the claim.

1. はじめに

筆者らの研究グループでは，電子化されたテキストデータを意思決定支援に活用することを目的として，ディベートをするシステムを開発している [Sato 15]. このシステムを本稿ではディベート型人工知能と呼ぶ. 本発表ではディベート型人工知能による反論生成のデモンストレーション展示を行う. 聴講者が主張をテキスト文で与えると，このシステムは，反論する主張およびその理由や根拠を提示する. たとえば「カジノは経済を活性化させる」という主張が与えられると，反論として「カジノは経済を活性化させない」という反対側の主張を提示し，続いてその理由や根拠となる事例を新聞記事等から抽出して提示する.

反論においては，単に議題に対する肯定・否定の立場が相手と反対であれば良いわけではなく，相手の主張と噛み合った議論を行う必要がある. 本研究では，入力される主張と同じ観点に基づいて反対側の立場から論じることにより，話の噛み合った反論を行う.

本研究では，入力された主張の依拠する価値を認識して，それを踏まえた反論側の主張を作成し，続けて反論側の主張を支持する根拠を提示するシステムを作成する. 指定の価値についての反論側根拠を集めることを可能とするために，データソースから抽出したテキストが，ある価値に依拠する主張に対する根拠であるか否かを推定するサポート性推定 [佐藤 16b]の問題を組み込む. よって本稿では特にサポート性推定に着目し，従来のタスクで有用であった特徴量の有用性を調べることによりサポート性推定の特徴を調べる.

2. 関連研究

議論解析は近年 Argument Mining 分野として自然言語処理の観点から多くの研究がなされている. 反論に関するものとしては，議論中に出現する 2 つの文の関係が支持（support）であるか反論（attack）であるかを推定する Relation-based Argument Mining というタスクが提案されている[Carsteins15,Cocarascu 17]. また，[Bosc 16]ではツイート間が支持関係にあるか反論関係にあるかを識別している. これらは議論内の構造を明らかにするものであり，与えられた主張に対して反論を提示するものではない. また，どの観点で反論しているかは取り扱っていない.

反論の生成に関する研究としては，Bilu らは，与えられた主張文を否定する主張文を生成する手法を提案している[Bilu 15].

連絡先：佐藤美沙，株式会社 日立製作所 中央研究所，
〒185-8601 東京都国分寺市東恋ヶ窪一丁目 280 番地，
042-323-1111，misa.sato.mw@hitachi.com

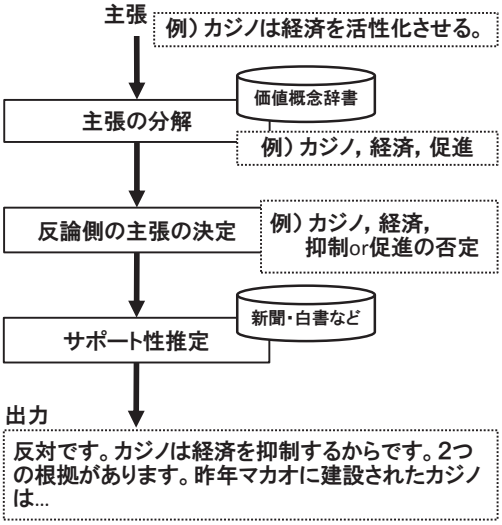


図 1. 反論生成システムの全体フロー

主張文に否定語“not”を加える，もしくは，感情語の極性を反転させるなどのルールベースの手法によって否定側の主張文を生成し，生成された否定側の主張文がディベートで使われた際にもっともらしいか否かを統計的な手法によって検証している. この研究では根拠の提示は行っていない.

本研究では，与えられた主張が問題としている議題および依拠する価値を推定し，議題から価値への影響が主張とは反対方向であることを示す根拠を探すことにより，反論を生成する. これにより，与えられた主張の観点を踏まえた反論を生成することができると考えられる.

3. ディベート型人工知能による反論生成

本研究では，[Sato 15]に説明しているディベート型人工知能の機能を一部組み替えて反論生成を行う. 入力される主張には，「カジノは経済を活性化させる」のような議論の対象と効果を示す文を想定している. 効果を論じる際に，価値というものを取り扱う. ここで言う価値とは，それ自体が人あるいは社会において良い存在（悪い存在）と捉えられるものであり，たとえば健康は良い価値，貧困は悪い価値，と考えることができる. つまり，ディベート型人工知能における肯定的な主張とは，議論の対象が良い価値を増やしていることへの指摘，あるいは，悪い価値を減らしていることの指摘であり，否定的な主張とは，議論の対象が悪い価値を増やしていることへの指摘あるいは良い価値を減らしていることの指摘である.

ディベート型人工知能における反論生成とは，与えられた主張に対して，それが肯定的な主張であれば否定的な主張およびその根拠を示し，否定的な主張であれば肯定的な主張およびその根拠を示すことである．図1に示す通り，全体フローは大きく以下の3ステップから成る．

1. 主張の分解
2. 反論側の主張の決定
3. 反論側の根拠の抽出

本章では各ステップの詳細を説明する．

3.1 主張の分解

主張の分解では，入力された主張文から議論の対象と価値を抜き出す．抜き出した後，議論の対象が価値に及ぼす影響の方向を推定する．影響の方向には，促進関係，抑制関係，促進関係の否定，抑制関係の否定，影響関係なし，の 5 通りを想定する．たとえば，「カジノは経済を活性化させる」という主張が入力された場合は，議論の対象が「カジノ」，価値が「経済」，影響の方向は「促進」となる．

議論の対象の抽出および価値の同定は，構文構造に対するルールベースの手法によって行う．優先度の付いた 5 つのルールを順番に適用し，合致した場合にそれを抽出する．最も優先度の高いルールは，影響関係に関する述語を同定し，その述語の主語を議論の対象，目的語を価値とするルールである [佐藤 16a]．影響関係に関する述語については約 350 語の辞書を用意している．

価値は，価値体系辞書によって分類を定義する [柳井 15]．価値体系辞書は 15 の大価値とそれにぶら下がる合計 69 の小価値からなる．それぞれの小価値には表現語が定義されている．表 1 に価値体系辞書の一部を示す．主張から価値を抜き出す際には，抽出した目的語がどの小価値にあたるかを表現語との単語列類似度により分類する．

次に影響の方向を推定する．ここでも構文構造に対するルールベースの手法を用いる．促進関係を 1，抑制関係を-1 とし，述語の極性と，述語に対する否定の係り受けの有無を掛け合わせることにより，方向を計算する．

表 2. データセットの内訳

分類	数
計	7955
影響関係なし	3784(48%)
影響関係あり	4171(52%)
促進関係	2861(68%)
抑制関係の否定	219(5%)
抑制関係	701(17%)
抑制関係の否定	390(9%)

3.2 反論側の主張の決定

反論側の主張においても，議論の対象が価値に影響を及ぼすという考え方を用いる．反論の依拠する価値を決定し，主張を決定する．入力された主張の価値を元に反論側の価値を決定するが，本研究では，元の主張の価値をそのまま反論側でも採用する．そして，影響の方向を反転させる．つまり，「カジノが経済を活性化させる」という主張に対しては，「カジノが経済を抑制する」という反論側の主張を行う．

3.3 反論側の根拠の抽出

前節で採用した反論側の主張を支持するような事例を新聞記事などのテキストから収集し，反論側の根拠として提示する．

サポート性推定では，入力されたテキストについて，議論の対象が価値に対して与える影響が，促進関係か，抑制関係か，あるいは影響関係が無いかを推定する． 根拠候補文のサポートする主張の影響関係の方向が反論側の主張と同一である場合，反論側の根拠であるとして抽出する．ここで反論側の根拠として抽出された文が最終的な反論文として表示されるため，サポート性推定の精度が高いほど，見逃しが少なく，誤りの少ない，良い反論生成システムになる．

最後に，信頼度の高い 2 文を選択し，反論側の根拠として提示する．

4. サポート性推定

4.1 手法

サポート性推定は，データソースから抽出したテキストが，主張を支持（否定）する根拠としてどの程度もっともらしいかを推定するタスクである [佐藤 16b]．サポート性推定の特徴を明らかにするため，関連タスクである根拠検知と賛否識別で使われている特徴量によってサポート性の推定がどの程度可能かを調べる．加えて，サポート性推定特有の特徴量の追加による推定精度への影響を調べる．

まず，根拠検知（Evidence Detection; ED）で有用な特徴量として，[Rinott 15]で使われている以下の 5 つを利用する．

・意味的類似度： 主張文と根拠候補文の間の類似度．Word2Vec のコサイン類似度[Mikolov 13]により計算する．

・センチメントの一致度： 根拠候補文のセンチメント値を[0,1]に正規化した値．センチメント値の導出には Stanford Core NLP [Manning 14] を用いた．

・語彙： 根拠文によく出現する語を集めた辞書を用意し，その辞書内の語がそれぞれ出現しているか否かを表す 1 か 0 の値．辞書は手作業で集めた 287 語からなる．専門家や公的機関の発言は説得力の元となるため，これらを表す語は根拠文に出現しやすいという考えの下に作成されている．

・固有表現クラス： 根拠候補文がそれぞれの固有表現クラスにあたる固有表現を含むか否かを表す 1 か 0 の値．固有表現およびクラスは Stanford Core NLP により抽出した．

表 1. 価値体系辞書の一部

大価値	小価値	極性	表現語
economy	economy	+1	economy, investment, development, …
〃	employment	+1	employment, job, …
〃	loan	-1	loan, debt, …
health	health	+1	health, healthy, …
〃	disease	-1	disease, complication, …
safety	crime	-1	crime, prostitution, …

・文パターン: 文が引用を含むか，人あるいは組織に寄る発言を含むか，人あるいは組織による行動を含むか，人あるいは組織の意見を含むか，を表すパターンを作成し，根拠候補文がそれぞれに当てはまるか否かを表す 1 か 0 の値.

次に，賛否識別（Stance Classification; SC）で有用性が知られている [Mandya 16]，以下の 1 つの特徴量を根拠候補文に対して適用する.

・依存関係: 根拠候補文において依存関係にある 2 語のペアを表す one-hot ベクトル.

最後に，サポート性推定（Supportiveness Recognition; SR）特有の特徴量として以下の 2 つを用いる. 議論対象と価値の関係に着目する問題であるため，候補文内のどの語句が議論対象および価値と対応するかを考慮した特徴量としている.

・機能語: 根拠候補文中の議論対象を表す語と価値を表す語の間に出現する動詞，名詞，副詞あるいは形容詞に対する one-hot ベクトル.

・否定語: 根拠候補文中の議論対象を表す語と価値を表す語の間に否定語が含まれるか否かを表す 1 か 0 の値. 否定語の辞書は，一般的な”not”などの否定語に加え，”ban”，“barrier”，“drop”，”hazard”などの極性を反転させるような語を含む 154 語からなる.

4.2 実験設定

データセットは，Annotated English Gigaword [Napoles 12] から候補となる文を取得し，人手でラベリングすることにより作成した. 候補文の取得は，31 通りの主張（議論の対象と価値のペア）について，議論の対象と価値の表現語の共起する文を抽出することにより行った. 表 2 にデータセットの統計値を示す.

反論側の根拠の候補には，(a)反論側主張と影響関係の方向が合致するもの，(b)影響関係の方向が反対であるもの，(c)影響関係がないもの，の 3 通りが存在する. 表 2 のラベルとの対応を考えると，反論側主張の影響関係の方向が促進関係であるとすると，(a)は促進関係あるいは抑制関係の否定，(b)は抑制関係あるいは促進関係の否定，(c)は影響関係なしが対応する. そこで，影響関係の有無を識別する（(a)と(b)あるいは(c)を識別する）2 値問題と，促進関係と抑制関係を識別する（(a)と(b)を識別する）2 値問題のそれぞれについて実験を行った.

前節で示した特徴量を用い，線形 SVM 識別器によって識別を行った. 3-fold の交差検定により精度を測定している. ただし，同じ主張に基づく根拠文が訓練データとテストデータの両方に含まれることはないように分割している. パラメータは，$C = \{10^{-2}, 10^{-1}, 10^{0}, 10^{1}, 10^{2}\}$とした. また，ベースラインの特徴量として Bag-of-Words（BoW）を用いた.

4.3 実験結果

表 3 に影響関係の有無の識別結果を示す. BoW，根拠同定および根拠分類の特徴量を用いた[BoW+ED+SR]が最も F 値が高く 57%となった. しかしながらいずれの特徴量の組み合わせも，BoW ベースライン特徴量の結果からさほどの向上は見られなかった. 類似のタスクの特徴量ならびに本稿で提案した特徴量は有用とはいえない.

表 4 に促進関係と抑制関係の識別結果を示す. [BoW]の結果に比べて[SC]は F 値が 5%高く，賛否分類の特徴量が有用であったことがみてとれる. 加えて，BoW 特徴量はうまく働かなかった. 賛否分類タスクにおいても BoW 特徴量はあまり機能しない [Mandya 16] ことから，この点も賛否分類との共通点といえる. しかしながら，賛否分類の特徴量にサポート性推定特有の特徴量を加えた[SC+SR]が最も良い精度となった. 議論の対象と価値に着目した特徴量によって精度の向上が見られた.

表 3. 影響関係の有無の識別実験結果

特徴量	適合率	再現率	F 値
[ED]	55%	55%	54%
[SC]	57%	56%	56%
[SC+SR]	56%	56%	56%
[BoW]	57%	56%	56%
[BoW+ED]	56%	55%	55%
[BoW+ED+SR]	**58%**	**57%**	**57%**

表 4. 促進関係と抑制関係の識別実験結果

特徴量	適合率	再現率	F 値
[ED]	58%	55%	56%
[SC]	62%	69%	64%
[SC+SR]	**68%**	**71%**	**69%**
[BoW]	61%	57%	59%
[BoW+ED]	62%	59%	60%
[BoW+ED+SR]	64%	63%	63%

5. おわりに

本稿では，反論生成システムの全体フローについて述べ，サポート性推定について実験を行った. サポート性推定というタスクを中心に据えることで，主張の依拠する価値を踏まえた反論を生成するシステムを開発した. 一方でサポート性推定については精度が未だ十分ではなく，特に影響関係の有無の識別については今回の実験では有効な特徴量を見つけることができなかった. エラー分析などにより問題の分析を進めていく.

今後は，精度向上と共に，立論システムと反論システムを統合して競技ディベートに出場可能なシステムとするため，立論から反駁まで一貫性のある議論を展開できるような手法の開発を進めていく.

参考文献

[Bilu 15] Yonatan Bilu, Daniel Hershcovich, and Noam Slonim: Automatic claim negation: why, how and when, *Proceedings of the 2nd Workshop on Argumentation Mining*, pp.84-93, Association for Computational Linguistics, 2015.

[Bosc 15] Tom Bosc, Elena Cabrio, and Serena Villata: Tweeties Squabbling: Positive and Negative Results in Applying Argument Mining on Social Media, *Computational Models of Argument (COMMA)*, pp.21-32, IOS Press, 2016.

[Carsteins 15] Lucas Carstens and Francesca Toni: Towards relation based argumentation mining, *Proceedings of the 2nd Workshop on Argumentation Mining*, pp.29-34, Association for Computational Linguistics, 2015.

[Cocarascu 17] Oana Cocarascu and Francesca Toni: Identifying attack and support argumentative relations using deep learning, *Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing*, pp.1374-1379, Association for Computational Linguistics, 2017.

[Mandya 16] Angrosh Mandya, Advaith Siddharthan, and Adam Wyner: Scrutable Feature Sets for Stance Classification, *Proceedings of the 3rd Workshop on Argumentation Mining*, pp.60-69, Association for Computational Linguistics, 2016.

[Manning 14] Christopher D. Manning, Mihai Surdeanu, John Bauer, Jenny Finkel, Steven J. Bethard and David McClosky: The Stanford CoreNLP natural language processing toolkit, *Proceedings of the ACL 2014: System Demonstrations*, pp.55-60, Association for Computational Linguistics, 2014.

[Mikolov 13] Tomas Mikolov, Ilya Sutskever, Kai Chen, Greg S Corrado and Jeff Dean: Representations of Words and Phrases and their Compositionality, *Proceedings of the Third Workshop on Argument Mining*, pp.3111-3119, Curran Associates, Inc., 2013.

[Napoles 12] Napoles, Courtney, Matthew Gormley, and Benjamin Van Durme : Annotated English Gigaword LDC2012T21, *Philadelphia: Linguistic Data Consortium*, 2012.

[Rinott 15] Ruty Rinott, Lena Dankin, Carlos Alzate Perez, M. Mitesh Khapra, Ehud Aharoni and Noam Slonim: Show me your evidence - an automatic method for context dependent evidence detection, *Proceedings of the EMNLP 2015*, pp.440-450, Association for Computational Linguistics, 2015.

[Sato 15] Misa Sato, Kohsuke Yanai, Toshinori Miyoshi, Toshihiko Yanase, Makoto Iwayama, Qinghua Sun and Yoshiki Niwa: End-to-end Argument Generation System in Debating, *Proceedings of the ACL-IJCNLP 2015 System Demonstrations*, pp.109-114, Association for Computational Linguistics, 2015.

[佐藤 16a] 佐藤 美沙, 柳井 孝介, 柳瀬 利彦, 是枝 祐太, 丹羽 芳樹: ディベート人工知能における影響関係認識のためのテキスト内の論理構造に関する考察, 人工知能学会全国大会論文集, 第 30 巻, 4B1-3, pp.1-3, 人工知能学会, 2016.

[佐藤 16b] 佐藤 美沙, 柳井 孝介, 柳瀬 利彦, 三好 利昇, 是枝 祐太, 丹羽 芳樹: 意見文章自動生成のための組合せ構文特徴を用いたサポート性推定, 人工知能学会論文誌, 第 31 巻, no. 6, pp. AI30-L_1-12, 人工知能学会, 2016.

[柳井 15] 柳井 孝介, 三好 利昇, 柳瀬 利彦, 佐藤 美沙, 丹羽 芳樹, Reisert, P., 乾 健太郎:ディベート人工知能における意見生成,人工知能学会全国大会論文集, 第 29 巻, 3M3-2in, pp. 1-3, 人工知能学会, 2015.

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

食知識に基づく連想型レシピ提案対話システム

Associative Dialog System for Recipe Recommendation Using Food Knowledge

山上 勝義 *1*2 Katsuyoshi Yamagami
遠藤 充 *2 Mitsuru Endoh
清丸 寛一 *3 Hirokazu Kiyomaru
黒橋 禎夫 *3 Sadao Kurohashi

*1産業技術総合研究所 Advanced Industrial Science and Technology
*2パナソニック株式会社 Panasonic Corporation
*3京都大学 Kyoto University

One of the problems when using the dialog system is that users do not know what utterances the system can understand to convey their preferences. To mitigate the problem, we developed an associative dialog system for recipe recommendation which utilizes food knowledge base. In addition to providing expressions candidates that system can accept, it also repetitively generates and respond with linguistic expressions related to foods associated with user input.

1. はじめに

我々は対話技術の実用化を目指してタスク志向の対話技術の開発をすすめている．レシピ提案をタスクとしたチャット型の対話実証実験システム CookChat[1][2] を構築，運用している．CookChat の運用を通じて得られた対話ログやアンケートなどの分析から技術課題を探り出しつつ改良を行っている．

フィードバックから得られた主な課題として，「あっさり」「パーティ向き」などの料理に関する印象や状況に関する要望を表したユーザ発話を十分に理解できない点がある．これについては，基本料理の知識ベースを構築し，料理にまつわる語彙知識を充実させ，ユーザ発話における語彙理解のカバー率を改善しつつある [3]．

一方で，翠らの研究 [4] で指摘されているように情報検索型タスクの対話システムにおいては，

- 対話システムがどのような観点でコンテンツを検索し絞り込むことができるのかをユーザが知りえないこと
- ユーザ自身も自分の嗜好を表す観点に気づいているとは限らないこと

といった課題がある．

本研究では，この課題に対して，基本料理に関する知識 [3] を用いて，料理から連想される言語表現（連想表現）を提示することで，対話システムが持つコンテンツ検索の観点をユーザに理解させるとともに，ユーザ自身が意識していなかった観点についての嗜好情報を取得する対話システムを試作した．



図 1: 連想型レシピ提案対話システムの対話動作の例

2. 連想型レシピ提案対話システム

2.1 連想型レシピ提案対話システムの概要

試作した対話システムの概要について述べる．図 1 に連想型レシピ提案対話システムでの対話動作の例を示す．ユーザと対話システムとの対話は以下の流れで進んで行く．

STEP1 ユーザが料理に関して思い浮かんだ表現をテキストで入力する (例:「おふくろの味」)

STEP2 対話システムは，入力された表現と関連が深い料理名を応答文で提示し，どのような料理を連想したかをユーザに示す

STEP3 対話システムは，料理に関係する表現（連想表現）を複数提示し，ユーザに料理の嗜好の観点を伝える

STEP4 所定の対話ターン数に達するまで，**STEP1** に戻り提示された連想表現から選択するか，あるいは，ユーザが思いついた次の表現を入力する

STEP5 **STEP4** で所定の対話ターン数に達すると，それまでにユーザが入力した表現からレシピに関する嗜好を推

連絡先: 山上 勝義，産業技術総合研究所，東京都江東区有明 2-4-7 臨海副都心センター yamagami.katsuyoshi@aist.go.jp

定し，その嗜好に近い順にランキングしてレシピをリストで提示する

STEP6 ユーザはレシピのリストから気に入ったレシピを選択する，あるいは，対話を継続するかを選択する．対話継続の場合は **STEP1** に戻る．

上記の対話動作の **STEP1** ～ **STEP4** までが連想型対話のフェーズである．このフェーズでユーザが入力した (あるいはボタン選択した) 連想表現からユーザのレシピの嗜好を理解して，**STEP5** ～ **STEP6** のレシピ提案フェーズで理解した嗜好に基いてレシピをリスト形式で提案する．このように，最初にユーザが入力した表現をきっかけとして，対話システムが連想的に料理に関する表現を提示し，ユーザの料理に関する興味・嗜好を探り出す形で対話が進行する．

以前の CookChat では，

1. ユーザが入力したテキストに含まれる料理に関するキーワードとレシピに付与されたキーワードを照合することでユーザへ提案するレシピの候補を絞り込む
2. さらに，決定木アルゴリズムで，最も絞り込みが進むキーワードを選択し，そのキーワードについてユーザの嗜好を質問して，絞り込みを進める

という流れで，ユーザの嗜好に合ったレシピを提案していた．CookChat が 1 で理解する，あるいは，2 で質問するキーワードのバラエティが少ないため，どんな表現が理解されるか分からないという課題に加え，繰り返し使っていると提案されるレシピが固定化するという課題もあった [*1]．

本連想型レシピ提案対話では，この課題についても考慮し，以前の CookChat よりも料理に関する観点の幅を広げ，ユーザの嗜好のバラエティを捉えやすくすることを狙った．

2.2 基本料理知識ベース

ユーザが入力した連想表現を理解し，対話システムが新たな連想表現を提示するために基本料理知識ベース [3] を利用した．

```
【ぶり大根】
[同義語]ブリ大根 鰤大根
[材料]<大根>生姜.7 ブリ.2 水.2 米飯.1 みりん.9 酒.9 醤油.9 砂糖.7 だし.4 食塩.3
[調理法]<煮る>
[属性]酒のアテ(105/付け合せ).5 家族の人気メニュー(201/対象).5
大人が好き(201/対象).5 家庭的(221/場所) あたたまる(231/効果・機能).5
あまじょっぱい(251/味).5 美味しい(251/味).5 トロトロ大根(252/食感).5
プリプリ(252/食感).5 生臭い(254/香り).5 よく染みてる(261/印象).5
美味しく作るのにはコツがいる(261/印象).5 部屋が臭くなる(261/印象).5
プロの技(301/作り手).5 煮崩れ(311/調理法・工程).5
美味しいけど難しい(322/難易度).5 面倒くさい(322/難易度).5
```

図 2: 基本料理知識ベースの記述内容の例

図 2 に基本料理知識ベースの知識記述例を示す．1 行目は料理名で，2 行目以降がこの料理名 (ぶり大根) に関する知識の記述部分である．[ ] で囲まれた部分は，料理名に関する知識の種類名である．[同義語] は料理名の同義表現の知識，[材料] は料理に用いられる材料の知識，[調理法] は料理の調理方法の知識，[属性] は料理の同義語・材料・調理法以外の知識である．知識の右側の小数点付きの数字は，料理がその知識をもつ信頼度を表している．< > で囲んだ部分はその料理特有の知識 (代表知識) であることを表す．代表知識の信頼度は 1.0 が付与されているものとして扱う．さらに [属性] の知識には下位の種類があり ( ) で囲んだ部分が下位の種類名 [*2] である．

連想型レシピ提案対話では，同義語，材料，調理法，属性のすべての知識をユーザが発話したレシピの嗜好を表す表現とのマッチング対象として扱う．また，この属性の知識をユーザに提示する連想表現の候補として用いる．属性の知識にはクラウドソーシングによって収集した料理に関する様々な観点の印象表現が含まれるので，ユーザが発話するレシピに関する嗜好表現を幅広く捉え，かつ，ユーザに多様な観点の連想を促すことが期待できる．

2.3 連想型レシピ提案対話システムの構成と動作

図 3 に連想型レシピ提案対話システムの構成と動作のフローを示す．

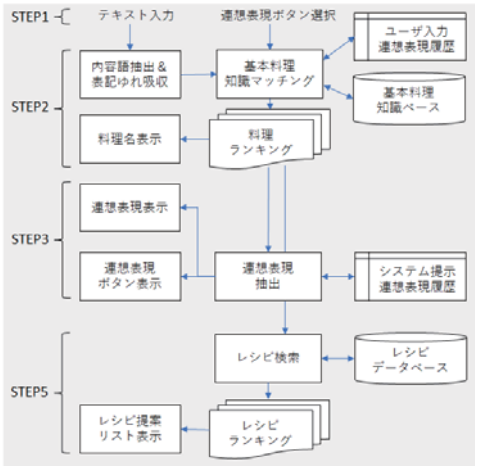


図 3: 連想型レシピ提案対話システムの構成と動作のフロー

内容語抽出・表記ゆれ吸収

ユーザのテキスト入力を形態素解析し，機能語以外の単語連鎖を内容語として抽出し，基本料理知識ベースの類義語関係を参照して表記ゆれを吸収した連想表現に変換する．

基本料理マッチング

基本料理知識ベースの料理の中から，料理がもつ知識と連想表現がマッチング (完全一致または部分一致) した料理を抽出し，マッチした知識に付与された信頼度を抽出した料理のスコア [*3] として料理のランキングを生成する．

料理名表示

料理ランキング上位の 2 つの料理名をシステムが連想した料理として応答文生成して表示する．

連想表現抽出

料理ランキングの料理上位 3 つの料理のそれぞれについて，最も信頼度が高い知識を抽出する．このときシステムが提示した連想表現の履歴を参照して既に提示したものは抽出対象からはずす．

*1 レシピの候補数が 500 未満で少ないことにも起因している

*2 '/' の右側が下位の種類名であり，'/' の左側の番号は下位の種類の体系化のために付与された番号である

*3 ユーザが入力した連想表現の履歴にある連想表現に関してもマッチングし，それぞれのマッチングでのスコアを合計する



図 4: 連想型レシピ提案対話システムでの対話例

連想表現表示
抽出した知識 (3 つ) をユーザに提示する連想表現として応答文生成して表示する．

連想表現ボタン表示
抽出した知識 (3 つ) をユーザが選択可能なボタンとして表示する．

レシピ検索
料理ランキングの各料理の料理名とレシピデータベース内のレシピ名をマッチングさせ，完全一致または部分一致したレシピを抽出する．料理名がマッチした料理のスコアをレシピのスコアとして，レシピのランキングを生成する．前記のマッチングが失敗した場合は，別途料理の上位下位関係を記述したオントロジーを用いてオントロジーの葉ノードの料理名とマッチングさせ，マッチングした料理名の上位概念の料理カテゴリー表現を用いてレシピを検索する．

レシピ提案リスト表示
レシピのランキングの上位 5 つを提案するレシピとして表示する．

上記の処理フローに従って動作する連想型レシピ提案対話システムの対話例を図 4 に示す．この対話例では，「節約」，「もやし」，「大根」はユーザがテキスト入力で行った発話，「いろんな味付けができる」はユーザがシステムが表示した連想表現のボタンを選択した発話である *4．

「節約」というユーザの発話に対して「もやしのナムル」「豆腐ハンバーグ」という基本料理が「節約」を知識としてもつ料理として検索され提示される (**基本料理マッチング**, **料理名表示**)．それら料理がもつ信頼度の高い知識を連想表現として「焼肉」「さっぱり」「家で食べる味じゃない」が抽出し表示する (**連想表現抽出**, **連想表現表示**)．この対話ターンを 4 回繰り返した後，ユーザが入力した連想表現の履歴からランキングした基本料理の料理名とレシピ名をマッチングさせてレシピのランキングを生成し表示する (**レシピ検索**, **レシピ提案リスト表示**)．なお，この対話例では，レシピ検索の際に基本料理名とレシピ名のマッチングに失敗したため，オントロジーで上位概念化してレシピ検索した結果を表示している．

3. 評価実験

従来の CookChat (以降，絞り込み型と記載) と試作した連想型レシピ提案対話 (以降，連想型と記載) のユーザ体験を比較するため，操作した上での主観評価を行った．

クラウドソーシングで募集した 20〜55 歳の男女 100 名を，絞り込み型を操作する評価者 50 人 (評価者群 A)，連想型を操作する評価者 50 人 (評価者群 B) とした．評価者は，絞り込み型，連想型をそれぞれ 3 回づつ操作し，各操作では異なる料理をイメージしてレシピの嗜好に関する発話を入力する．さらに，操作の後に対話システムの使用感に関するアンケートに回答する．

表 1 にアンケートの項目を示す．項目のカテゴリは 7 種類あるが，各カテゴリに対して対話システムの機能性を問う観点 (機能性評価項目) と対話システムの自然性を問う項目 (自然性評価項目) に分けて質問した．評価者は各項目に関して，

- 全くそう思わない → 1
- あまりそう思わない → 2
- どちらとも言えない → 3
- そう思う → 4
- かなりそう思う → 5

*4　ボタン表示はユーザが選択した後，選択したボタン表示の吹き出しに変わる．

表 1: 評価者へのアンケート項目

	機能性評価項目	自然性評価項目
エージェントの発話の質	Q1 分かりやすい応答ができていると思いましたか?	Q2 人間らしい応答ができていると思いましたか?
対話の円滑さ	Q3 やりとりが円滑に行えたと思いましたか?	Q4 思い通り話せましたか?
話しやすさ	Q5 何を発話すればよいか，すぐに分かりましたか?	Q6 どう会話を始めたらよいか躊躇しましたか?
エージェントへの親近感	Q7 エージェントを違和感無く利用できると思いましたか?	Q8 エージェントと親しみを持って会話できると思いましたか?
対話の満足度	Q9 エージェントの提供する情報にあなたは満足しましたか?	Q10 エージェントとの会話にあなたは満足しましたか?
継続利用	Q11 またシステムを利用してみたいですか?	Q12 またエージェントとお話してみたいですか?
理解性能	Q13 異なる表現の入力も正しく理解されると感じましたか?	Q14 いろんな言い回しをちゃんと理解できると感じましたか?

の 5 段階で回答する．

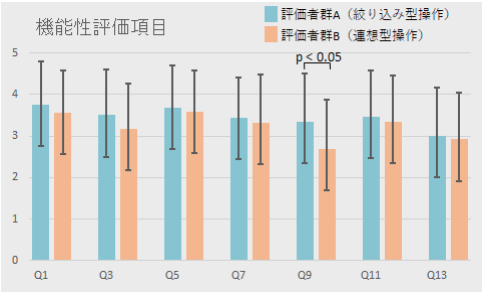


図 5: 機能性評価項目の比較

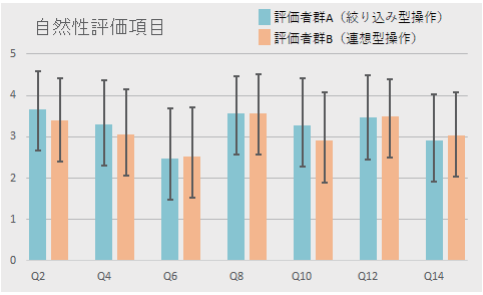


図 6: 自然性評価項目の比較

図 5 と図 6 に，絞り込み型を操作した評価者群 A の回答結果と連想型を操作した評価者群 B の回答結果 (1 ～ 5 のスコアの平均と標準偏差) の比較を示す．各質問項目に関して，左側のバーが評価者群 A の回答結果，右側のバーが評価者群 B の回答結果である．図 5 は機能性評価項目に関する比較，図 6 が自然性評価項目に関する比較である．

評価者群 A と評価者群 B の各質問項目に関する回答結果 (1~5) を t-検定したところ，Q9 のみ 5%水準有意で，評価者群 A より評価者群 B の方が回答結果のスコアが低くなった (平均値で 3.34 と 2.68)．他は有意差は無かった．

表 1 に示す質問項目以外のアンケートの設問として，対話システムを使用した感想を問う自由回答記述も設定した．表 2 に連想型の評価者の自由回答の一部を示す．Q9 の質問項目のスコアが低い評価者の自由回答には「イメージしていたレシピとはずれたレシピが提案された」という内容の回答が多かった．

ポジティブな回答からは，それほど具体的なレシピのイメージを持っていなかったユーザに対しては，ユーザ自身が自覚していなかった嗜好について探り出すという我々が狙った連想型の対話の効果があったことが分かる．一方で，ネガティブな回答からは，具体的なレシピのイメージを持っていたユーザは，自身の発話で明確にレシピが絞り込まれることを期待しており，

表 2: 連想型の評価者の自由回答 (一部)

ポジティブな回答
・とくに食べたいものが決まらないときに連想していって，決めるのもいいなと思った．
・頭にある雰囲気をさっちしてレシピを選んでくれるのが楽しい．
・何を作るか困った時に役に立ちそうなのでこのサービスを使いたいと思った．
・曖昧な言葉でも反応してくれるし，ちゃんと好みを具現化してくれるので使いやすいと思いました．
・お餅グラタンなど，まったく予想していなかったレシピが表示されて楽しい．
ネガティブな回答
・どうしてもこちらの意図とは異なる単語をピックアップされるようだ．
・最初に入力した言葉に対するシステムの返事が，想像力を間違った方向に使い選択の幅を違う方向に広げて行っているように感じた．
・連想を繰り返しているうちに，最初のワードとは全く関係のないレシピに落ち着いてしまう．
・自分の予想とはかけ離れた方向の提案が出てきてしまうので，戸惑いました．
・会話があまり成り立っていなかったと思った．一番最初に入力した材料や料理のジャンルの中から見つけてほしかった．

連想型の対話で我々が狙った効果を感じなかったと思われる．ユーザが料理の嗜好として発話する表現を，どの程度強い絞り込み条件として扱うかの制御が必要であることが分かった．

4. まとめと今後の課題

食知識に基づく連想型レシピ提案対話システムを試作しユーザの主観評価を行った．主観評価の結果は，従来の絞り込み型のレシピ提案対話に対して連想型のレシピ提案対話が好評価とはならなかったが，評価者の一部は，我々が狙った効果を感じたことが確認できた．今後，ユーザが料理の嗜好を発話する際の「絞り込み度合い」の意図を推測し，嗜好の重みの強さに反映させるなどのアプローチを検討する予定である．

参考文献

[1] 山上 勝義, 遠藤 充, 牛尾 貴志, 堀井 則彰.: “対話サービスプラットフォームの開発”, 人工知能学会全国大会 (第 31 回) 論文集, (2017)

[2] 遠藤 充, 牛尾 貴志, 山上 勝義, 堀井 則彰.: “発話とコマンドの系列を制御する対話エージェント”, 人工知能学会全国大会 (第 31 回) 論文集, (2017)

[3] 清丸 寛一, 黒橋 禎夫, 遠藤 充, 山上 勝義.: “料理レシピとクラウドソーシングに基づく基本料理知識ベースの構築”, 言語処理学会第 24 回年次大会 (NLP2018), (2018)

[4] 翠 輝久, 大竹 清敬, 堀 智織, 柏岡 秀紀.: “意思決定を支援する音声対話システム”, 言語処理学会第 18 回年次大会 (NLP2012), pp. 658-661(2012)

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

対話行為における説得による作業意欲の分析

Analysis of work motivation by persuasion in dialogue

水上　卓哉 *1
Takuya Mizukami

*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

In this research, I conducted "a persuasive game" where a worker convinces the character about the importance of the work and analyzed the increase in motivation levels of the worker. When the worker fails to persuade, the worker confirms the importance of the work, so the motivation for work will be improved. In this experiment, I prepared two types of systems : one with a character that accept any persuation(conventional system) and one that may or may not accept a persuation , incorporating the success or failure of a persuation based on its cntent (proposed system), compare and evaluate each went. As a result, it was shown that the system that incorporates the success or failure of persuasion tends to significantly improve the motivation before work, compared with the conventional system.

1. 研究背景と目的

作業意欲が起こらない単純かつ退屈な作業は未だに存在している．そのため，そのような作業への意欲向上を目的とした研究が行われている．そのうちの 1 つに作業前に作業者がキャラクタに作業の重要性を説得させることで，作業意欲が向上することを示した研究がある [1]．この研究では，説得行為を行うことに重点を置いており，作業者の説得内容に関しては考慮していない．そのため，作業の重要性を理解していない作業者は意欲が向上しない問題がある．そこで本研究では，作業者がキャラクタ説得した際，説得の成否を取り入れることを提案し，作業前の作業意欲が向上に効果があるかを分析する．

2. 関連研究

Festinger ら [2] は自分の作業を本音と関わらず，あえて他人に「この作業は面白いものだ」と説明し納得させる被験者実験を行った．その結果，被験者が抱いていた作業に対するネガティブな印象がポジティブな印象に変容したことを明らかにした．この研究を参考に藤野ら [1] は，他人ではなくキャラクターエージェントに対して，作業の重要性を説得し，納得させるゲームシステムを考案した．その結果，説得対象がキャラクターエージェントであっても作業者の作業意欲が向上することを示した．しかし，十分に作業の重要性を理解しない人の場合は，キャラクタが常に説得される設定のため，効果的でないこともわかった．そこで本研究では，キャラクタが説得を受け入れないという設定を取り入れたシステムを提案する．

3. 提案

本研究では，藤野らのシステム [1] に対して， 説得の成否を取り入れたものを提案する．従来の研究では，どのような内容の説得に対しても，キャラクタは常に納得する設定している一方で，本研究では，あらかじめ決められた答えの文章に近い内容でなければ，キャラクタは説得を受け入れない設定をする．仮説としては，キャラクタにへの説得に失敗した作業者は，説得成功のために作業の目的や重要性をより深く考察するため，作業意欲が向上すると考えられる．

3.1 システム概要

本提案である説得成否の方法について述べる．作業者は作業の重要性を文章として入力する．入力された文章は Language Understanding Intelligent Service(以下 LUIS)[3] と呼ばれる自然言語処理エンジンによって Correct，Nearly，None のいずれかに分類される．この分類結果に応じて，キャラクタの作業者に対する応答文章を生成する．文章生成には C#を用い，そこでは，分類結果を受け取り，その結果ごとに決められている文章の返答を行う．説得システムの構成を図 1 に示す．

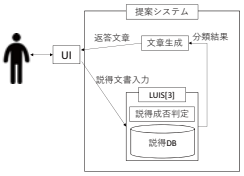


図 1: システムの構成

分類結果ごとの文章生成の中身を以下に示す．

```
CASE 分類結果 OF
 Correct：Display
  "納得しました。ありがとうございます"
  "この調査は隔年に行われている、文部科学省の調査でとても重要だそうです。"
  "作業がんばってください！"
 Nearly：Display
  "惜しいです。"
  "ヒント：なにかの資料を得ることを一番の目的としています"
 None or null:Display
  "こんにちは、私は説得キャラクターのボットです"
  "私を説得できたら勝ち、出来なかったら負けのゲームです"
  "あなたの作業はどのような目的がありますか？"
ENDCASE
```

連絡先: 水上卓哉，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，〒 169-8555 東京都新宿区大久保 3-4-1　51 号館 15 階 02 号室，090-7847-6874，mizumizu-35@fuji.waseda.jp

4. 実験概要

実験は従来手法 [1] および提案手法に各 4 名，計 8 名で行う．今回被験者に課した作業は，紙に印刷された数値データを，表計算ソフトに入力する作業である．実験手順は以下に示す．

1. 実験説明
   被験者に作業の内容，および実験シナリオの説明を行った．実験シナリオは 2 種類用意した．ただし，実験シナリオ，そこで用いられている数値データは本研究のために架空に作成されたものである．

2. 作業 1
   作業 1 では作業とアンケートを行う．アンケートは作業前（1-1），作業中（1-2），作業後（1-3）の 3 回実施し，それぞれ作業アンケートと感情評価の 2 種類取得する．作業アンケートは，藤野らの研究のものを用いた [1]．その内容の一部を表 1 に示す．このアンケートでは計 11 項目を被験者は各項目 7 段階尺度で回答を行う．そして，合計得点をその被験者の作業意欲とする．感情評価では寺島ら [4] の多面的感情状態尺度短縮版（MMS）を用いて，ポジティブ，ネガティブ感情を 1〜4 段階で計測を行う．

3. 説得ゲーム
   被験者は作業 2 の重要性や目的をキャラクタに説明する．従来手法ではどのような内容の説得でも成功とし，提案手法では説得に対して成否の判定を行い，説得が成功するまで，説得を行う．

4. 作業 2
   被験者は作業 1 と同様に 2 回目の作業を行い，作業 1 の時と同様に，作業前（2-1），作業中（2-2），作業後（2-3）にアンケートを実施する．

5. 事後アンケート
   最後に実験に関して感想を自由記述で取得した．

表 1: 作業アンケートの例 [1]

Q1	この仕事に従事して、あなたは社会のための重要な人物だと思いますか？
Q4	この仕事は楽しいですか？
Q9	あなたはこの仕事に興味がありますか？
Q11	この仕事に従事して、あなたはイライラしますか？☆

(☆：Reverce Question)

5. 結果と考察

提案手法において，どの被験者も 1 回目の説得では失敗をしている．つまり，提案手法での被験者は従来手法の被験者よりも説得の回数が多い．そこで，説得ゲームによる作業意欲への影響を分析するため，各被験者の 1-1 での値を基準値とし，作業 2 での作業意欲との比較を行う．その結果を図 2 に示す．この結果から，作業 2 の作業前の意欲に関して，従来手法では基準値と比較して約 10 %に減少しているのに対し，提案手法では基準値と比較して，約 6 %上昇している．つまり，提案手法は従来手法と比較して，作業前の意欲が向上していると考えられる．そこで，基準値に対する 2-1 での値に関して，従来手法，提案手法において，各被験者の値を F 検定，片側 t 検定を行い，その結果を表 2 に示す．$p < 0.10$ となり作業前の

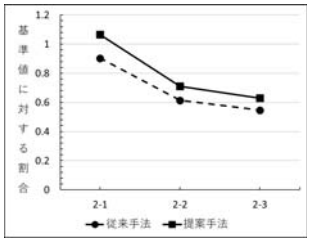


図 2: 2 回目の作業意欲の変化 (従来 n=4，提案 n=4)

表 2: 作業意欲の分析

実験手法	平均	分散	f	t
提案手法 (n=4)	1.064	0.014	1.213	-1.821
従来手法 (n=4)	0.903	0.017		

作業意欲に関して，従来手法と提案手法との差には有意傾向がある．つまり，説得に失敗した被験者はそうでない被験者と比較して作業意欲が向上しやすい傾向がある．

次に MMS[4] の結果から作業中の感情変化を分析した．その結果，作業中の集中の感情において違いが見られた．そこで，1-2 での値と 2-2 での値との比較を行う．得られた値を F 検定および両側 t 検定を行い，その結果表 3 に示す．

表 3: 作業中での集中感情の分析

実験手法	平均	分散	f	t
提案手法 (n=4)	0.945	0.013	1.926	-2.834*
従来手法 (n=4)	0.673	0.243		

5 %水準で集中感情に関して，従来手法と提案手法に有意な差がある．つまり，従来手法では約 33 %と減少しているのに対し，提案手法ではほぼ変化がないという違いであり，これは説得回数の差が作業中の集中感情に影響を与えたといえる．

事後アンケートでは，提案手法において説得失敗によって作業の重要性を確認するという意見が得られた．一方で，「説得をしているというよりもゲームの正解を考えているように感じた」という意見も得られた．つまり，作業者にとって説得文章を考えることが，ただゲームの答えを考えるためのものに変わる可能性が確認された．

6. まとめと今後の課題

本研究では，従来の説得ゲームのキャラクタが作業者のどのような説得も受け入れるという設定に対して，作業者の説得文章が答えの文章に類似するものでなければ，キャラクタは説得を受け入れない設定を取り入れた．その結果，従来手法と比較を行い，作業前の意欲の向上に有意傾向があった．今後の課題として，作業者にとって用意された答えが納得感が得られない可能性があるため，成否の判定の種類を増やし納得感が得られる仕組みが必要だと考えられる．

参考文献

[1] 藤野　秀則，石井　裕剛，下田　宏，吉川　榮和：アフェクティブインターフェースを用いた作業意欲向上の開発と評価，電気学会論文誌，Vol.128，No.1，pp.11-23(2008)．

[2] L. Festinger and J.M. Carlsmith： Cognitive consequences of forced compliance， *Journal of Abnormal Psychology*，Vol.58，No.2，pp203-210(1959)．

[3] Microsoft：LUIS:Homepage，
https://www.luis.ai/home，最終閲覧日 2017/12/18

[4] 寺島　正治，岸本　陽一，古賀　愛人：多面的感情尺度の作成，心理学研究，Vol.62，No.6，pp.350-356(1992)．

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

状態空間モデルを用いたWikipediaからの雑談対話システム用発話文の獲得

Acquiring Utterance Candidates for Chat-oriented Dialogue Systems from Wikipedia Based on a State Space Model

松本 知己 *1　酒井 正人 *1　中野 幹生 *2
Tomoki MATSUMOTO　Masato SAKAI　Mikio NAKANO

*1株式会社 Nextremer　*2株式会社 ホンダ・リサーチ・インスティチュート・ジャパン
Nextremer Co., Ltd.　Honda Research Institute Japan Co., Ltd.

This paper presents a method for acquiring utterance candidates for chat-oriented dialogue systems in specific domains from Wikipedia articles. A previously proposed method extracts sentences from Wikipedia articles related to the domain, converts them to utterances suitable for chat, and excludes sentences inappropriate as system utterances using a classifier. The classifier uses position information of the sentence in the article, but it is based on a simple logistic regression. On the contrary, our proposed method uses a state space model in a Bayesian approach. Experimental results show the proposed method outperforms the previous method.

1. はじめに

我々は, 特定のドメインの雑談を行う対話システムの構築を目指している. 雑談対話システムの発話生成として, seq2seqのようなニューラルネットワークにより発話文を生成する方法 [Li 16] と, あらかじめ用意された発話文集合から文脈に合うものを選択する手法 [稲葉 17] がある. 後者は自然な文が生成されるというメリットがあるが, あらかじめ人手で大量の文を用意するのは多大なコストがかかる.

そこで, 自動的に対話システムの発話候補文を獲得する手法として, Wikipedia[*1] を利用した方法が提案されている [太田 09, 杉本 17]. Wikipedia の記事は誰でも編集をすることが可能であるため情報の信頼性が心配されるが, 一定の信頼性があることが分かっている [日下 12]. また Wikipedia の各記事は, 記事ごとに差はあるが 1 つの記事にあるトピックについての情報が網羅されており, 記事の数も膨大であるため, 対話システムに用いる対話候補文の獲得源として注目されている. 本稿では, Wikipedia を対話候補文の獲得源として注目した [杉本 17] の研究を発展させ, 雑談対話システムのための新たな対話候補文の獲得方法を提案する.

本稿の構成は以下の通りである. 第 2 章では, 本研究に関連する研究を紹介する. 第 3 章では, [杉本 17] の方法を概説した後, [杉本 17] のモデルを拡張したモデルについて説明し, 第 4 章で提案したモデルの評価をする. 第 5 章では考察を述べ, 第 6 章では本稿のまとめと, 今後の課題を述べる.

2. 関連研究

[太田 09] は, 対話が盛り上がるような発話を行う雑談対話システムへの応用を目的に, Wikipedia から発話候補文の抽出を行う方法を提案している. [太田 09] は珍しい単語や単語の組み合わせで構成される文は人間にとって意外性があり, 対話を盛り上げるような内容であると仮定し, TF-IDF, 単語の共起性, 文の長さを用いて計算されるスコアで文をランク付けする方法を提案し, そのスコアの値が高い文ほど, 対話を盛り上げる内容の文であるとしている. しかし, この方法では一部の特徴的な文だけが抽出されるため, これだけでは雑談対話システムの実現は難しい.

また, [杉本 17] は雑談対話システムのために Wikipedia の記事から自動的に文を抽出し, 抽出した文を対話システムの出力として相応しいかという点でフィルタリング, 及び口語体へ変換する方法を提案している. そして, こういった変換が施された文が, 実際に対話システムの文として使用可能かどうか判別するモデルとして, 文を抽出する際に付随する記事上における文の位置情報を特徴量とした, ロジスティック回帰判別モデルを提案している. しかし, [杉本 17] の判別モデルは, 文の位置情報を十分に活用できていなかった.

本稿では, これら文の位置情報をベイジアンモデリングの枠組みに組み込むことで, [杉本 17] が提案したロジスティック回帰判別モデルを拡張する.

3. 提案手法

本章では, [杉本 17] が提案した, Wikipedia から発話候補文を獲得する方法について概説した後, 獲得した文に付随する情報を用いた, 新たな文使用可否判別モデルを提案する.

3.1 候補文の獲得

[杉本 17] が提案した, 発話候補文を獲得する方法について概説する. まず, Wikipedia 記事の HTML の<p>タグ内に属する文章を抽出し, 句点 (。) 区切りで文章を文に分割する.

次に, 抽出した各文に対して, フィルタリングを行い, さらに口語体変換を行う. フィルタリングは, 一文中に含まれる文字数や, 一文で意味を理解できない文 (文脈依存の文), 対話システムへの使用が不適切と判断される表現を含む文などを排除することである. そして, フィルタリングによって排除されなかった文は口語体に変換される. この時点で, 例えば, Wikipedia の「お好み焼き」トピックからは

お好み焼きは, 小麦粉とキャベツなどを使用する鉄板焼きの一種で, 日本の庶民的な料理なんですよ *2

連絡先: 松本 知己, 株式会社 Nextremer, 東京都板橋区成増 1-30-13 トーセイ三井生命ビル 10F, 03-6915-6447, tomoki.matsumoto@nextremer.com

*1 日本語版 Wikipedia: http://ja.wikipedia.org/

*2 本稿では, クリエイティブ・コモンズ・表示・継承ライセンス 3.0 (http://creativecommons.org/licenses/by-sa/3.0/) のもとで公表されたウィキペディア (https://ja.wikipedia.org/) の「お好み焼き」及び「ウイスキー」の項目を二次利用した. (参照日 2018 年

といった文が抽出される.

こうして抽出された文が対話システムに使用可能であるかどうかを判定する. ここで, 対話システムに使用可能かどうかの基準は, (1) 日本語として自然で, (2) その文だけで内容が理解でき, (3) その記事のトピックに関して述べている, である. この判別には, 記事から文を抽出した際に得られる, 以下の特徴量を用いたロジスティック回帰判別を用いる.[*3][*4]

- f_1: header info（<h1>,<h2>,<h3>,<h4>）
- f_2: header id（上から何番目のヘッダに所属するか）
- f_3: paragraph id（ヘッダ中の何番目の段落に登場するか）
- f_4: sentence id（所属する段落の何文目に登場するか）

3.2 モデル

本節では, [杉本 17] のロジスティック回帰を状態空間モデルへ拡張した, 階層文状態空間モデルを提案する.

[杉本 17] は, ロジスティック回帰モデルの特徴量として記事における文の位置情報を使用したが, 単に説明変数として使用しただけであったため, 十分に位置情報をモデルに組み込めてはいなかった. そこで [杉本 17] のモデルを, 以下を考慮したベイズモデルへ拡張する:

(i) それぞれの記事は, 固有の特徴がある.
(ii) それぞれの記事は, ヘッダーによる階層構造を持っている.
(iii) 段落内において, ある文が使用可である確率が, その次の文の使用可否に影響を与える.
(iv) 段落内において, 文の使用可否の状態は連続的に変化する.

仮定 (i) は, それぞれの記事は現時点で手に入っているデータからは説明することができない, 固有の特徴を持っていることを仮定している. これは, 生態学において生物や植物の個体を解析する際に個体差と呼ばれているもので, 記事差と呼ぶこととする. 仮定 (ii) は, それぞれの記事はヘッダーごとに異なる傾向を示すであろうということを仮定している. 例えば, ヘッダー 1 内の文は使用可となりやすく, ヘッダー 4 内の文は使用不可となりやすい, といった異なる傾向を持つことを仮定していることになる. 仮定 (iii) は, 例えば, ある文が使用可になる確率が高ければ, その次に続く文も使用可になりやすいといった傾向が存在することを仮定している. 今回は, ある文に影響を与える文は, その文の 1 つ前の文, 2 つ前の文の 2 文とした. 仮定 (iv) は, 段落内における文の先頭からの順番を時系列のインデックスとみなしたときに, 段落内で文はある種の“状態”を持っており, その状態は前の文から次の文へ伝搬していくということを仮定している. このことを表現するために, 今回はある文の状態とその 1 つ前の文の状態は似ているという 1 階差分の制約を課した.

以上をまとめるとモデルは以下となる. 以下の式で, $a = 1, \ldots, A$ は記事番号, $h = 1, \ldots, 4$ はヘッダー番号, $b = 1, \ldots, B_a$ はパラグラフ番号, $s = 1, \ldots, S_{a,b}$ は文番号, $t = 1, 2$ はそれぞれ 1 つ前, 2 つ前の文を表す遅延番号, $i = 2, 3$ は特徴量番号で, それぞれ 3.1 節で定義した特徴量 f_2, f_3 を表すインデックスとする. インデックス h には特徴量 f_1 を, インデックス s には特徴量 f_4 を用いることができる. また, $y_{a,h,b,s}$ は [杉本 17] の方法によって抽出された文のアノテーション結果であり, 教師データとなる. つまり, 抽出された文が使用可であれば $y_{a,h,b,s} = 1$, 使用不可であれば $y_{a,h,b,s} = 0$ となる.

$$y_{a,h,b,s} \sim Bernoulli(p_{a,h,b,s}) \tag{1}$$

$$p_{a,h,b,1} = \mathrm{logit}^{-1}(\gamma_a + \alpha_1 + \beta_{h,0} + \sum_{i=2}^{3} \beta_{h,i} f_{a,h,b,1,i}) \tag{2}$$

$$p_{a,h,b,2} = \mathrm{logit}^{-1}(\gamma_a + \alpha_2 + \eta_{h,1} p_{a,h,b,1} + \beta_{h,0} + \sum_{i=2}^{3} \beta_{h,i} f_{a,h,b,2,i}) \tag{3}$$

$$p_{a,h,b,s} = \mathrm{logit}^{-1}(\gamma_a + \alpha_s + \sum_{t=1}^{2} \eta_{h,t} p_{a,h,b,s-t} + \beta_{h,0} + \sum_{i=2}^{3} \beta_{h,i} f_{a,h,b,s,i}) \tag{4}$$

$$\gamma_a \sim Normal(\theta_\gamma, \sigma_\gamma^2) \tag{5}$$

$$\alpha_s \sim Normal(\alpha_{s-1}, \sigma_\alpha^2),\ s = 2, \ldots, S_{a,b} \tag{6}$$

$$\beta_{h,0} \sim Normal(\theta_{\beta_0}, \sigma_{\beta_0}^2) \tag{7}$$

$$\beta_{h,i} \sim Normal(\theta_{\beta_i}, \sigma_{\beta_i}^2) \tag{8}$$

$$\eta_{h,t} \sim Normal(\theta_{\eta_t}, \sigma_{\eta_t}^2) \tag{9}$$

$$\theta_\gamma, \theta_{\beta_0}, \theta_{\beta_i}, \theta_{\eta_t} \sim Normal(\mu, \rho^2) \tag{10}$$

$$\alpha_1, \mu \sim Uniform(-\infty, \infty) \tag{11}$$

$$\sigma_\gamma, \sigma_\alpha, \sigma_{\beta_0}, \sigma_{\beta_i}, \sigma_{\eta_t}, \rho \sim Uniform(0, \infty) \tag{12}$$

logit^{-1} はロジスティック関数, $Bernoulli$ はベルヌーイ分布の確率質量関数, $Normal$ は正規分布の確率密度関数, $Uniform$ は一様分布の確率密度関数を表している. $Uniform(-\infty, \infty)$ 及び $Uniform(0, \infty)$ は無情報事前分布を表しており, 事前情報を仮定しないことを意味している.

式 (5) は仮定 (i) を表している. それぞれの記事 a についての固有の特徴 γ_a の値は, 平均値としては記事全体に共通の θ_γ であり, その平均の周りを共通の標準偏差 σ_γ で正規分布した結果, 記事ごとに異なる特徴 γ_a が現れるというモデリングである. したがって, 標準偏差 σ_γ は記事差がどれほど存在するかの指標となり, 小さな値を取れば, それぞれの記事の固有の特徴は平均周りに集中的に分布することになるため, あまり記事差が無いことを示唆し, 逆に大きな値を取れば, それぞれの記事の特徴は平均から離れた値を取りやすくなるため, 記事差があることを示唆する.

式 (7), (8), (9) は仮定 (ii) を表している. ヘッダー h ごとのロジスティック回帰における切片項 $\beta_{h,0}$, 特徴量 f_i $(i = 2, 3)$ に対する係数 $\beta_{h,i}$ と, $t(= 1, 2)$ つ前の文が使用可である確率に対する係数 $\eta_{h,t}$ は, それぞれが各ヘッダーに共通の平均 $\theta_{\beta_0}, \theta_{\beta_i}, \theta_{\eta_t}$ の周りを標準偏差 $\sigma_{\beta_0}, \sigma_{\beta_i}, \sigma_{\eta_t}$ で正規分布した結果, ヘッダーごとに異なった値として現れるというモデリングである. したがって記事差の場合と同様に, これら標準偏差はヘッダーごとに異なる傾向を示すことの指標となる.

式 (3), (4) は仮定 (iii) を表現している. ロジスティック回帰モデルにおける確率を計算するロジスティック関数 logit^{-1} の中に, 前の文が使用可になる確率とその係数が掛け合わされた形で入っている.

式 (6) は仮定 (iv) を表現している. ある文の状態 α_s とその前の文の状態 α_{s-1} は“似ている”という, 以下の 1 階差分の

03 月 08 日）

*3 フィルタリングや口語体変換, 文が対話システムで使用可能かどうかの判別の訓練データのアノテーションの方法の詳細は [杉本 17] を参照.

*4 [杉本 17] の検証では, f_1, f_2, f_4 を説明変数として使用したロジスティック回帰判別モデルの精度が最も高かった.

	(f_2)	(f_3)	(f_2, f_3)	[杉本 17]
WAIC	0.572	0.576	0.571	-
精度	-	-	0.682	0.644

表 1: 提案モデルの WAIC と精度, 及び [杉本 17] のモデルの精度. (f_2), (f_3), (f_2, f_3) はそれぞれ提案モデル説明変数として f_2 だけを用いた場合, f_3 だけを用いた場合, f_2 と f_3 をともに用いた場合を表している.

制約をそれぞれの文の状態に課すことで, 文の使用可否の状態が連続的に変化することを表現している.

$$\alpha_s - \alpha_{s-1} \approx 0 \iff \alpha_s \approx \alpha_{s-1}$$

このことを, ある文の状態 α_s はその前の文の状態 α_{s-1} を中心に標準偏差 σ_α で正規分布するという形で表現したものが式 (6) であり, これは一般的に 1 階差分ガウス状態空間モデルと呼ばれている.

最後に, θ と下付き文字で表されるすべての正規分布の平均パラメータはすべて共通の平均 μ, 標準偏差 ρ の正規分布に従うとし, 段落内における先頭の文の状態 α_1, μ, σ と下付き文字で表されるすべての正規分布の標準偏差パラメータ, そして ρ はすべて無情報事前分布に従うとする.

4. 評価

本章では, 提案手法のモデル選択と精度評価を行う. 提案モデルには, 説明変数として f_2 だけを用いる場合, f_3 だけを用いる場合, f_2 と f_3 をともに用いる場合の 3 パターンの自由度があるため, 変数選択の指標として WAIC (Widely Applicable Bayesian Information Criterion) を用いる [Watanabe 13]. WAIC は事後分布が正規分布で近似できない場合にも使用できる情報量基準であり, AIC(赤池情報量基準) を一般化したものである.

精度評価には 5-fold の交差検証を実施した. また, Wikipedia から抽出されたデータは [杉本 17] で使用されたものを使用した. [杉本 17] は料理分野に関する 60 記事から候補文を抽出していたため, その 60 記事を 5 分割することで訓練データ 48 記事, 検証データ 12 記事のペアが 5 つできる. これらを用いて交差検証を行い, 5 回の検証で得られた精度の平均値を評価指標とする. モデルの推定には, Stan を R 言語上で実行することができる, RStan を使用した [Stan Development Team 17]. Stan は, 事後分布に従うパラメータのサンプルを得ることができるサンプラーである.

検証結果は表 1 のようになった. WAIC によるモデル選択の結果, WAIC の値が最も小さい, 説明変数として f_2 と f_3 をともに用いるモデルが選択された. また, 選択されたモデルと [杉本 17] のモデルの精度を比較すると, 我々が今回提案するモデルの方が [杉本 17] のモデルよりも高精度に文の使用可否を判別できていることがわかる.

5. 考察

3.2 節で説明したように, 提案したモデルには 4 つの仮定を置いていた. 本章では, それぞれの仮定についての妥当性を確認する.

表 2 は, 3.2 節で提案したモデルの各正規分布の標準偏差パラメータの推定結果である. σ_γ は, 各記事は特有の効果を持っているという仮定 (i) についての妥当性を表していると考えられる. 各記事の特徴は, 平均パラメータ θ_γ の値が定まると, その θ_γ を中心に平均的に標準偏差 0.69 でばらつく. 例えば, 他の変数の値が同じで記事差だけが 0.69 異なる記事同士を比較したとすると, 使用可の確率は $\exp(0.69) = 1.993$ と, 約 2 倍異なってくる. これは記事差が存在することを表していると言える.

	mean	sd	2.5%	25%	50%	75%	97.5%
σ_γ	0.69	0.10	0.51	0.62	0.68	0.75	0.90
σ_0	2.87	3.94	0.77	1.35	1.97	3.11	10.2
σ_{η_1}	0.83	0.81	0.06	0.40	0.64	1.03	2.72
σ_{η_2}	0.49	0.73	0.02	0.16	0.34	0.62	1.86

表 2: モデルの各正規分布の標準偏差パラメータの推定結果. mean は平均値, sd は標準偏差を表す.

	mean	sd	2.5%	25%	50%	75%	97.5%
$\eta_{1,1}$	-0.02	0.53	-1.13	-0.34	0.00	0.31	0.98
$\eta_{2,1}$	0.54	0.27	0.03	0.35	0.54	0.72	1.07
$\eta_{3,1}$	0.39	0.31	-0.18	0.18	0.38	0.60	1.03
$\eta_{4,1}$	-0.35	0.57	-1.56	-0.72	-0.30	0.05	0.64
$\eta_{1,2}$	0.04	0.43	-0.82	-0.19	0.01	0.24	1.00
$\eta_{2,2}$	0.12	0.28	-0.40	-0.07	0.10	0.29	0.74
$\eta_{3,2}$	-0.13	0.33	-0.88	-0.31	-0.10	0.07	0.48
$\eta_{4,2}$	0.10	0.47	-0.76	-0.15	0.05	0.32	1.25

表 3: 1 つ前, 2 つ前の文が使用可となる確率に対する, ヘッダーごとの係数の推定結果. mean は平均値, sd は標準偏差を表す.

σ_0 は, それぞれの記事はヘッダーによる階層構造を持っているという仮定 (ii) の妥当性を表していると考えられる. σ_γ の場合と同様の議論で, ヘッダーごとに異なる特徴を持っていることが言える. σ_{η_1}, σ_{η_2} はそれぞれ 1 つ前, 2 つ前の文が使用可となる確率に対する, ヘッダーごとの係数 $\eta_{h,1}$, $\eta_{h,2}$ の標準偏差である. 1 つ前, 2 つ前の文が使用可となる確率が当該文に与える影響がヘッダーごとに異なることを表しており, このことからもヘッダーごとに異なる特徴を持っていることが言える.

表 3 は, 1 つ前, 2 つ前の文が使用可となる確率に対する, ヘッダーごとの係数 $\eta_{h,1}$, $\eta_{h,2}$ の推定結果である. 特に 1 つ前の文が使用可となる確率に対する係数 $\eta_{h,1}$ について, ヘッダー 1 は 1 つ前の文が使用可となる確率に影響をあまり受けず, 逆にヘッダー 2 と 3 に属する文は正の影響を, ヘッダー 4 に属する文は負の影響を受ける傾向があることが分かる. このことからも仮定 (ii) は妥当なものであると考えられ, また前の文が使用可である確率が次の文が使用可になる確率に影響を与えるという仮定 (iii) は妥当なものであると考えられる.

図 1 は, 推定された段落内における文の状態の推定結果を, 横軸が段落内における先頭からの文の順番, 縦軸が推定された文の状態として図示したものである. 段落の先頭の文が最も使用可になりやすく, 段落の深い箇所にある文であるほど使用可になりにくいという構造が推定されている. このことから, 段落内において, 文の使用可否の状態は連続的に変化するという仮定 (iv) は妥当なものであると考えられる.

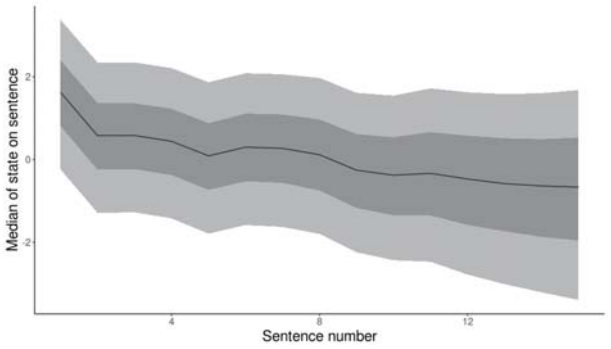


図 1: 文の状態推移．横軸が段落内における先頭からの文の順番, 縦軸が推定された文の状態．実線は 50%点, 濃い区間は 50%信用区間, 薄い区間は 80%信用区間を表している．

また，以下は使用可とアノテーションされた文のうち, [杉本 17] のモデルでは使用不可と判別されていたが, 今回我々が提案したモデルでは正確に使用可と判別できるようになった文の例である．

英国スコットランドで造られるウイスキーをスコッチ・ウイスキーまたは単にスコッチと呼ぶんですよ

この文は「ウイスキー」トピックの記事において, 上から 18 番目のヘッダー番号 4 のヘッダーに属していた．ヘッダー番号 4 の文は使用不可になりやすく, また記事の下の方にあるヘッダーに属する文も使用不可になりやすい傾向にあるため, [杉本 17] のモデルはこの文を使用不可と判断したと考えられる．しかし, この文は段落内における先頭の文であったため, 先頭の文はより使用可になりやすいという, 我々が提案したモデルにおける文の状態の推定結果によって, この文が正しく使用可であると判別できるようになったと考えられる．

以上から, 3.2 節で提案した仮定は妥当なものであると考えられ, こういった文の構造のモデル化の妥当性が, 第 4 章における文の使用可否の判別性能の向上に繋がったと考えられる．

6. おわりに

本稿では, [杉本 17] が提案した雑談対話システムのために Wikipedia から発話候補文を獲得する方法によって得た候補文が使用可能であるかを判別する, 階層文状態空間モデルを提案した．また, [杉本 17] が提案したロジスティック回帰モデルと精度の比較検証を行い, 提案モデルの方がより高精度に文の使用可否判別が行えることを確認した．

今後の課題として, 今回は単に説明変数として用いたヘッダーの順番 f_2 と段落の順番 f_3 のさらなる活用がある．今回のモデルではヘッダー情報を表す f_1 と段落内での文の順番を表す f_4 を, それぞれ階層化の対象と状態変化の対象としてモデルに組み込むことができた．しかし, ヘッダーの順番 f_2 と段落の順番 f_3 は単に説明変数として用いただけであったため, これらを適切にモデルの中に組み込む方法を考える必要がある．また, 現在は文の位置情報だけをモデルに用いており, 仮に同じ構造をもつ記事が複数あった場合, 記事の内容や文の意味に関わらず全く同じ使用可否判別を行うことになる．より高精度な判別のためには, 文の意味を組み込んだモデルが必要となる．

参考文献

[稲葉 17] 稲葉 通将，高橋 健一：非タスク指向型対話システムのためのリカレントニューラルネットワークを用いた発話候補ランキング, 電子情報通信学会論文誌 D, Vol.J100-D, No.6, pp. 661-671, 2017.

[稲葉 12] 稲葉 通将, 平井 尚樹, 鳥海 不二夫, 石井 健一郎：非タスク指向型対話エージェントのための統計的応答手法, 電子情報通信学会論文誌, vol.95, pp. 1390–1400. 2012.

[太田 09] 太田 知宏, 島海 不二夫, 石井 健一郎：発話生成を目的とした Wikipedia からの文抽出, 人工知能学会全国大会講演論文集, 2009.

[日下 12] 日下 九八：ウィキペディア：その信頼性と社会的役割, 情報管理, vol.55, pp. 2–12. 2012.

[杉本 17] 杉本 俊, 植木 拓, 林 宏幸, ニコルズ エリック, 中野 幹生：特定ドメイン雑談対話システムのための Wikipedia を用いた発話文の生成, 人工知能学会 言語・音声理解と対話処理研究会, vol.81, pp. 98-99. 2017.

[東中 14] 東中 竜一郎：雑談対話システムに向けた取り組み, 人工知能学会研究会資料 SIG-SLUD-70, pp. 65–70. 2014.

[樋口 11] 樋口 知之：予測にいかす統計モデリングの基本—ベイズ統計入門から応用まで, 講談社. 2011.

[Gelman 13] Andrew Gelman, John B. Carlin, Hal S. Stern, David B. Dunson, Aki Vehtari, Donald B. Rubin : Bayesian Data Analysis, Third Edition, CRC Press. 2013.

[Li 16] Jiwei Li, Michel Galley, Chris Brockett, Georgios PSpithourakis, Jianfeng Gao, Bill Dolan : A persona-based neural conversation model, In Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (ACL-16), pp. 994-1003. 2016.

[Stan Development Team 17] Stan Development Team : RStan: the R interface to Stan. R package version 2.16.2. 2017.

[Watanabe 13] Sumio Watanabe : A Widely Applicable Bayesian Information Criterion, Journal of Machine Learning Research, vol.14, pp. 867-897. 2013.

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

未知の属性の問合せに応答可能な対話システムを目指した知識グラフの拡充

Knowledge Graph Expansion for Constructing Dialogue Systems Responding to Queries about Unknown Attributes

藤岡 勇真　　駒谷 和範
Yuma Fujioka　　Kazunori Komatani

大阪大学産業科学研究所
The Institute of Scientific and Industrial Research, Osaka University

Dialogue systems cannot respond to queries including unknown words. Constructing a perfect knowledge base is practically impossible; that is, filling all the attributes in relational databases is quite labor-intensive. We are trying to construct a system that responds reasonably by exploiting existing system knowledge even when a user's query contains unknown attributes. More specifically, we use knowledge graphs as the system's backend and infer unknown attributes of entities by generalizing them with collaborative filtering and tensor factorization. As a first step for it, we extracted a knowledge graph from Wikidata, a commonly-used LOD (linked open data), in the food and dish domain, but it was sparse for generalization. We expand the knowledge graph with external datasets, specifically recipe data contributed to a Web site, and evaluate it by a task to find similar words.

1. はじめに

対話システムは，未知の情報に関する問合せに上手く応答することが出来ない．対話システムに対するよくある入力例として，ある語に関する情報の問合せを考える．このような問合せが入力された場合，システムはその知識ベースから必要な情報を検索し，適切な応答文を生成する．しかし現状の対話システムは，要求された情報が知識ベースに存在しなかった場合，話題を変えたり「わかりません」といった，文脈上不自然な応答をしてしまう．また，必要な情報が全て網羅されている知識ベースを構築するのは非常に困難である．ゆえに，より良い応答の出来る対話システムを目指すうえで，知識ベースに無い情報の問合せへの対応は避けられない課題だと言える．

本研究では，質問された語の情報がシステムにとって未知だった場合でも合理的に応答出来るシステムの構築を目指している．図 1 に目標とするシステムの枠組みを示す.「ミネストローネってイタリアの料理なんですか？」と，ユーザからある語に関する問合せがシステムに入力される．この問合せには，入力語である「ミネストローネ」の「国」という属性に関する情報が必要になる．知識ベースにその情報がないことが判明すれば，システムは既知の情報を用いて，欠損した語の属性や類似した語の推測を試みる．図 1 では,「ミネストローネ」の「国」が「イタリア」であるかどうかを既知の情報から推測し，その結果から「ミネストローネはたぶんイタリアの料理だと思いますよ」という，断定はしないが可能性をほのめかせる応答を行っている．

対話システムにおける入力文中の未知語の処理に取り組んだ研究はこれまでにも行われている [大塚 13][大野 18]．これらの研究では，ユーザへの質問や発話内容の解析によって未知語の情報の獲得を試みているが，本研究では既に知識ベース上にある情報を利用して必要な情報の推測を目指す．

図 1 のような応答生成の実現に向けての第一歩として，システムがバックエンドで持つ知識ベースとして知識グラフを使用する．知識グラフとは，グラフ構造を持ったデータベースである．知識グラフはデータ間の様々な関連性を表現するのに長けた知識モデルであり [Angles 08]，近年こういったグラフ構造をもつデータベースが徐々に増えている．

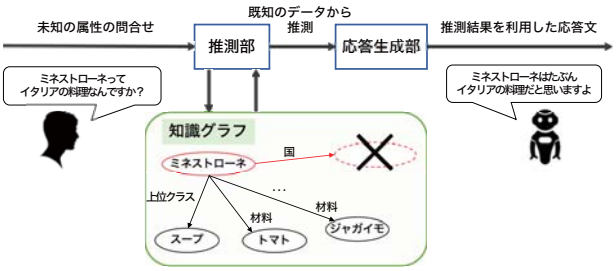


図 1: 目標システムの全体像

本稿では，システムが持つ知識グラフが料理の一般的な情報を持つとして，その構築を行う．まず大規模知識ベースである Wikidata[*1] からのデータ抽出によって知識グラフを構築した．しかし，構築した知識グラフ上には料理の一般的な材料情報が十分でなく，知識グラフがあまりにスパースだと推測や解析が困難になると考えられる．そこで，楽天公開データ [*2] 中の楽天レシピに関するデータを使って，料理の一般的な材料情報を知識グラフの拡充を行う．知識ベースの拡充手法には Web 上のテキストデータからの抽出などがあるが [高橋 07]，本研究では構造化されたレシピデータを用いて信頼性の高いデータの抽出を試みる．拡充の有効性は，入力語に類似した語を知識グラフ上から得るというタスクにより検証した．

2. システムが持つ知識グラフ

2.1 知識グラフ

目標システムは，料理に関する一般的な情報が格納された知識グラフを持つとしてその構築を行う．ここで知識グラフとは，データとデータの間にある関係がグラフ構造によって表現されたデータベースを指す．一般に，グラフ中のそれぞれのノードが 1 つのデータを表現し，ノード間に張られるエッジは

連絡先: 藤岡勇真，大阪大学産業科学研究所，大阪府茨木市美穂ヶ丘 8-1，06-6879-8416，fujioka@ei.sanken.osaka-u.ac.jp

∗1 https://www.wikidata.org
∗2 https://rit.rakuten.co.jp/data_release_ja/

その 2 つのデータ間に何らかの関係があることを示している．また，データ間の構造的な関係を表現するには向きを持つ有向エッジが用いられ，エッジそのものにラベルを付与し関係の種類，すなわちどんな属性であるかを表すこともある．

2.2 Wikidata を用いた知識グラフの構築

Wikidata は，Web の仕組みに基づきリンクされたオープンなデータである Linked Open Data として公開されている．Wikidata は大規模知識ベースの 1 つとして知られ，多言語対応，人手による管理体制などが主な特徴として挙げられる．Wikidata は，Resource Description Framework(RDF) 用のクエリ言語である SPARQL を用いたデータ検索が可能である．

RDF とは，概念や実体を抽象化したリソースの関係を，主語・述語・目的語という三つ組によって記述するデータモデルであり，この三つ組は一般的にトリプルと呼ばれている．RDF は，トリプルを有向エッジ，リソースをエンティティ，述語に記述されたプロパティを有向エッジのラベルとする，ラベル付き有向グラフとして表現することが出来る．SPARQL ではそのグラフパターンを指定することでデータ検索を実現しており，トリプルとしてデータを抽出することが出来る．

Wikidata からの料理に関する情報抽出の手順を示す．はじめに，目標システムが料理としてみなすエンティティの集合である料理群を設定した．具体的には，

1. 『料理，料理のサブクラス，type of food or dish』のインスタンス
2. 『料理，type of food or dish』のサブクラス

という 2 つの条件を 1 つでも満たすエンティティの集合である．

この条件を満たすエンティティを Wikidata から収集すると，その数は 3278 個であった (重複を除く)．

そして，取得した料理群の要素となるエンティティ(以下，料理エンティティと記述する) が主語もしくは目的語となっているトリプルを全て取得した．ここで取得した 110255 個のトリプルには，他のデータベース上における固有 ID や画像・発音音声へのリンクなどといった，エンティティ間の関連性を表さないプロパティを持つものが多く存在していた．そのため，前述のようなプロパティを除く 10 種のプロパティを持つ 11495 個のトリプルによって知識グラフを構築した．

3. 楽天公開データを用いた知識グラフの拡充

前節で構築した知識グラフは，一般的な料理の材料情報が不足していた．そこで，楽天公開データ中の料理レシピ検索サイト「楽天レシピ *3」に投稿された約 80 万件分のレシピデータから，料理の一般的な材料の情報を抽出して知識グラフに拡充する．

このレシピデータはレシピ名・料理名・カテゴリ・材料などの情報が各レシピごとにデータ化されたものである．同じ料理名が記述されたレシピでも，使っている材料はレシピ毎に異なる．またレシピに記載されている材料の中には，地域性や投稿者のアレンジなどに由来する，その料理の材料としては一般的でない材料が含まれている場合もある．ゆえに，料理名に結びつけられた使用材料をそのまま全て知識グラフに拡充することは，一般的な料理の材料情報の拡充という目的にそぐわない．そこで，ある料理で使われている材料 m の一般性が高いほど，その料理のレシピにおける材料 m の使用率が高いと仮定し，使用率に基づく拡充対象の選別を行う．

*3 https://recipe.rakuten.co.jp/

表 1: 楽天レシピデータにおける「オムライス」の材料使用率

使用された材料名	使用率 U_{rate} (%)
「卵」	79.9
「ケチャップ」	69.9
「ご飯」	44.7
「玉ねぎ」	38.4
……	……
「しいたけ」,「ほうれん草」	1.6
「豆乳」,「みりん」,「ソース」	1.5
「塩麹」,「とろけるチーズ」,「冷凍コーン」	1.3
……	……

「料理名が c でその材料が m である」という情報を知識グラフに拡充する手順は，大きく分けて次の 3 つのステップからなる．

1. 全てのレシピデータから，料理名と使用材料の組を抽出する．
2. 料理名 c のレシピにおける材料 m の使用率 $U_{rate}(c,m)$ を算出する．
3. 一定の条件を満たす c,m の組を知識グラフへの拡充候補とし，そうでない場合は拡充候補から棄却する．

まず，第 1 ステップである料理名と使用材料の組の抽出について述べる．料理名 c における材料 m の使用率を求めるために，各レシピデータから料理名と材料の組を抽出する．i 番目のレシピデータに記述されている料理名 $c^{(i)}$ と使われている材料からなる集合 $M^{(i)}$ を抜き出し，i 番目のレシピデータの料理名・材料の組を表す集合 $S^{(i)} = \{c^{(i)}, M^{(i)}\}$ を抽出する．この $S^{(i)}$ の作成を，$i = 1, 2, ..., 796067$ について行う (796067 はレシピ総数)．

第 2 ステップである，料理名 c のレシピにおける材料 m の使用率 $U_{rate}(c,m)$ の算出について述べる．料理名 c における材料 m の使用率 $U_{rate}(c,m)$ を式 (1) のように定義する．

$$U_{rate}(c,m) = \frac{|\{S^{(j)}|c^{(j)} = c, M^{(j)} \ni m\}|}{|\{S^{(j)}|c^{(j)} = c\}|} \qquad (1 < j < n) \tag{1}$$

式 (1) の分母は料理名が c であるレシピの総数を表している．そして分子は，料理名が c であるレシピの中で，材料 m が使用されているレシピの総数を表す．

使用率 $U_{rate}(c,m)$ の実例として表 1 に，c を「オムライス」とした時の，材料ごとの使用率の一部を示す．表 1 は「オムライス」の食材を使用率の昇順に並べたもので，使用率が高い食材と低い食材の一部を抜粋している．使用率が高い材料には「卵」,「ケチャップ」,「ご飯」といった,「オムライス」の一般的な材料が並んでいる．一方で，使用率が低い材料には,「しいたけ」,「豆乳」,「塩麹」等といった「オムライス」の材料としては一般的ではない材料が多く含まれている.「オムライス」の例は，使用率が高いほどその料理に一般に使われる材料であるという仮説を支持する結果になっている．

次に第 3 ステップである，材料情報の拡充の判定について述べる．使用率 $U_{rate}(c,m)$ に対するしきい値を θ とし，$U_{rate}(c,m) \geq \theta$ が成り立つ c,m の組を知識グラフへ拡充する．この判定で，使用率の低い材料が知識グラフに拡充されることを防ぐ．しきい値 θ の値は 4.2 節の調査結果より決定する．

例外として，多くの料理に材料として頻出した「水」,「油」,「砂糖」,「塩」の 4 つの材料は，料理の特徴的な材料としては不適当であるとし，これらの材料を含む c, m の組は拡充対象から除外している．また，Wikidata を用いて構築した知識グラフ上のエンティティの中に，c, m というラベルが付与されたエンティティが片一方でも存在していない場合でも，拡充対象から除外している．これは実装上設けた制限であり，構築した知識グラフ上に新たなエンティティを作成することは行っていない．あくまで Wikidata を用いて構築した知識グラフ上のエンティティ間に，材料の関係を結びつける形になる．

第 3 ステップで述べた条件を満たす全ての c, m の組について,「c の材料が m である」という事実を表すトリプルを作成し，知識グラフにトリプルを拡充する．以上の処理によって，楽天公開データから料理の材料情報をトリプル形式で抽出し，Wikidata と楽天公開データの料理に関する情報を統合する．

4. 知識グラフ上での類似語推測性能の調査

4.1 調査方法

知識グラフの拡充の効果を，入力語に類似した語を知識グラフから得るというタスクにより検証する．一般的な料理の材料情報が楽天公開データから拡充されていれば，その情報によって知識グラフ上の料理エンティティは正しく特徴付けられる．よって拡充を行わない場合に比べて，容易に知識グラフ上から類似語を得ることが出来ると考えている．反対に一般的でない料理の材料情報が拡充されていれば，料理エンティティが一般的でない情報で特徴付けられ，類似した語を得るのが困難になると考えている．

入力語に類似した語をシステムが見つけられているかどうかの指標として，類似度に基づくランキングにおける順位を用いる．この調査では，テストセット中の 30 種の料理を入力語と仮定している．ここでテストセットとは，30 種の料理と各料理に類似した料理を 1 から 3 種人手で選定してペアとして結びつけた 30 個のペアを指す．類似した料理の合計は 57 個となった．類似した料理を入力語に対する類似語とし，入力語と紐づけた類似語を類似度ランキング上で高く順位付け出来るかで構築した知識グラフの評価を行う．

類似度ランキングの作成に際して，知識グラフ上の各エンティティを表現するベクトルを定めた．知識グラフ上のエンティティを表現するベクトルは，知識グラフにおけるエンティティ間の接続関係を 1 と 0 で表した隣接行列を用いて表現した．

入力語を表現するベクトルと料理エンティティを表現するベクトルに関するコサイン類似度に従ってランキングを作成する．ランキング対象とする料理エンティティは，エンティティを表現するベクトルの要素の総和が 4 以上かつ Wikidata から取得したエンティティのラベル情報に，日本語のラベルが含まれている 513 個の料理エンティティである．

4.2 類似度ランキングにおける順位による評価としきい値の分析

テストセット中の入力語とする 30 種の料理全てに対して類似度ランキングを生成した．類似度ランキングの生成は，拡充していない知識グラフと，$U_{rate}(c, m)$ に関するしきい値 θ に基づいて拡充した知識グラフに対して行った．θ は 0 から 0.28 まで 0.01 刻みに変化させ，調査結果からしきい値を決定した．θ の変化に対する，作成した類似度ランキングにおける似た料理全 57 種の平均順位，および拡充されたトリプルの数の変化を図 2 に示す．

θ が 0 から 0.03 に増加するにつれて平均順位は高くなっていき，$\theta = 0.03$ の時に平均順位が最高になった．$\theta > 0.03$ の区間では，θ が増加するにつれて緩やかに平均順位が低下する傾向が見られた．$\theta = 0$ として 7685 個全てのトリプルを知識グラフに拡充するよりも，$\theta = 0.03$ として使用率の低い材料を除外した 4035 個のトリプルを知識グラフに拡充した方が平均順位が高くなるということがわかる．拡充するトリプルを約半数削っているにもかかわらず平均順位は高くなっており，使用率の低い材料の情報を知識グラフに加えることが，類似語の推測性能に悪影響を与えることがわかる．料理の一般的でない材料情報によって，料理エンティティが特徴付けられたためだと考えられる．

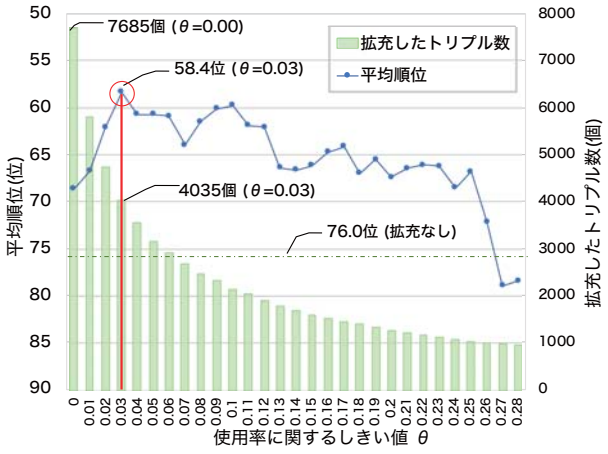


図 2: 類似度ランキングにおける平均順位と拡充トリプル数の θ に対する変化

そして，しきい値 θ が高くなるにつれて，拡充トリプル数の減少量が少なくなっている．このことから，使用率が高い材料の種類数に比べて，使用率が低い材料の種類数の方が多いことがわかる．

また，楽天公開データからのデータ拡充をしていない知識グラフでの結果は 76.0 位であったが，$\theta < 0.27$ においてはその値を上回っており，拡充の有無による差が見られる．

表 2: 類似度ランキングにおける類似語の順位の平均・標準偏差

	平均順位 (位)	標準偏差 (位)
拡充あり ($\theta = 0.03$)	58.4	76.7
拡充なし	76.0	68.1

表 3: 拡充結果の詳細 ($\theta = 0.03$)

構築された知識グラフの総トリプル数	15530 (個)
楽天レシピを用いて拡充したトリプル数	4035 (個)
材料情報を拡充した料理の種類数	573 (種)
拡充した料理の平均追加トリプル数	7.0 (個)

以上の調査から θ を，平均順位が最も高くなる 0.03 に決定して拡充を行った．拡充前後の平均順位，標準偏差を表 2 に示す．拡充後の平均順位の値が拡充前に比べ 17.6(位) 上昇しており，拡充の効果が見られる．一方，ランキング対象とした料理エンティティが 513 個であることを考慮すると，58.4 位と

いう平均順位はさほど高精度な結果ではないと考えられる．拡充結果の詳細を表 3 に示す．結果として楽天公開データから，4035 個のトリプルを知識グラフに拡充した．

4.3 類似度ランキングの実例

類似度ランキングの実例を示し，類似した料理が想定通りに推測出来た例とそうでない例での傾向の差異について述べる．

表 4: 「ボルシチ」に関する類似度ランキング

順位	料理名
1	◆ミネストローネ
2	ヴィシソワーズ
3	ハヤシライス
4	シチー
5	◆ビーフストロガノフ
6	カレーライス
7	ポトフ
8	クリームシチュー
.....	.....

まず，類似した料理が想定通りに推測出来た例として,「ボルシチ」に関する類似度ランキングから，上位 10 位までを抜粋したものを表 4 に示す．表 4 内で太字で示されている「ミネストローネ」と「ビーフストロガノフ」は，テストセット上で「ボルシチ」に類似した料理として結びつけられた料理である.「ミネストローネ」は 1 位,「ビーフストロガノフ」は 5 位に順位付けられており，想定通りの推測結果が出ている．上位 10 位以内に順位付けされている他の料理についても，煮込み料理が主に並んでおり，概ね似ていると思われる料理が多い．

表 5: 「トルティージャ」に関する類似度ランキング

順位	料理名
1	バカリャウ・ア・ブラース
2	オリヴィエ・サラダ
3	フラットブレッド
4	フォカッチャ
5	ビリヤニ，ザルツブルガーノッケルン
7	マギリッツァ，けんちん汁
.....	.....
47	◆オムレツ，他 22 種
.....	.....
133	◆卵焼き，他 7 種
.....	.....

反対に，類似した料理が上手く推測出来なかった例として,「トルティージャ」に関する類似度ランキングから，一部を抜粋したものを表 5 に示す．表 4 と同様に,「オムレツ」と「卵焼き」はテストセット上で「トルティージャ」に類似した料理として結びつけた料理である．ランキングにおいて「オムレツ」は 47 位,「卵焼き」は 133 位に順位付けられており，類似した料理を想定通りに推測出来ていない．上位に順位付けられている料理も，サラダや汁物，パンなどが見られ，似ていると思われる料理が少ない．

「ボルシチ」と「トルティージャ」の類似度ランキングを見比べてみると,「トルティージャ」の類似度ランキングには同率に順位付けされている料理が多い傾向にあるということがわかる.「トルティージャ」の類似度ランキングを見ると，5 位,7 位,47 位,133 位には同率に順位付けされている料理エンティティが存在する．この原因として考えられるのは，定めたベクトルが持つ情報量の少なさである．表 6 に,「ボルシチ」と「トルティージャ」，そしてテストセット上でこの二つの料理と結びつけた料理エンティティを表現するベクトルの要素の和を示す．料理エンティティを表現するベクトルの要素の和は，結びつく他エンティティの数を表す.「ボルシチ」とそれに紐づけた料理エンティティのベクトルの要素の和に比べ,「トルティージャ」とそれに紐づけた料理エンティティのベクトルの要素の和は小さい傾向にあることがわかる.「トルティージャ」やそれに紐づけた料理エンティティを表すベクトルに，他エンティティとの差を表す情報を十分に組み込めておらず，類似性という点でも，単純なコサイン類似度では差がつかない料理が同率順位に並んでいるのだと考えられる．

表 6: 料理エンティティを表すベクトルの要素の和

ボルシチ	27	トルティージャ	7
ミネストローネ	24	オムレツ	11
ビーフストロガノフ	27	卵焼き	20

5. おわりに

未知の属性の推測にむけて，今後は構築した知識グラフ上における関係を推測する手法の確立を目指す．またエンティティ間の接続関係だけでなく，プロパティなど他の情報を考慮した推測が効果的かどうか検証する．得られた推測結果を応答生成に反映させる枠組みについても検討する必要がある．

謝辞

本研究では，楽天株式会社が国立情報学研究所の協力により研究目的で提供している「楽天公開データ」を利用した．

参考文献

[Angles 08] Angles, R. and Gutierrez, C.: Survey of graph database models, *ACM Computing Surveys*, Vol. 40, No. 1, pp. 1–39 (2008)

[高橋 07] 高橋 潔考, 鈴木 遼, 下村 芳樹, 舘山 武史, 吉岡 真治, 武田 英明 : Web 情報を用いた設計知識情報データベースの拡充手法, 横幹連合コンファレンス予稿集, Vol. 2007, pp. 45–45 (2007)

[大塚 13] 大塚 嗣巳, 駒谷 和範, 佐藤 理史, 中野 幹生 : データベース検索音声対話システムにおける店舗属性値取得のための質問生成, 人工知能学会第 27 回全国大会 (2013)

[大野 18] 大野 航平, 武田 龍, ニコルズ エリック, 中野 幹生, 駒谷 和範 : 対話を通じた未知語のクラス獲得に向けた暗黙的確認の提案, 人工知能学会論文誌, Vol. 33, No. 1, pp. 1–10 (2018)

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

子どもを対象とする雑談対話システムにおける発話理解と感情生成

Utterance understanding and emotion generation in a dialogue system for children

山本 賢人[*1] 大村 俊哉[*2] 根本 凌[*2] 和田 史織[*1] 杉本 徹[*2]
Kento Yamamoto Syunya Omura Ryo Nemoto Shiori Wada Toru Sugimoto

[*1] 芝浦工業大学大学院 理工学研究科
Graduate School of Engineering and Science, Shibaura Institute of Technology

[*2] 芝浦工業大学 工学部
College of Engineering, Shibaura Institute of Technology

We propose a dialogue system for children with emotions. In this paper, we focus on utterance understanding and emotion generation in this dialogue system. In utterance understanding, we extract utterance intention and focus. Machine learning based on utterances collected from college students gives an accuracy of about 70% for utterance intention analysis and about 90% for focus extraction for children's utterances. In emotion generation, we deal with two types of emotion: short emotion and mood. The type of response is affected by mood, and short emotion is expressed as a facial expression. Regarding expressions of emotion, college students judged about 60% of emotions generated in dialogue as valid, but we could not confirm their usefulness in dialogue with children.

1. はじめに

近年，雑談対話システムの研究やビジネス利用が盛んである．たとえば，NTT ドコモ社の「しゃべってコンシェル」，ソフトバンク社の「Pepper」が例として挙げられる[東中 2014]．また，子どもを対象とした対話システムの研究として「たけまるくん」が存在する[西村 2004]．

一方で子どもが対話システムを利用する場合，子どもが退屈せずに楽しめるための話題や機能の充実といった課題が考えられるが，このような課題に焦点を当てた研究は少ない．

そこで我々はシステムの対象年齢を 7〜12 歳程度と仮定し，子どものユーザとクイズや石取りゲーム，雑談を楽しむことができるシステムの開発を目指している．クイズや石取りゲームといった子ども向けの対話の内容に加えて，システムに感情を持たせることや強化学習を行い子どもに適応することで，子どもが退屈せず利用できるようにする．

本稿では，この子どもを対象とする雑談対話システムにおける発話理解と感情生成手法に焦点を当て評価と考察を行う．

2. システムの概要

提案するシステムの処理の流れを図 1 に示す．

ユーザが音声による入力を行うと，発話理解部は入力結果から発話内容を解析し，発話意図や焦点などの情報を抽出する．

そして感情更新部では，発話理解で得られた結果をもとに感情の更新を行う．本研究では感情の概念をシステムの情緒と気分の二つに分けて定義する．得られた情緒に基づき，キャラクターの表情を出力する．また得られた気分に基づきシステムのいくつかの応答候補に対してその応答のスコアを増加させる．

一方でクイズ出題部では発話理解部で得られた現在の対話状況に応じて次にクイズとして出題する問題文の選択や，クイズの正誤判定を行う．

連絡先：山本賢人，芝浦工業大学大学院 理工学研究科，
〒135-8548 東京都江東区豊洲 3-7-5
E-mail: al14097@shibaura-it.ac.jp

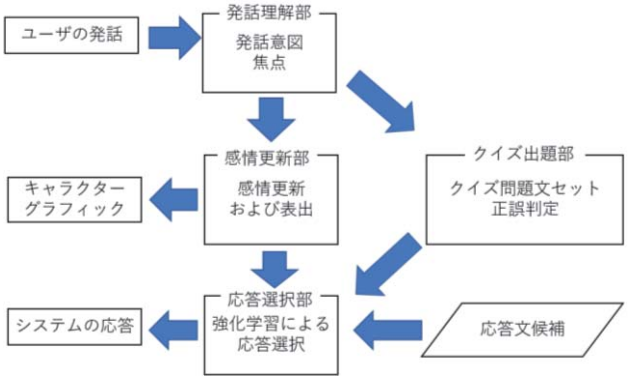


図 1. システムの処理の流れ

最後に応答選択部で応答文の選択を行う．本研究では現在の対話の状態をタスクとフェーズの組として表現し，それらに加えシステムの気分，発話行為タイプ，キーワードが含まれているか，ユーザの沈黙時間等に基づいて複数の応答文の候補のスコアリングを行い，スコアが最大の応答候補を選択する．ここでタスクとは，雑談・クイズ中・石取ゲームのいずれかである．一方，フェーズとはタスクが行われている・中断している・もう一度行うか現在確認中のいずれかである．

スコアの値は現在の状態に対しユーザの沈黙時間や相手を褒める内容や貶す内容が発話に含まれているか等を報酬とした強化学習により調整される．

最後に応答文を音声合成して出力する．

3. 発話理解手法

3.1 発話意図および焦点情報の抽出

(1) 発話意図解析

発話意図は発話行為タイプと属性の組で表す．発話行為タイプはその発話がどのような意味であるかを大まかに表す．一方属性は発話行為タイプが指し示す具体的な内容である．発話行為タイプは[Meguro 2010]が雑談対話システム用に定めた 33 種類の発話行為タイプを参考にし，後述する発話収集の実

験での発話内容を踏まえつつ本システムに合わせて 18 種類定義した. このうち 4 種類はシステムの発話のみに付与されるため, ユーザの発話に付与される発話行為タイプは 14 種類である. 発話行為タイプの例を表 1 に示す.

表 1. 発話行為タイプおよび焦点の例

発話文	発話行為タイプ	焦点
僕の誕生日は 3 月 2 日だよ.	陳述	誕生日, 3 月 2 日
寝たことありますか.	質問	寝る, ある
やらない.	質問返答. 否定	(無し)

発話行為タイプの付与は LIBLINEAR を用いてロジスティック回帰で行う. 属性は, 各発話行為タイプに対応した品詞の単語を形態素解析の結果から抽出する.

(2) 焦点解析

焦点とは発話の中心となる語であり, 名詞(句)と述語の組み合わせと定義する. 述語は動詞, 形容詞, 名詞(句)のいずれかである. なお名詞または述語どちらか一方しか含まれない場合はそれだけを抽出する. 焦点の例を表 1 に示す. 発話への焦点情報の付与は, CRFsuite を用いて形態素単位の系列ラベリングで行う.

3.2 発話データの収集および学習

(1) 学習に用いる発話の収集

発話意図解析および焦点解析の学習を行うため発話を収集した. 大学生に子どもを演じてもらい, システム役の人間と実際の対話を想定した模擬対話を行い 9 人から合計 563 発話を収集した. 発話文は人手で書き起こしを行い, 発話行為タイプと焦点情報を付与した.

(2) 発話意図解析に用いる素性の決定

発話意図解析の学習に用いる素性の決定を行った. 素性の候補と最終的な使用の有無を表 2 に示す.

表 2. 発話意図解析で用いる素性の候補

素性の種類	使用の有無
単語および品詞 n-gram	1,2,3-gram
何発話分の n-gram を使用するか	ユーザの発話と直前のシステムの発話
ユーザの発話の文字数	使用
直前のシステムの発話行為タイプ	不使用
直前のシステムの発話に焦点が含まれているか	不使用
ユーザの発話の形態素解析結果に JUMAN の 22 種類の意味カテゴリや 4 種類の固有表現情報が含まれているか	使用

素性の組み合わせは, 現在得られている最も正解率の良い組み合わせに新しい素性を加えて正解率を調べ, 正解率が向上した場合その素性を加えることを繰り返した. 素性は表 2 の上から順に加えた. 表 2 に示す素性の組み合わせで最高 0.701 の正解率が得られた. 正解率は学習データの発話のうち, LIBLINEAR が出力する確率値が最大の発話行為タイプと正解の発話行為タイプが一致した発話の割合である.

なお LIBLINEAR のアルゴリズムは L2 正則化 primal を使用し, パラメータはデフォルト値を使用した. また, 素性のスケーリングは行わなかった. 正解率を調べる際には 10 分割交差検定を用いた.

(3) 焦点解析に用いる素性の決定

焦点解析の学習に用いる素性の決定を行った. 素性の候補と最終的な使用の有無を表 3 に示す.

表 3. 焦点解析で用いる素性の候補

素性の種類	使用の有無
単語 n-gram	1,2gram
品詞 n-gram	1,2,3gram
直前のユーザとシステムの発話行為タイプ	使用
直前のシステムの発話に焦点が含まれているか	不使用
ユーザの発話の文字数	使用
発話文中での形態素の位置を正規化した値*1	使用
ユーザの発話の形態素解析結果に JUMAN の 22 種類の意味カテゴリや 4 種類の固有表現情報が含まれているか	不使用

*1 $\frac{\text{発話文中での形態素の位置}}{\text{発話文の形態素数}} * 10$

素性の組み合わせの求め方は発話意図解析と同様である. ただし評価基準は焦点の F 値および再現率を用いた. F 値がほぼ等しい場合は再現率が高いものを選択した. 表 3 に示す素性の組み合わせで 0.688 の再現率が得られた.

なお内部アルゴリズムおよびパラメータはデフォルト値を使用し, 5 分割交差検定で調べた.

4. 感情更新手法

4.1 感情生成モデル

[目良 2010]では, 感情の概念を情緒, 気分, 表情の 3 つに分けて定義している. 情緒は瞬間的に生じる短くて強い感情である. 気分は生起した情緒や内的状態に起因して生じる弱いながらも長く持続する感情である. 表情は情緒や気分などが身体を通じて表出されるものである. 本稿では, 感情の概念をシステムの情緒と気分の 2 つに分けて定義する. 情緒と気分は, Russel の感情円環モデル[Russel 1980]を用いて「快-不快」を表す好感度, 「覚醒-眠気」を表す覚醒度の二次元平面上の実数値の組として表現する. また, 極座標ベクトルの方向および大きさをそれぞれ情緒および気分の種類と大きさとする. 本研究で扱う情緒の種類を表 4 に示す.

表 4. 生起する情緒の種類

	覚醒	眠気
快	喜び	平常
不快	怒り	悲しみ

4.2 好感度の計算

最初にユーザの発話文から名詞, 動詞, 形容詞, 副詞を抽出する. 抽出した語の好感度データを実数値で取り出し, その平均値をその発話文における好感度とする. 好感度データには, 単語感情極性対応表[高村 2006]を用いる. この表は, ある単語が一般的に良い印象を持つか, 悪い印象を持つかを-1 から+1 の実数値で表したものである.

4.3 覚醒度の計算

覚醒度はシステムがユーザの発話に興味を持つかどうかで判定する. システム自身の好き嫌いやユーザの発話行為タイプ, クイズや石取ゲームを連続して続けた回数に応じてスコア付けを行い-1 から+1 の実数値を決定する.

システム自身の好き嫌いは, システムのプロフィールとして好きなもの, 嫌いなものを登録しておき, ユーザの発話に好きなものの語が含まれればシステムは興味を持ち覚醒度が上がる. 嫌いなものの語が含まれれば覚醒度が下がる.

ユーザの発話行為タイプが自己開示や情報提供などを意味する陳述である場合は, システムは興味を持ち覚醒度が上がる.

クイズやミニゲームを連続して続けた場合にも覚醒度は上がるが，すぐにやめてしまった場合には覚醒度は下がる．また，長く続けた場合にも飽きが来ると考え覚醒度は下がる．

4.4 情緒および気分の更新

情緒と気分を以下の式で更新する．まず 4.2 節，4.3 節の手法で好感度 Fr および覚醒度 Ar を求め初回の情緒$\mathrm{E}_1 = \binom{\mathrm{Fr}}{\mathrm{Ar}}$を決定する．次に，気分Mを決定する．初回は$\mathrm{M}_1 = \mathrm{E}_1$とする．2 回目以降は 1 回目と同様にFrとArを求め，以下の式により情緒E_nを更新する．

$$\mathrm{E_n} = (1-\mathrm{t})\binom{\mathrm{Fr}}{\mathrm{Ar}} + \mathrm{tM_{n-1}} \qquad (\mathrm{n} \geq 2)$$

tはどれだけ現在の気分を反映させるかの定数であり今回は 0.5 とした．気分の更新方法は生起した情緒の種類によって以下の二つに分けられる．

1. 生起した情緒の種類が直前の情緒の種類と異なる場合:

$$M_n = E_n$$

2. 生起した情緒の種類が直前の情緒の種類と同じ場合:

$$M_n = \frac{\alpha}{2}\left(M_{n-1} + E_n\right) (\alpha\text{: 気分の減衰率})$$

以上により情緒および気分を更新する．

4.5 情緒に応じた表情の生成

生起した情緒はシステムの表情として出力される．[中村 1996]では人類に共通していると考えられる表情の特徴をまとめている．本研究ではこの特徴をもとに表情の作成を行った．

4.6 気分に応じた応答戦略

システムの現在の気分に応じ，いくつかの応答に対してその応答の選択されやすさを変化させる．システムの気分が良いときはシステムの方から積極的に話すようになると考え，システムの自己開示，話題に基づく応答，オープンクエスチョンの応答をしやすくなるようにスコアを増加させる．システムの気分が悪いときは，システムは消極的になると考え，傾聴や当たり障りのない応答をしやすくなるようにスコアを増加させる．スコアの増加量は現在の気分M_nの好感度と覚醒度の二乗和の平方根により求める．

5. システムの実装および評価実験

5.1 プロトタイプシステムの実装

本研究のシステムのプロトタイプを作成した．このプロトタイプに用いたキャラクターの喜び，怒り，悲しみ，平常時での発話状態のグラフィックを図 2 に示す．



喜び　　怒り　　悲しみ　　平常(発話時)

図 2. キャラクターの各感情のグラフィック

また，今回は音声認識を用いずユーザが話した音声をオペレータが入力する形で対話を行った．

クイズは子どもが興味を持つと考えられる話題の問題を 23 問人手で子どもに合わせた言葉遣いで作成した．

5.2 発話理解手法および感情生成手法の評価実験

前述したプロトタイプを用いて小学 2 年生 3 人，5 年生 2 人と対話を行った．対話では感情を表出するシステム，しないシステムそれぞれと各 7 分間対話を行い，対話するシステムの順番はランダムに入れ替えた．合計 244 発話を収集した．ユーザとシステムの対話例を表 5 に示す．

表 5. 対話例

番号	発話者	発話文
1	システム	はじめましてボクの名前はクリームだよ，さっそくだけどクイズか石取ゲームやらない，それとも僕とお話しする?
2	ユーザ	石取.
3	システム	石取りゲームは1から数を数えていって先に21を言ったほうが勝ちだよ．1回で3まで数をふやすことができるよ．さいしょはボクからスタートだよ．じゃあ 1，2.
…		
4	ユーザ	21.
5	システム	おめでとう，君の勝ちだよもう一回やる？
6	ユーザ	もう一回やる.
…		
7	システム	ボク，チョコレートが大好き.
8	ユーザ	僕はふつう.
…		
9	ユーザ	クイズ.
10	システム	それでは問題です，あさごはんによくでる，ねばねばしてい大豆からできた食べ物は何でしょう，1 番とうふ，2 番なっとう，3 番ドーナツ.
11	ユーザ	2 番.

最初に 1 のようにシステムから発話が行われる．2 から 6 は石取ゲームの発話であり，7 から 8 は雑談中の発話，9 から 11 はクイズ中の発話である．

(1) 発話理解の精度

3.2 節で述べた大学生の発話データを学習データとして，LIBLINEAR と CRFsuite の学習を行った．その後プロトタイプを使用して子どもから得た発話データをテストデータとして与え適合率および再現率を求めた．発話意図解析の適合率および再現率を表 6 に，焦点抽出の適合率および再現率を表 7 に示す．

表 6. 発話行為タイプごとの適合率および再現率

発話行為タイプ	適合率	再現率
陳述	0.456（21/46）	0.750（21/28）
質問	0.846（33/39）	0.804（33/41）
質問返答.肯定	0.875（14/16）	0.560（14/25）
質問返答.否定	1.000（02/02）	0.400（02/05）
質問返答.その他	0.823（14/17）	0.875（14/16）
話題変更		0.000（00/02）
相槌	0.470（08/17）	0.615（08/13）
クイズ.回答	1.000（20/20）	0.645（20/31）
石取	0.861（62/72）	1.000（62/62）
定型	0.000（00/02）	
要求	0.000（00/01）	
+評価		

-評価	0.000 (00/03)	
その他	0.333 (03/09)	0.142 (03/21)
平均	0.725 (177/244)	

表 7. 焦点抽出の適合率および再現率

ラベル	適合率	再現率
焦点	0.717 (0160 / 0223)	0.824 (0160 / 0194)
非焦点	0.959 (0802 / 0836)	0.927 (0802 / 0865)
平均	0.908 (0962 / 1059)	

表 6 に関しては，発話行為タイプの出現頻度に差がみられ，出現頻度が高い発話行為タイプほど再現率も高い．これは学習データにも同様の傾向がみられ，学習データの量が十分であるため正しく判別が出来ていると考えられる．一方で話題変更，定型，要求，+評価，-評価は出現数が少ないか全く出現していないため分類精度を調べられなかった．これらは学習データにもほとんど出現しないため，発話行為タイプの種類自体の見直しや収集方法を工夫する必要があると思われる．

表 7 に関しては，焦点の再現率が学習データの 0.688 に比べ向上している．これは，子どもが話す文に複文や複雑な係り受け関係が少ないため，文字数や形態素の位置の素性がより有効に働いたためと考えられる．

学習データおよびテストデータの形態素数の分布をそれぞれ図 3，図 4 に示す．

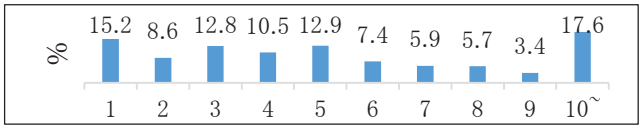


図 3. 学習データ(大学生)の形態素数

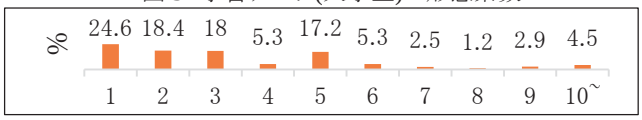


図 4. テストデータ(小学生)の形態素数

小学生の発話は形態素数が 10 以上の発話が少ないことが分かる．

(2) 感情生成手法の有効性の評価

対話後に各システムについて 4 段階(1~4)で評価してもらった．評価内容および各システムの平均値を表 8 に示す．

表 8. 各システムのアンケート評価結果

アンケート項目	感情あり	感情なし
上手に会話できていたか	2.8	3.0
話していて面白かったか	3.0	3.0
また話してみたいか	3.0	3.2
仲良くなれそうだったか	3.0	3.0

アンケートの結果から，感情を表情として表出するシステムとしないシステムで，あまり差異は見られなかった．これは実際に実験の様子を観察して，子どもが画面を見ずに別の方を見ていたり，画面を見ていても字幕を読むことに集中していたことから，システムの表情の変化に気づかなかったのではないかと推測される．従って，システムの表情の変化を分かりやすくするために，表情と共に背景色を感情に合わせた色に変化させるなどの工夫をする必要があると考えられる．

(3) 感情生成手法の妥当性の評価

大学生の被験者 7 人に，子どものユーザとシステムの対話ログを読み，システムの発話時に生成される情緒が妥当かを 5 段階で評価してもらった．評価は，ユーザの発話に対するシステムの発話を 1 対話として合計 36 対話に対して行った．被験者が選択した評価のうち，最も多かったものをその対話の評価とし，各評価に割り当てられた対話の数とその割合を表 9 に示す．

表 9. 各評価に割り当てられた対話数とその割合

評価	1 妥当である	2 まあまあ妥当である	3 どちらとも言えない	4 あまり妥当でない	5 妥当でない
対話数	16	6	5	5	4
割合	44%	17%	14%	14%	11%

1 および 2 の評価で約 61%の割合となった．4 および 5 の評価となった対話には，ユーザ発話が質問なのに対し怒りなどの情緒が生成されている場合があった．

6. まとめ

本研究では子どもを対象とする雑談対話システムの提案を行い，実際にプロトタイプを構築し，発話理解の精度および感情生成の手法についての評価を行った．発話意図解析では約 7 割，焦点解析については約 9 割の正解率で分類が行えるという結果を得た．一方，感情生成については約 6 割の対話について生成された情緒が妥当という結果を得たが，子どものユーザに対する感情の表出の有用性は確認できなかった．

今後は発話検出や音声認識を組み込んだ発話理解部の開発や，感情表出の仕方の見直しを行う．またシステムのクイズの自動生成機能の実装や，強化学習による応答選択の最適化に関する評価実験を行う．

参考文献

[東中 2014] 東中竜一郎: 雑談対話システムに向けた取り組み，人工知能学会第 70 回言語・音声理解と対話処理研究会，2014.

[西村 2004] 西村竜一，西原洋平，鶴身玲典，李晃伸，猿渡洋，鹿野清宏: 実環境研究プラットホームとしての音声情報案内システムの運用，電子情報通信学会論文誌 J87-D-II(3) pp. 789-798，2004.

[Meguro 2010] Meguro, Toyomi, Minami Yasuhiro, Higashinaka Ryuichiro, Dohsaka Kohji: Controlling listening-oriented dialogue using partially observable Markov decision processes, Proceedings of COLING, pp. 761-769, 2010.

[目良 2010] 目良和也，市村匠，黒澤義明，竹澤寿幸:情緒計算手法と心的状態遷移ネットワークを用いた音声対話エージェントの気分変化手法，日本知能情報ファジィ学会誌 22(1) pp. 10-24，2010.

[Russel 1980] J.A. Russel: A circumplex model of affect, Journal of Personality and Social Psychology 39(6), pp. 1161-1178, 1980.

[高村 2006] 高村大也，乾孝司，奥村学: スピンモデルによる単語の感情極性抽出，情報処理学会論文誌 47(2) pp. 627-637，2006.

[中村 1996] 中村真: 表情とコミュニケーション，繊維製品消費学 37(1) pp. 4-9，1996.

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

テンプレートを用いた疑問文生成による対話応答文DBの拡充

Augmentation of Dialogue Database by Generating Interrogative Sentences Using Templates

長内洋太 *1 Yota Osanai　尾形朋哉 *1 Tomoya Ogata　小町守 *1 Mamoru Komachi　下川原（佐藤）英理 *1 Eri Sato-Shimokawara　和田一義 *1 Kazuyoshi Wada
山口亨 *1 Toru Yamaguchi　高谷智哉 *2 Tomoya Takatani

*1首都大学東京 Tokyo Metropolitan Univercity　*2トヨタ自動車株式会社 TOYOTA MOTOR CORPORATION

In recent years, there are many dialogue systems selecting an appropriate response from a dialogue database. However, when the number of sentences in the database is small, it may not contain an appropriate sentence in an open domain setting. Therefore, it is desirable to prepare a large number of candidate sentences and to fully expand the dialogue database beforehand. In this research, we generate templates from handwritten responses from actual dialogue logs to augment interrogative sentences for a dialogue database.

1. はじめに

近年，コンピュータが自然言語を用いて人と会話を行うための対話システムの研究が行われている．対話システムには，大別して，経路案内や Web 検索などの特定の目的のために発話，応答を行う task-oriented なもの [Williams 07] と，特定の目的がない，主に雑談を行う non-task-oriented なもの [Wallace 09] の 2 種類がある．

non-task-oriented な対話システムにおいて，事前に応答の候補となる文を生成，または収集し，データベースに大量に蓄えておくことで，ユーザ発話に適切な応答を文選択によって出力するという手法が古くから研究されている [Higashinaka 06][柴田 09]．この手法は，応答文を出力する際，フィルタリングやスコアリングを用いることによって，非文を出力しづらいという強みがある．しかし，データベース内にユーザ発話に対する応答文としてふさわしい文が存在しない場合，適切でない文を選択し，応答文として出力してしまうという問題が存在する．そのため，応答文のデータベースは様々なユーザのあらゆる発話に対応できるよう，応答文となり得る様々な応答文を大量に保持していることが望ましい．

また，比較的小規模な日本語対話データや，Twitter などのスラングやノイズの多いデータセットを用いて生成された応答文は，それらを除外するためのフィルタリングに非常にコストがかかるという問題点がある．

そこで，本研究では，実際の対話ログから応答となる疑問文を手書きで作成し，テンプレート生成の観点から分類する．その後，日本語形態素解析器 JUMAN++の辞書情報を外部リソースとして用いて，分類ごとにルールベースの手法を用いて作成したテンプレートを適用することで，文選択の選択肢となりうる候補文を簡易かつ大量に生成する手法を提案する．

本研究の貢献は，以下の通りである．

1. ユーザ発話に対して応答疑問文を人手で作成し，それらを応答可能性の観点から分類した
2. ユーザの 1 発話から，対話を続けるための日本語の対話応答候補文のテンプレートを作成した

連絡先: 長内 洋太，首都大学東京，osanai-youta@ed.tmu.ac.jp

2. 関連研究

テンプレートから日本語応答文を生成する研究として，加藤らの研究 [加藤 15] や山内らの研究 [山内 14] がある．

加藤ら [加藤 15] は，話題となる単語とともにユーザ発話内の感情を表現する語を抜き出し，話題語のカテゴリと感情の一致を考慮してテンプレートに挿入した．話題を一致させることは対話のロボット応答における違和感を低減することが示されたが，固有表現抽出の精度が悪いことや，感情語の活用や品詞を考慮していないことなどに問題があり，生成文の流暢性が低いという問題がある．本研究では，彼らのいう‘話題語’に着目し，どのような品詞が話題語に該当し，どのようなカテゴリであれば応答の生成にテンプレートを用いることができるかの分類を行い，自然な応答文が生成されるテンプレートを作成した．また，ユーザ発話への応答疑問文を事前に人手で作成し，単語を話題語として抽出すべきかどうかで分類した．

また，山内ら [山内 14] は，日本語文について，ある特定の分野に関する用語の情報が記述された用語データベースを用意し，ユーザとの会話の話題をその特定分野に誘導することで，テンプレートを用いた応答文生成を行なう．ただし，特定の分野の単語に対してのみ情報を所持しているため，他の分野の単語に対しては適切な応答文生成ができないという問題がある．そこで，本研究では，日本語形態素解析器 JUMAN++の辞書情報を用いて，ある分野の単語のみでなく，分野を限定せずに，日本語の応答疑問文を生成した．

3. テンプレートの生成

テンプレートによって応答疑問文を作成できるユーザ発話群の発見のため，対話データ中のユーザ発話の分類を行う．その後，応答疑問文を作成できるものに対して応答文を人手で作成し，作成した応答疑問文に対して，テンプレートを作成できる応答疑問文群発見のための類型化を行う．

応答疑問文の作成において，文脈を考慮する場合，応答疑問文の候補は多岐に渡る．したがって本研究では，文脈を考慮せず，ユーザの 1 発話のみを見るという制約のもとで応答疑問文を作成した．また，ユーザ発話のどの内容を受けた応答疑問文であるかを明確化するために，ユーザの使用した単語（見出

表 1: 各分類におけるユーザ発話の件数と例

分類	件数	ユーザの発話の例	作成した応答文
単語抽出が必要	733	**本**を読んだりラジオを聴いたりしてます。 特別な**習い事**はしてないです。	最近はどんな**本**を読まれましたか？ 何か**習い事**をしてみたいと思ったことはありますか？
単語抽出が不要	72	おはよう，今起きました。 ただいま帰りました。	おはようございます。今日は何をされるご予定ですか？ お帰りなさい、お疲れ様でした。
User-negative	125	ダメです、全く泳げません。 全く興味ありません、できません。	- -
User-question	54	あなたのお名前は？ はい、毎日してます。一緒にしませんか？	- -
単語抽出不可	150	そうですね。 うーん…。	- -
書き起こし文なし	66	-	-

し語）を一語以上使用することも制約として加えた．

以上の制約下で作成した応答疑問文を用いて，応答疑問文同士で類似した箇所を探し，テンプレートを作成する．

3.1 データセット

実際に用いる対話ログに関しては，先行研究 [下川原 16] で収集，編集したデータを扱う．このデータは，主にロボットが高齢者のユーザに対して質問を行い，ユーザがそれに返答をする雑談形式の対話ログである．ユーザの発話ログには，ユーザ発話を聞き取って書き起こされたものを扱う．本研究では，2014 年 6 月に収集した 6 ユーザの発話から各 200 文，計 1,200 文を抜き出し，それに対して分類を行い，疑問文を作成可能なユーザ発話に対して応答文を人手で作成した．

3.2 データセットの分類と応答疑問文作成

対話ログにおけるユーザ発話文の分析を行う．応答疑問文を作成するかどうかで場合分けし，それぞれに対しさらに分類を行う．応答疑問文の作成が可能である場合は，ユーザ発話から単語を抽出して応答疑問文を作成したか否かによって 2 つの分類に分かれる．疑問文の作成が不可，もしくは応答を作成すべきでないとき，これらは，‘ 単語の抽出が可能であるか不可であるかに関わらず，ユーザ発話が否定的な応答をしている ’，‘ 単語の抽出の可否に関わらず，ユーザ発話が疑問文である ’，‘ 抽出するべき単語がユーザ発話に含まれない ’，‘ ユーザ発話データが存在しない ’ の 4 つの分類に分かれる．

単語抽出が必要　ユーザ発話内に，ユーザとシステム間で今行われている会話の話題が読み取れる単語，主に自動詞が存在し，それを抜き出して用いることで応答疑問文が作成できる場合が該当する．

単語抽出が不要　主に ‘ おはよう ’ や ‘ ただいま ’，‘ ありがとう ’ などの挨拶や「言語行為の定型表現・運用上固着した語彙 [加藤 06]」，それにより応答が疑問文である必要がない場合などが，抽出の必要がない場合に該当する．

User-negative　ユーザが ‘ 嫌い ’，‘ 全くない ’ 等の語を含む否定的な発話をした場合が該当する．この場合，ユーザは 1 つ前でロボットが提示した話題に対して，会話の続行を望んでいないと推測できる．したがって，単語抽出によって疑問文の作成が可能な場合であっても，他の話題についての発話を行なった方が適切であると判断したため，疑問文を作成していない．

User-question　ユーザの発話が疑問文である場合が該当する．この発話に対する応答の作成には，ユーザやロボットのパーソナリティ情報や外部のリソース等から情報を取得する必要があり，ユーザ発話に含まれる単語をテンプレートに挿入して疑問文を作成することは適切ではない．

表 2: 各名詞の細分類内訳と例

細分類	該当する名詞の例	件数
普通名詞	服, メール, テニス	353
地名	日本, 東京, パリ	79
サ変名詞	会話, 経験, 予定	79
時相名詞	梅雨, この後, 最近	57
数詞	100, 何, 一	10
副詞的名詞	前, ところ	3
組織名	ユニクロ	1

単語抽出不可　感嘆詞のみであったり，聞き取りがうまくいかずに名詞等が途中で途切れている場合などの，主にユーザ発話に自動詞が存在していない場合が該当する．

書き起こし文なし　ユーザが実際に発話していない場合に加え，ノイズやユーザの声量の問題で，ユーザ発話が正しい文として書き起こされていない場合が含まれる．

以上の分類に基づき，‘ 単語抽出が必要 ’ と ‘ 単語抽出不要 ’ の応答疑問文を作成可能なユーザ発話に対して，疑問文を人手で作成した．各分類におけるユーザ発話の件数と，作成した応答を表 1 に示す．ユーザ発話における単語抽出を行う場合，ユーザ発話に含まれる単語を用いつつ応答を作成した．

3.3 抽出した単語の分類

テンプレートに挿入される頻度の高い品詞の特定のため，ユーザ発話の分類 ‘ 単語抽出が必要 ’ に対して作成した各応答文 733 件について，応答作成で抽出された単語の品詞ごとに分類を行う．ユーザ発話に含まれる 1 単語を抽出して作成した応答文について，日本語形態素解析器 JUMAN++（version 1.01）を用いて，抽出した単語の品詞分類を行った．

抽出した品詞を分類したところ，名詞 470 件（例：犬，ご飯，今日），動詞 153 件（例：起きる，食べる，行く），形容詞・形容動詞 110 件（例：静か，長い，若い）となり，抽出される単語の品詞は名詞が最も多かった．そのため，本研究では名詞に対するテンプレートを考えることにした．

名詞を用いて作成した応答文に対して，JUMAN++で解析した結果における，名詞の細分類，JUMAN++辞書における ‘カテゴリ’，‘ドメイン’ の両分類を用いることで，各名詞の属性付けを行う．ここで言及した JUMAN++のカテゴリとは，語の上位下位関係に基づくものであり，‘人’，‘動物’，‘植物’ 等 22 種存在する．ドメインは単語をオントロジー横断的に意味情報で区分したものであり，‘文化・芸術’，‘スポーツ’，‘健康・医学 ’ などの 12 種が存在する [黒橋 16]．

表 3: カテゴリ・ドメインの組の内訳と例 - 上位 10 件

カテゴリ名	ドメイン名	該当する名詞の例	件数
時間	-	昨日, この後	60
抽象物	-	天気, 流行	59
抽象物	家庭・暮らし	メール, 買い物	28
人工物-その他	家庭・暮らし	ゴミ, クーラー	23
人工物-食べ物	料理・食事	食べ物, 缶詰	23
人	家庭・暮らし	主人, 女の子	21
抽象物	文化・芸術	文化, 演奏	18
抽象物	スポーツ	テニス, スポーツ	15
人工物-その他	-	話題, ボールペン	13
動物	-	虫, ペット	13

作成した応答文のうち，名詞を抜き出して作成した応答文の名詞について品詞細分類を付与した内訳を表 2 に，カテゴリとドメインの組の出現頻度上位 10 件と該当する名詞の例を表 3 に示す．この中で，JUMAN++の解析結果において，名詞の解析候補が複数存在する名詞は，複数の分類のテンプレートに挿入することが考えられるため，それぞれの解析候補を別の名詞として考えて出現頻度を計算した．また，解析結果が一つであっても，複数のカテゴリやドメインを持つ単語に対しては，意味の詳細な絞り込みのため，その単語の持つ複数のカテゴリ，または複数のドメインの組み合わせを独立した分類として考える．また，カテゴリとドメインのどちらか，もしくはその両方を持たない語も存在した．

3.4 テンプレートの作成

ユーザ発話から，名詞を一つ抽出して挿入することで応答文となるテンプレートを作成する．

今回は，抽出した各名詞と述語の共起などは考えず，述語を各テンプレートに固定する形で作成した．このうち，作成できたテンプレートの該当する分類を表 5 に示す．表 5 において，`<word>`で示されるのが実際にユーザの発話から抜き出した単語である．

また，表 2 の‘サ変名詞’に該当する名詞は，それをする主体が必要であるという点で述語と扱いが類似しており，今回は挿入する名詞から除外している．

3.5 考察

内訳の上位に位置する，カテゴリが‘時間’や‘抽象物’である場合，ドメインが‘家庭・暮らし’である場合などの非常に広範に渡る分類では，カテゴリとドメインに加えて，名詞の細分類を用いても抽出した名詞の情報を絞りきれず，その分類に該当する名詞が適用できるテンプレートの考案が難しい場合がある．そのため，さらに細かい名詞の区分が必要である．

カテゴリ‘人’の分類では，‘妻’，‘嫁’などの名詞がよく見られた．これらの単語は，ユーザが発話者である場合と，システム発話の場合において名称が変わる名詞である．今回の手法ではこれらの単語への対応は難しいが，人称名詞の辞書を用いて活用することで，テンプレート作成が可能になると考える．

また，カテゴリ‘抽象物’に該当する名詞に見られるように，適切な述語が，抽出した名詞ごとに様々である分類において，述語をテンプレートに固定する今回の手法は適していない．このような場合，抽出した各名詞と共起しやすい述語を同時に挿入するテンプレートを作成することで，適切な出力文が得られる可能性がある．

表 3 において，‘家庭・暮らし’のドメインが頻出であることは，データセットが高齢者とロボットの日常的な対話ログであることに起因すると考えられる．

4. テンプレートを用いた応答文生成実験

3.4 節で考案したテンプレートに対して，ユーザ発話文から抽出した単語を挿入して応答文を生成し，自然な応答文が出力されるかどうかを検証する．今回は，表 4 に示す 3 つの分類のテンプレートに対して，対話ログデータ内の全単語を挿入して応答文を生成し，カテゴリのみ・ドメインのみ・両方を用いた場合の 3 つの場合において検証を行った．全体として，3 つの分類に属する名詞 118 語から，応答候補文 557 文が生成された．テンプレートに単語を挿入した出力例を表 5 に示す．

表 5 に示した例のうち，カテゴリとドメインの両方を用いて単語を挿入した場合，出力は非文ではなく，簡潔かつ応答文の範疇を逸脱していないといえる．また，カテゴリのみもしくはドメインのみを用いた場合の自然な文の出力割合が，該当するカテゴリ，ドメインによって大きく異なることがわかる．例として示した分類のうち，‘抽象物’というカテゴリのみを用いた場合は，この区分が非常に広範であるため，作成したテンプレートに適する単語を抽出できていないことが問題である．ドメイン‘料理・食事’については，ドメイン側が広範な区分であることと，‘冷蔵’や‘煮（る）’のような事態性名詞が普通名詞として挿入されることが問題となっていた．

しかし，広範な分類の名詞を挿入した場合など，依然として文として意味が通じないものが生成された．今回の設定では，全体の 8.98 %の出力が適切でない応答文であり，挿入した単語によって，その単語を挿入した応答文全てが不自然である場合と，ある特定のテンプレートに挿入した場合のみ不自然な文が出力された場合が存在した．適切でない出力の事例としては，以下の 3 つが見られた．

挿入する単語の粒度の問題　表 5 の‘スポーツの他に何かスポーツはされるのですか?’等の出力に見られる，該当の分類に属する単語同士の意味的な粒度が揃っていない場合である．この原因として挙げられるのは，カテゴリまたはドメインの意味的なばらつきが原因で，そのテンプレートに挿入するのにふさわしくない単語が挿入されてしまうことである．この問題に対しては，異なる辞書を用いることによって，単語の分類をさらに細かく行うことが必要がある．この問題については，テンプレート自体に含まれる単語や，それに類する単語に，フィルタをかけてテンプレートに挿入しない等の対策が必要である．

形態素解析の誤りによる問題　JUMAN++の解析結果が実際の単語の意味と異なる解析を行なった場合である．例としては，表 5 の細分類‘地名’における，‘将棋’のような単語である．この問題は，テンプレート作成の段階での対処が難しいため，異なる出力を行なった場合に，順次人手で JUMAN++辞書を修正，拡張する等の対応が望まれる．

外部知識や環境情報の問題　ロボットの応答が発話者にとって当然の事柄であり，会話の進行を妨げてしまう場合も存在する．例としては，日本人に‘日本にはよく行かれるのですか?’等の応答を出力する場合である．ただし，この場合を適切でないと判断するのは難しい．なぜなら，この分類の不自然な出力文は，ユーザやロボットの立ち位置や周囲の環境などの状況によって，自然な文になりうるからである．この場合，応答候補文の生成としては問題ないが，実際に候補文の中から応答文を選択する際に，ユーザの出身がどこであるかなどのユーザの登録情報や，ユーザとロボットが今どこで会話しているかなどの対話環境といった，追加情報の取得が必要になる．

表 4: 各分類における出力の統計

分類			カテゴリ・ドメイン			カテゴリのみ			ドメインのみ		
細分類	カテゴリ	ドメイン	単語数	出力文数	正文割合	単語数	出力文数	正文割合	単語数	出力文数	正文割合
地名	-	-	79	395	89.9	-	-	-	-	-	-
普通名詞	抽象物	スポーツ	15	90	98.9	296	1,939	9.3	16	96	92.7
	人工物-食べ物	料理・食事	24	72	87.5	38	114	61.4	61	183	38.8

表 5: 作成したテンプレートと対話ログから抽出した単語を用いた出力例.
（文頭に‘*’のあるものは適切でない出力例，‘?’のあるものは疑問の残る，または議論の必要性のある出力例）

分類			作成テンプレート	出力
細分類	カテゴリ	ドメイン		（**ゴシック**が挿入単語）
地名	-	-	<word>には行ったことはありますか？ <word>にはよく行かれるのですか？ <word>と聞くと何を思い浮かべますか？ ご自宅から<word>へはどう行かれるのですか？ <word>へ行ってみたいと思いますか？ <word>でよく行くお店はありますか？	*将棋に行ったことはありますか？ ?**日本**にはよく行かれるのですか？ **横須賀**と聞くと何を思い浮かべますか？ ご自宅から**新宿**へはどう行かれるのですか？ **パリ**へ行ってみたいと思いますか？ **新宿**でよく行くお店はありますか？
普通名詞	抽象物	スポーツ	<word>はよくされるのですか？ <word>の他に何かスポーツはされるのですか？ <word>の観戦に行かれたことはありますか？ <word>はいつ始められたのですか？ <word>を始めたきっかけは何だったのですか？ <word>をしていて楽しい時はどんな時ですか？	**テニス**はよくされるのですか？ ***スポーツ**の他に何かスポーツはされるのですか？ **サッカー**の観戦に行かれたことはありますか？ **ジョギング**はいつ始められたのですか？ **体操**を始めたきっかけは何だったのですか？ **野球**をしていて楽しい時はどんな時ですか？
	人工物-食べ物	料理・食事	<word>はよく食べるのですか？ <word>はお好きですか？ ご自分で<word>を作られたことはありますか？	**刺身**はよく食べるのですか？ **ご飯**はよく食べるのですか？ ?**食べ物**はお好きですか？ **ヨーグルト**はお好きですか？ ご自身で**漬物**を作られたことはありますか？ ご自身で **弁当**を作られたことはありますか？

5. おわりに

本研究では，ユーザの発話に対して人手で応答文を作成し，作成した応答文の単語を，日本語形態素解析器 JUMAN++の辞書におけるカテゴリやドメイン等の情報を活用することでテンプレートを作成した．ユーザの発話から文脈となる単語を抽出し，JUMAN++の辞書上で該当する各分類のテンプレートに挿入することで，その単語を使いつつ対話を続行するための文が得られることがわかった．

提案手法は，生成したテンプレートと単語の条件が合致すれば一定数の文が得られる一方，テンプレートを考案することが難しい単語や品詞においては，他の手法を用いた応答文の生成が必要になる．また，カテゴリとドメインの分類ごとにテンプレート数に偏りがあるため，一部のカテゴリやドメインにおいては十分な応答文が得られない問題や，カテゴリまたはドメインが非常に広範であるために，単語情報を絞り込めない場合，適切なテンプレートの作成が難しいという問題が存在する．

また，今回の手法では名詞のみに焦点を絞ったため，ユーザ発話が名詞を含まない場合を考慮できていない点が課題として残る．ユーザ発話が名詞を含まない場合には，今までの対話ログから会話の文脈を考慮しつつ，ユーザ発話に含まれる述語を抽出し，テンプレートに挿入することが考えられる．

今後は，提案手法に加えて，ユーザ発話から得られる情報のみならず，ロボットとユーザの位置関係や名前等のパーソナリティを利用したテンプレートによる応答生成と，意味的な観点からの客観的な評価を行う予定である．加えて，一つの名詞を抽出してテンプレートに挿入する手法において，挿入する名詞と関連性の高い述語を同時に挿入できるテンプレートを作成することで，さらに豊富な応答文を得る可能性についても探っていきたい．

参考文献

[Higashinaka 06] Higashinaka, R., Prasad, R., and Walker, M. A.: Learning to Generate Naturalistic Utterances Using Reviews in Spoken Dialogue Systems, *Proceedings of ACL*, pp. 265–272 (2006)

[Wallace 09] Wallace, R. S.: *The Anatomy of ALICE* (2009)

[Williams 07] Williams, J. D. and Young, S.: Partially Observable Markov Decision Processes for Spoken Dialog Systems, *Computer Speech & Language*, Vol. 21, No. 2, pp. 393–422 (2007)

[下川原 16] 下川原 （佐藤）英理, 篠田 遥子, 李 海妍, 高谷 智哉, 和田 一義, 山口 亨：高齢者と音声対話ロボットの雑談履歴の解析, *JRSJ*, Vol. 34, No. 5, pp. 309–315 (2016)

[加藤 06] 加藤 重広：日本語文法入門ハンドブック, 研究社 (2006)

[加藤 15] 加藤 和樹, 柴田 千尋, 田胡 和哉：文のテンプレートの学習および感情を考慮した会話文の生成, 情報処理学会第 77 回全国大会講演論文集, pp. 175–176 (2015)

[黒橋 16] 黒橋 禎夫：日本語形態素解析システム JUMAN++ version1.0 マニュアル (2016), http://lotus.kuee.kyoto-u.ac.jp/nl-resource/jumanpp/jumanpp-manual-1.0p2.pdf

[山内 14] 山内 祐輝, Neubig, G., Sakti, S., 戸田 智基, 中村 哲：対話システムにおける用語間の関係性を用いた話題誘導応答文生成, 人工知能学会論文誌, Vol. 29, No. 1, pp. 80–89 (2014)

[柴田 09] 柴田 雅博, 冨浦 洋一, 西口 友美：雑談自由対話を実現するための WWW 上の文書からの妥当な候補文選択手法, 人工知能学会論文誌, Vol. 24, No. 6, pp. 507–519 (2009)

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

会話によるニュース記事伝達のための発話意図分類とデータベースの構築

Utterance Intention Classification and Database Construction for Conversational News Delivery System

横山 勝矢 *1 Katsuya Yokoyama　高津 弘明 *1 Hiroaki Takatsu　本田 裕 *2 Hiroshi Honda　藤江 真也 *1*3 Shinya Fujie　林 良彦 *1 Yoshihiko Hayashi
小林 哲則 *1 Tetsunori Kobayashi

*1早稲田大学 Waseda University　*2本田技術研究所 Honda R&D Co.,Ltd.　*3千葉工業大学 Chiba Institute of Technology

In a human-human conversation, a listener frequently conveys various intentions explicitly/implicitly to the speaker with reflexive short responses. The speaker recognizes the intentions of these feedbacks and changes the utterance plans to make the communication more smooth and efficient. These functions are expected to be useful for human-system conversation also, but when human face the system they do not always give the same feedback as they did with human. We investigated the feedback phenomena of human users against our system which is designed to transfer a massive amount of information like news articles by spoken dialogue. First, user's intentions of feedbacks that can affect the behavior of the system were classified from the viewpoint of roles in the progress of conversation: presence/absence of a user's interest, comprehension state, release/keep turn, and so on. Then, using our news delivery conversation system, we gathered user's short responses, and labeled the intention through listening test by the subjects. We also attempted automatic identification of those intentions. As a result, in the current system, it is found that there are many feedbacks to convey doubt and automatic identification of them is possible stably, but there are not so many other feedbacks.

1. はじめに

実会話システム利用時における，システム発話に対するユーザのフィードバックの現象を分析するためのコーパス収集について検討する．

人同士の会話において，聞き手は，話し手の発話に対し，しばしば反射的な応答を行う．これらの応答は，発話の理解状態や発話内容への興味の程度など，聞き手の様々な状態を，話し手にフィードバックする．話し手は，これらのフィードバックをもとに，相手の理解が乏しければ情報を補足し，興味がなさそうなら話題を変えるなど，自らの発話計画を適宜修正し，聞き手の状態に合わせた発話を行うことになる．

こうした一連の処理を，人とシステムとの会話にも適用することで，従来の一問一答の枠組みを超えた，円滑で利便性の高い会話システムを実現できることが期待されている [Fujie 06, Kobayashi 13]．ここで，聞き手からのフィードバックは，必ずしも言語的に明示的な形でのみ表現されるとは限らず，抑揚や声色などに表れるパラ言語を伴った複雑な形で表現される [益永 14]．このため，こうした機能の実現には，自然なフィードバックを含む大規模な会話音声コーパスが必要となる．

会話における聞き手からのフィードバックを扱うためのコーパスの研究には，既に様々なものがある．牧野ら [牧野 17] は，人—人の会話における話者交代の現象を分析対象として，話者交代の際に起こる韻律情報と視線情報を調査するためのコーパスを作成した．荒木ら [荒木 17] は，雑談における会話内容に対するユーザの興味の有無を分析対象として，MMDAgent を用い，WoZ（Wizard of Oz）方式により対話データの収集を行った．井上ら [井上 17] は，エンゲージメント（興味や意欲による対話継続欲求度）を分析対象として，自立型アンドロイド ERICA[Inoue 16] を用い，WoZ 方式により，会話時の相槌，笑い，うなずき，視線などのデータを収集した．

これら，人—人の会話や，WoZ 方式のように，応答時に人が介在して収集したコーパスには，極めて自然なフィードバックが含まれ，研究対象としては興味深い．しかし，現状，実際の会話システムを使用したときのユーザの振る舞いとは乖離している可能性があり，システムへ組み込む機能を実現するための学習データとしては必ずしも適切ではない．

このような観点から，実際の自律システムとの対話を通じてデータ収録した研究もある．長澤ら [長澤 17] は，インタビューを行うシステムにおいて，ユーザの反応によって話題を掘り下げるか，話題を転換するかなどの対話戦略を決めるために，実際にロボットを用いた対話を行ってデータを収録し，ユーザの発話への積極性を 5 段階でアノテーションしている．

本研究においても，長澤らの研究と同様に，実システムの利用時におけるユーザの応答を調査対象とすることを試みる．現在我々が作成しているニュース伝達のための会話システム [高津 18a] を対象として，ユーザが実際にシステムとの会話時にどのようなフィードバックを行い，システムはどのようにそれを利用しうるかを検討する．システムからの提示情報に対するユーザの興味の有無，発話交代に関する働きかけ（発話権を取りたいか，継続したいかなど），システム発話の理解状態など，ユーザがフィードバックの発話に込めた，システムの振る舞いに影響を与えうる情報を広くとりあげ，これらの機能を整理・分類するとともに，これらが，現状のシステムとの会話におけるユーザの応答にどの程度含まれるかを調査する．

以下本稿では，2. でユーザが会話時に行うフィードバックの分類について説明し，3. でデータセットの収集方法やアノテーションについてとその結果について述べる．

連絡先: 早稲田大学 理工学術院 知覚情報システム研究室
〒 162-0042 東京都新宿区早稲田町 27
E-mail:katsuya@pcl.cs.waseda.ac.jp

2. 発話意図分類

システム会話におけるユーザのフィードバック現象を分析するコーパスの収集に先駆け，フィードバックがシステムの振る舞いに影響を与えうる情報を広くとりあげ，これらの機能を整理・分類した．

フィードバックの役割は，システムにある種の要求を伝えることにあるが，これらは，ユーザの要求を直接明示的に伝えるものと，ユーザ状態等を伝達することで間接的，あるいは暗示的に伝えるものがある．本稿ではこれらをまとめて発話意図（intention）と呼ぶ．

円滑なシステムを実現するための機能として，人の発話とシステムの発話が同時に起きるべきではないと考え（発話の衝突回避），また，利便性の高いシステムを実現するための機能として，システムが伝える情報の量という観点から，その増減を行うフィードバックがあることを考えた．これらのフィードバックを分類し，以下の 6 つの発話意図を提案する．

・待機要求
・質問
・補足要求
・反復要求
・無関心
・既知

「待機要求」はユーザがある発話の後少し間を空けても話し続けることを示し，システムの発話は待ってほしいという意図である．従来の音声対話システムでは VAD(Voice Activity Detection) により発話の区切りが検出されたら次の発話を開始するというものであった．そのためユーザはまだ発話を継続するつもりにも関わらず，システムが発話を開始し発話の衝突が起こっていた．この「待機要求」を認識することでシステムは発話を待機し，衝突を陽に回避することができると考えられる．

「質問」「補足要求」「反復要求」は伝達する情報を増やすための意図である．まとまった量の情報を伝達するシステムにおいてユーザの理解状態に応じて情報量の調整を行う必要があるが，中でもユーザの疑問解消や十分な情報の伝達は不可欠である．そのため，これらの意図を認識することで伝達する情報量を増やす調整を行うことができると期待した．「質問」はユーザが疑問をもち陽に質問を行ったもので，対話行為で分類される「質問」と同様のものである．「補足要求」は「質問」のように陽に質問は行っていないが，システム発話に疑問点を感じているもしくはシステム発話に理解が追いついていないため補足説明がほしいという意図である．「反復要求」はシステム発話を聞き取れなかった場合や受け取れなかった場合にもう一度同じ発話を繰り返してほしいという意図である．

「無関心」「既知」は，伝達する情報を減らすための意図である．興味のないトピックや既に詳細を知ってる情報を長々と伝えるシステムは利便性のあるものではない．そういった情報をユーザの反応に応じて省くことで利便性があり，継続して利用したくなるようなシステムになると考えられる．「無関心」は対話を行うトピックに対してユーザが興味を持っていないという意図である．ユーザの興味の無い情報を伝達することは無駄だと考え，この意図を認識した場合は他のトピックへ遷移することが考えられる．「既知」はシステムが伝える情報がすでにユーザが有する情報であることを示す意図である．既知情報を含むトピックに関しては詳細な情報を省き伝達することで，伝達効率を上げることができると考えられる．



図 1: 収録環境

3. データセット構築

2. で提案した発話意図に関するラベルを付与したデータセットの構築について述べる．発話意図のあらわれ方は，人同士で対話した場合と，システムと対話した場合とでは異なることが考えられる．本研究ではシステムと対話した際の現象をとらえるため，実際に [高津 18a] のシステムを用い，24 人の被験者が対話を行った際の音声データを収集した．さらに．収集したデータを 10 人のアノテータにより 2. で提案した発話意図に関するアノテーションを行った．

3.1 音声収録方法

人がシステムと対話した際の現象をとらえるため，実際に [高津 18a] のシステムを用い，被験者が対話を行った際の音声データを収集した．現在 2103 対話分の収録が完了している．音声データ収集には 24 人（男：12 人，女：12 人）の被験者がシステムとの対話を行い，その際の音声データを随時収録した．

3.2 アノテーション

アノテーションは，図 2 に示すアノテーションツールを作成し，10 人のアノテータで行った．このツールで用いるラベルは 2. で提案した発話意図を示すことができるかどうかと，このツール自体の使いやすさを考慮し設計した．具体的には，ラベルを現象，行為，内部状態の 3 つのレイヤに分け内部状態には 5 つの軸を設定した．

現象では，「発話の完了」を示す終了，「発話が途切れていたり，遮られている」ことを示す継続，「音声のない区間」を示す無音・雑音，「システム対話と関係のない音声」を示す無効，の 4 ラベルを付与する．

行為では，発話行為として分類される相槌，ターンをとる，返答，質問，情報開示，リアクションの 6 ラベルについて当てはまるものを選択する．

内部状態では「システム発話を受け取れているかどうか」「システム発話の内容に疑問を感じているかどうか」「対話内容に興味を抱いているかどうか」「システム発話の内容に好意的かどうか」「システム発話の内容が予期しえたかどうか」の 5 つの軸についてそれぞれ 3 段階で評価を行う．



図 2: 作成したアノテーションツール

表 1: 各ラベルに対応する発話意図とそれに対して想定されるシステムアクション

ラベル		発話意図	システムアクション
質問		質問	質問応答
継続		待機要求	傾聴
ターンをとる			
意外		補足要求	補足説明
相槌 or リアクション	＆懐疑		
	＆不受理	反復要求	繰り返し
	＆無関心	無関心	他トピックへ移行
当然		既知	詳細説明省略

アノテーションのルールは，1. 現象のレイヤで「終了」のラベルを付けた場合には行為，内部状態のレイヤに関しても必ずラベルを付与する．2.「継続」のラベルを付けた場合には分かれば行為，内部状態のレイヤに関してラベルを付与する．3.「無音・雑音」「無効」のラベルを付けた場合には行為，内部状態のレイヤにはラベルを付与しない．とした．

各レイヤでの選択は独立に行われ，内部状態のレイヤでは軸ごとにも独立に評価が行われる．各ラベルに対応するユーザ意図とそれに対して想定されるシステムアクションを表 1 に示す．

対象音声の分割は WebRTC vad（aggressiveness=2）[*1] を用い，即時的な反応を対象とするため 1.5 秒以下の音声を対象とした．また [森 05] において前の文脈が対象発話の評価に影響を及ぼすことが示されている事を考慮し，評価の際の材料として「対象音声の 3 秒前から再生」「対象音声の 5 秒前から再生」を作成した．さらに 5 秒前の音声からのみでは評価できなかった場合を考慮して,「対話全体」を聞けるようにし，対象発話が全体の中で何秒から始まるかの記述も行った．

他にも，アノテータ間の意見の相違をなくすためアノテーションの試用期間を設け，不一致が多かったものに対する意見のすり合わせ等も行った．

アノテーションを行う際には，アノテータ同士の一致度を求めるため．200 発話分に対しては全員がラベルを付与し，その一致度を求めた．一致度の計算にはフライスのカッパ係数（Fleiss' Kappa）を用い,「現象」「行為」ではそれぞれどのラベルを選択したか,「内部状態」では各軸毎にどのラベルを選択したかで一致度を求めた．

*1 https://github.com/wiseman/py-webrtcvad

表 2: 各ラベルの数

ラベル名		数	ラベル名		数
現象	終了	9240	内部状態	受理	8511
	継続	271		不受理	396
	無音・雑音	930		納得	3426
	無効	215		懐疑	2337
行為	相槌	3671		興味	2287
	ターンをとる	88		無関心	1156
	返答	233		当然	301
	質問	2161		意外	1594
	情報開示	366		好感	844
	リアクション	4950		嫌悪	542

表 3: 各発話意図に対応するラベルとそのデータ数

ラベル		発話意図	データ数
質問		質問	2161
継続		待機要求	312
ターンをとる			
意外		補足要求	2055
相槌 or リアクション	＆懐疑		
	＆不受理	反復要求	192
	＆無関心	無関心	1145
当然		既知	301

3.3 結果と考察

データセットの構築により得られた結果について述べる．現在，10420 発話に対するラベル付与が済んでおり，集まったデータについて各ラベルの数は表 2 の通りである．この数とは，アノテータが重複している場合は一人でも付与しているラベルがあればカウントしたものである．

この中から表 1 で示した発話意図の分類に当てはまるラベルの数は表 3 の通りである．また，アノテータ全員がラベルを付与した 200 発話に対する一致度 (Fleiss' Kappa) は図 3 のようになった．

提案した音声対話によりまとまった情報を伝えるシステムにおいて理解するべきユーザの発話意図において，最も表出度合が高かったものは「質問」が 2161 発話，次いで「補足要求」が 2055 発話,「無関心」が 1145 発話であり，他の意図に関しては表出度合が低かった．また，一致度についてみると現象や行為のラベルについては κ 係数が約 0.8 とほぼ完全な一致に近い値であったが，内部状態のラベルについてはどれも 0.4 を下回り，アノテータの評価一致度は低かった．

内部状態のラベル数は,「システム発話を受け取れているかどうか」の軸に関するラベルの付いた発話数が 8907 と「終了」のラベルが付いた発話のほぼすべてにラベルがついていたが,「システム発話の内容に疑問を感じているかどうか」に関するラベルの付いた発話数は 5763,「対話内容に興味を抱いている

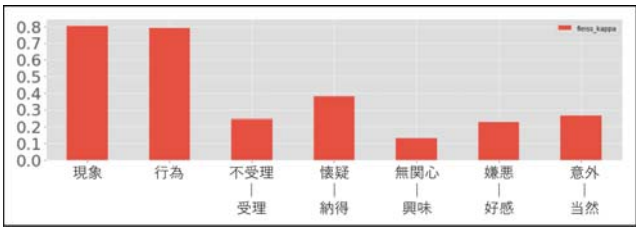


図 3: アノテータ同士のラベル一致度（Fleiss' Kappa）

かどうか」に関するラベルが付いた発話数は 3443,「システム発話の内容に好意的かどうか」に関するラベルが付いた発話数が 1386,「システム発話の内容が予期しえたかどうか」に関するラベルが付いた発話数が 1895 と「システム発話を受け取れているかどうか」の軸以外は内部状態のラベルの付いた発話が少ないことがわかる．このことから，現状のシステムとの対話において話者はそれほど内部状態の表出を行っていないことが分かる．

使用したシステムのニュースを伝えるという特性上,「質問」「補足説明」といった発話意図の表出が増えることは容易に想像でき，それは表出度合にも表れている．中でも「質問」に関してはラベルの一致度も高いため，システム実運用においても有用な意図であり，データセットとしての質も高く学習などに用いることができると考えられる．しかし,「補足要求」についてはその構成するラベルの一致度が低いためシステム実運用の際に判断のブレが強く出てくることが考えられる.「無関心」については，話者の内部状態表出が少ないことから，棒読みに聞こえることが多く，第三者からすると無関心に聞こえることが多かったのではないかと考えられる．また，ラベルの一致度については「補足説明」と同様のことが言える．他の意図に関しては表出度合が低く，構成するラベルの一致度も低い．

このように話者のフィードバックが少ない対話では，従来感情認識や意図認識として行われてきた研究の成果が生かせず，効率的な対話の実現ができない．また，雑談対話のようなタスクにおいても，システムの対話戦略をユーザの意図に沿わずに決定することになり，継続的に使われるシステムの実現は難しい．そのため，ユーザが内部状態を表出するためには現状のシステムで改善するべきものは何か，どのような機能を加えるべきなのか，そもそもシステムという時点で内部状態は表出しないのか，といった検討が必要である．

また，今回作成したコーパスの中でもデータ量が多く，アノテータ間の一致度も高かった発話意図「質問」については各発話が「質問」かどうかの識別実験も行った [高津 18b]．この結果，識別率約 95 %と非常に高い識別性能を得ることができた．

4. おわりに

実会話システム利用時における，システム発話に対するユーザのフィードバックの現象を分析するためのコーパス収集について検討を行った．現在我々が作成しているニュース伝達のための会話システム [高津 18a] を用いて，ユーザが実際にシステムとの会話時にどのようなフィードバックを行い，システムはどのようにそれを利用しうるかを調査した結果，現状のシステムでは発話意図「質問」においては出現頻度は高く，アノテータ間の一致度も高いことが分かった．一方で，その他の発話意図についてフィードバックは陽に得られないことが分かった．今後の課題として話者のフィードバックを陽に得られるようなシステムの作成があげられる．

参考文献

[Fujie 06] Shinya Fujie, Riho Miyake, Tetsunori Kobayashi: Spoken Dialogue System Using Recognition of User's Feedback for Rhythmic Dialogue, in Proceedings of Speech Prosody (2006)

[Kobayashi 13] Tetsunori Kobayashi, Shinya Fujie: Conversational Robots: An Approach to conversation protocol issues that utilizes the paralinguistic information available in a robot-human setting, Acoustical Science and Technology, Vol. 34, pp64-72 (2013)

[益永 14] 益永祐吾, 川端豪: 発話意図判定における文型・韻律・音色の相補的効果, 情報処理学会研究報告音声言語情報処理（SLP）, Vol.2010-SLP-80, No.14 (2014)

[牧野 17] 牧野孝史, 三浦寛也, 竹川佳成, 平田圭二: 複数人対話における話者交替現象分析のためのコーパスの作成, 人工知能学会言語・音声理解と対話処理研究会（SIG-SLUD）, pp.3-8 (2017)

[荒木 17] 荒木雅弘, 冨増紗也華, 中野幹生, 駒谷和範, 岡田将吾, 藤江真也, 杉山弘晃: マルチモーダル対話データの収集と興味判定アノテーションの分析, 人工知能学会言語・音声理解と対話処理研究会（SIG-SLUD）, pp.20-25 (2017)

[井上 17] 井上昂治, Divesh Lala Pierrick Milhorat, 高梨克也, 河原達也: 潜在キャラクタモデルによるリアルタイム対話エンゲージメント推定, 人工知能学会言語・音声理解と対話処理研究会（SIG-SLUD）, pp.78-83 (2017)

[Inoue 16] K. Inoue, P. Milhorat, T. Zhao, T. Kawahara: Talking with ERICA, an autonomous android, in Processings of SIGDIAL Conference, pp.212-215 (2016)

[長澤 17] 長澤史記, 石原卓弥, 岡田将吾, 新田克己: ユーザーの態度推定に基づき適応的なインタビューを行うロボット対話システムの開発, 人工知能学会言語・音声理解と対話処理研究会, pp.72-77 (2017)

[高津 18a] 高津弘明, 福岡維新, 藤江真也, 林良彦, 小林哲則: 意図性の異なる多様な情報行動を可能とする音声対話システム, 人工知能学会論文誌, Vol.33, No.1 (2018)

[森 05] 森大毅, 相澤宏, 粕谷英樹: 対話音声のパラ言語情報ラベリングの安定性, 日本音響学会誌 61 巻 12 号, pp.690-697 (2005)

[高津 18b] 高津弘明, 横山勝矢, 本田裕, 藤江真也, 林良彦, 小林哲則: 会話によるニュース記事伝達のための発話意図理解, 第 32 回人工知能学会全国大会論文集 (2018)

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

機械学習技術を用いた交渉エージェントのための自動交渉シミュレータ Jupiter の提案

A proposal of automatic negotiation simulator Jupiter for negotiation agents using machine learning.

福井智哉 *1　伊藤孝行 *1
Tomoya Fukui　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

The purpose of this paper is to propose Jupiter, a new environment for automated negotiations in which we can easily create agents that is able to use machine learning. Genius is cited as a prior study of the environment where automated negotiation can be simulated. It provides an environment for automated negotiations that aim to solve multi-issue negotiation problems. In the field of automated negotiation, it is expected that agreement results are optimized by machine learning. However, it is difficult to use Genius to simulate automated negotiations with agents using machine learning, because the past negotiations information provided by Genius is insufficient. As above, in this paper we propose Jupiter as a new automated negotiation environment in which we can easily create agents that is able to use machine learning. In addition, we compare Jupiter with Genius and show the superiority of Jupiter.

1. はじめに

本論文の目的は，機械学習技術を用いたエージェントの作成が容易な交渉シミュレーション環境として Jupiter を提案することである．

交渉は互いの利害の調整のために，社会において必要不可欠な行為である．自動交渉を模擬的に行う環境の先行研究として，Genius が挙げられる．Genius は複数論点交渉問題における，エージェントによる自動交渉シミュレーション環境を提供し，自動交渉の合意結果から自動交渉エージェントの性能を定量的に測ることができる．

近年，ハードウェア技術の向上に伴い，機械学習技術の発展が目覚ましい．しかし，Genius では繰り返し交渉を行う際に，過去の交渉に関する情報が一部分しか取得できないため，機械学習技術を用いる際に必要となる学習データが不足しており，機械学習技術を応用したエージェントの自動交渉実験が困難である．以上の点から，本論文では機械学習技術を用いたエージェントの作成が容易な環境として Jupiter を提案する．また提案システムである Jupiter と Genius で比較と評価実験を行うことにより，Jupiter の有用性を示す．

2. 関連研究

2.1 ANAC

概要

本論文で提案する Jupiter では，既存研究 ANAC[Baarslag 2016] を参考に，扱うことのできる交渉プロトコルと交渉ドメインを設定した．交渉プロトコルとしては Stacked Alternating Offers Protocol(SAOP)[Reyhan 2017] を採用している．交渉プロトコルとは，交渉の進め方や各エージェントの行動の定義をまとめた概念である．SAOP では，交渉参加エージェントが，交互に合意候補案の中から 1 つ提案を行うことにより，交渉を進行させる．交渉時間の種類にはターン制と時間制の 2 種類が存在し，各エージェントの行動には Offer，Accept および EndNegotiation の 3 種類存在する．

本節では Jupiter で取り扱う交渉プロトコルと交渉ドメインについて述べる．

交渉時間の種類

交渉の制限時間についてターン制と時間制の 2 種類述べる．

1. ターン制
   全参加エージェントの合意または EndNegotiation が発生したとき，もしくはあらかじめ決められたターンまで合意が得られかったときまで交渉を続ける．

2. 時間制
   全参加エージェントの合意または EndNegotiation が発生したとき，もしくはあらかじめ決められた制限時間まで合意が得られかったときまで交渉を続ける．

各エージェントの行動

各エージェントが取ることの出来る行動について述べる．エージェントの行動には Offer，Accept 及び EndNegotiation の 3 種類が存在する．各交渉参加エージェントは，自分の手番が回ってくる度に，3 種類の行動から 1 つ選ぶ．また，交渉参加エージェントは，交渉参加エージェントの順番に関係なく，他エージェントの行動を公開情報として全て認知することができる．しかし，行動を起こすには，自分の手番が回ってくるまで待たなければならない．

1. Offer
   合意案候補から 1 つ選び，提案する．他エージェントからの Offer をされたあとに，自エージェントが Offer を行なった場合，その他のエージェントの Offer は自動的に却下されたことになる．

2. Accept
   最近の他エージェントからの Offer を受け入れることを意味する．あるエージェントの Offer を，提案したエージェント以外の全エージェントが連続で Accept した場合，その交渉は合意に至ったとして判定され，交渉が終了する．

3. EndNegotiation
   交渉の強制的な終了を意味する．他のエージェントの行動に関わらず，交渉を終了することができる．一般的に他エージェントが交渉において，割引効用が大きいにもかかわらず，まったく妥協しない場合に有用な選択肢となる．

交渉ドメイン

ANAC で取り扱われる交渉ドメインについて述べる．交渉ドメインには，交渉結果における，各エージェントが取得する効用値に関する情報が記されている．

交渉ドメインに記述されている内容を説明する前に，合意案候補 (bid) を数式で示す．$\boldsymbol{s}$ を合意案候補，n を論点の数，I_i

連絡先: 福井智哉，名古屋工業大学工学部情報工学科，fukui.tomoya@itolab.nitech.ac.jp

を i 番目の論点で取りうる選択肢の集合と定義すると，各合意案候補 (*bid*) はの式 (1) により定義される．

$$\boldsymbol{s} = \{(s_1, s_2, \ldots, s_n) | s_i \in I_i, i = 1, 2, \ldots, n\} \quad (1)$$

式 (1) をふまえて，交渉ドメインに記述されている各合意案候補の効用値，留保価格及び割引効用の 3 つを説明する．

1. 各合意案候補の効用値
   各合意案候補の効用値 $U(\boldsymbol{s_k}; \boldsymbol{w})$ は式 (2)，式 (3) 及び式 (4) を用いて表される．

$$U(\boldsymbol{s}; \boldsymbol{w}) = \sum_{i=1}^{n} w_i \cdot eval(s_i) \quad (2)$$

$$\sum_{i=1}^{n} w_i = 1 \quad (3)$$

$$eval(s_i) = \frac{value(s_i)}{\arg\max_{s_i \in I_i} value(s_i)} \quad (4)$$

   w_i は i 番目の論点における重みを表し，$0 \leq w_i \leq 1 (1 \leq i \leq n)$ である．$value(s_i)$ は I_i において s_i を選んだ場合の効用値を表す．$w_i (1 \leq i \leq n)$ と $value(s_i) (s_i \in I_i)$ の値は交渉ドメインに記されている．補足として，式 (4) から

$$0 \leq eval(s_i) \leq 1 \quad (5)$$

   である．式 (2)，式 (3) および式 (5) より

$$0 \leq U(\boldsymbol{s}; \boldsymbol{w}) \leq 1 (\forall \boldsymbol{s})$$

   である．

2. 留保価格
   EndNegotiation や合意が得られずに交渉が終了した際に得られる効用値を表す．留保価格を r，合意失敗を e とすると，式 (6) で定義される．

$$U(e) = r \quad (6)$$

3. 割引効用
   交渉が終わった際に，交渉にかかった時間に応じて，各エージェントが得られる効用値を割り引くために使われる値である．各エージェントが得られる割引済みの効用値を U_d，割引効用を d，正規化された交渉の経過時間を $t (0 \leq t \leq 1)$ とすると

$$U_d(\boldsymbol{s}, t; d) = U(\boldsymbol{s}) \cdot d^t \quad (7)$$

$$U_d(e, t; d) = U(e) \cdot d^t \quad (8)$$

   と表される．

2.2 Genius

概要

既存の自動交渉シミュレーション環境に関する先行研究として，Genius[Lin 2014] について述べる．汎用的な自動交渉エージェントに関する研究を支援し，Java API を用いて交渉エージェントの開発や自動交渉シミュレーションを行うことができる．Genius の主な機能は，以下の 3 つである．

1. 交渉問題を定義する交渉ドメインファイルの作成
2. 自動交渉エージェントによる交渉シミュレーション
3. 交渉の過程と結果の記録と解析

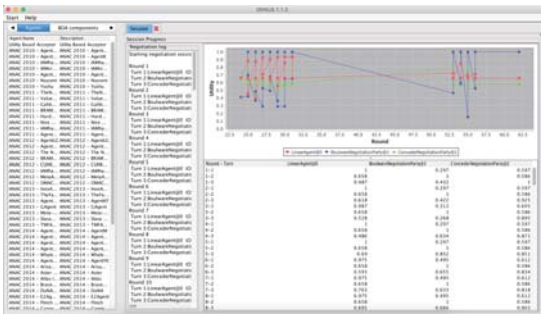


図 1: Genius の実行例

Genius はパレートフロント，ナッシュ解，およびカライ・スモロデンスキー解といった合意案候補点をグラフ上に描画するため，自動交渉の結果を視覚的に分析することができる．また特定の交渉問題ではなく，本章で説明した交渉プロトコルを採用することにより，汎用的な自動交渉全般に関する研究を支援している．よって Genius は，異なる交渉戦略をもつエージェント同士を，客観的な指標を用いて評価することが可能であり，自動交渉エージェント及び交渉戦略の研究において重要な役割を果たしている．Genius の実行例として，図 1 を添付しておく．

Genius の問題点

Genius を用いた自動交渉エージェントの研究開発では，さまざまな分野の技術が用いられている．森ら [森 2015] の提案するエージェントでは，ゲーム理論の観点からエージェントを作成している．Williams の提案するエージェント [Williams 2011] では，ガウス過程という機械学習技術を用いたエージェントを作成している．

一方，昨今のエージェントの研究分野では，深層学習技術を用いた研究が注目されている．2017 年には Lewis らが自然言語により自動交渉を行うエージェントの研究 [Lewis 2017] を行なっている．今後も深層学習などの機械学習技術を用いたエージェントの研究が期待される．しかし，Genius は Java 実装である点や，2010 年より開発されているという経緯から，昨今の深層学習技術を用いたエージェントの開発に向けて作成されていない．一般的に深層学習技術を実装する場合には，Python で実装されることが多い．

3. 自動交渉シミュレーション環境 Jupiter

3.1 Jupiter の概要

Jupiter は本論文で提案する自動交渉シミュレーション環境である．Jupiter は 2.1 章で述べた交渉プロトコルと交渉問題を扱うことができる．またプロセス間通信を行うことにより，Genius 上で動作する自動交渉エージェントを Jupiter 上で動かすことができる．本章では，Jupiter の実行方法と動作例を示す．

3.2 Jupiter で自動交渉を行うまでの流れ

本章では，本論文で提案する自動交渉シミュレーション環境 Jupiter により，自動交渉を行う際の処理の流れを説明する．

1. ユーザが交渉の長さ，交渉ドメインファイルおよび交渉参加エージェントを指定する．
2. Jupiter が交渉ドメインファイルを読み込む．またエージェントを呼び出し，エージェントに交渉ルール，交渉ドメイン情報を渡す．
3. 交渉を実行する．

また交渉を実行する際のパラメータ次第で，交渉過程を動的に表示させることや交渉履歴を json 形式で保存することができる．

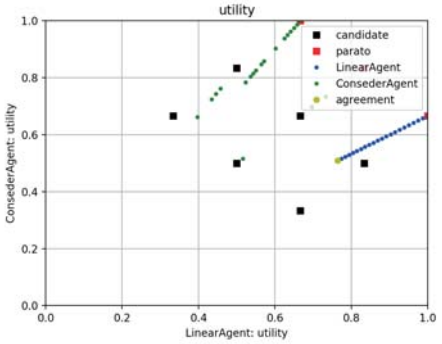


図 2: Jupiter の実行例

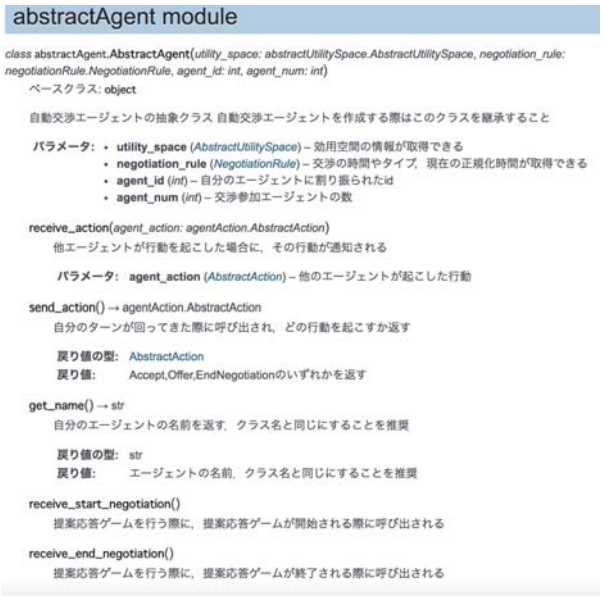


図 3: abstractAgent

Jupiter の実行例として，図 2 を載せる．緑色の点が ConcederAgent の提案した合意案候補であり，青色の点が Linear エージェントの提案した合意案候補である．横軸が Linear エージェントの獲得できる効用値であり，縦軸が Conceder エージェントの獲得できる効用値である．また黒色の四角形と赤色の四角形が合意案候補点である．

3.3 Python による自動交渉エージェントの作成

Jupiter でエージェントを実装するには，図 3 に表示されている，自動交渉エージェントの抽象クラスである abstractAgent クラスを継承したクラスを作成すればよい．継承した子クラスについて，親クラスの各メソッドをオーバーライドすることにより，エージェントの交渉戦略を定義できる．

ここでエージェントを実装する際の，Genius との差異として，receive_start_negotiation メソッドと receive_end_negotiation メソッドがあることを挙げておく．繰り返し提案応答ゲームにおいて機械学習技術を応用する際に，提案応答ゲームと提案応答ゲームの間に，パラメータの調整などの処理を行いたい場合がある．receive_start_negotiation メソッドは提案応答ゲームの開始時に，receive_end_negotiation メソッドは終了時に呼ばれる．そのため，提案応答ゲームが終了した際の後処理を実装したい場合，Jupiter では容易に行うことができる．

表 1: Genius と Jupiter によって実装された Linear エージェントの比較

シミュレーション環境	コードの行数	コードの文字数
Genius	57	120
Jupiter	36	83

4. Jupiter と Genius の比較

4.1 概要

本章では Jupiter と Genius について，定性的な評価と定量的な評価を行うことにより，その差異を示す．

まず Genius 実装のエージェントと，Jupiter 実装のエージェントについて，そのコードの長さを比較する．次に Genius によって行われる自動交渉と，Jupiter によって行われる自動交渉で，実行にかかる時間を比較する．実行にかかる時間が短ければ，自動交渉エージェントの実験にかかる時間を削減することができる．よって，自動交渉シミュレータにとって重要な課題である．次に定性的な評価について比較を行う．最後に，本章で行なった比較のまとめと考察を行う．

4.2 自動交渉エージェントのコードの長さの比較

本実験では，Linear エージェントを Jupiter 環境と Genius 環境で動くようにそれぞれ実装し，そのコードの行数と文字数を定量的に比較する．以下，Linear エージェントについて解説する．

エージェントを作成する際には，交渉戦略を設計する必要がある．自動交渉エージェントはその交渉戦略に基づいて受容 (Accept)，提案 (Offer) 及び交渉打ち切り (EndNegotiation) から 1 つ選択する．特に他エージェントからの提案を受容するかどうか，に関する戦略を Acceptance Strategy と呼ぶ．Acceptance Strategy を設計する際に，自身が獲得できる効用値からその判断を行うエージェントが多く存在する．その判断の手法には，提案された内容の効用値を入力として，受容するかどうかの 2 値を出力する，譲歩関数を用いる手法が存在する．文献 [C.Sierra 1999] では，譲歩関数に交渉の経過時間 $t(0 \leq t \leq 1)$ を用いたエージェントを提案している．

$$T(t) = 1.0 - t^{\alpha} \tag{9}$$

具体的には式 (9) で定義される譲歩関数 $T(t)$ を提案している．式 (9) で表される譲歩関数を持ち，特に $\alpha = 1$ となるような譲歩関数を持つエージェントを Linear エージェントと呼ぶことにする．Linear エージェントは，譲歩関数の出力する値以上の効用値を持つ提案または受容を行う．

比較の結果を表 1 にまとめた．一般的に Python 言語は Java 言語よりも，コードを簡潔に記述できるとされている．本比較の結果においても，定量的なコードの記述量による比較から，コードの簡潔さを示すことができた．

4.3 実行速度の比較

本実験では Linear エージェント，Conceder エージェント及び Boulware エージェントによる 3 者間交渉を行う．Conceder エージェントは式 (9) において $\alpha = 0.5$ となるような譲歩関数を持つエージェントである．Boulware エージェントは式 (9) において $\alpha = 10$ となるような譲歩関数を持つエージェントである．

交渉の設定としてはターン制で，180 ターンを上限とした．また，交渉ドメインファイルとして，ANAC2016 で用いられた triangularFight，KDomain 及び NewDomain を用いる．交渉ドメインファイルを選んだ基準として，合意案候補の数を考えており，合意案候補の数が少ないもの，中くらいのもの及び多いものを選んだ．それぞれの効用空間の大きさは表 2 を参照されたい．

交渉参加エージェントの順列が ${}_3P_3 = 6$ 通りであり，それぞれ 10 回ずつ自動交渉を行うため，各々の効用情報について合計 $6 \times 10 = 60$ 回ずつ自動交渉を行う．

表 2: 実験で用いる効用空間の大きさ

ドメイン名	論点数	合意案候補の数
triangularFight	2	9
KDomain	5	1280
NewDomain	7	35840

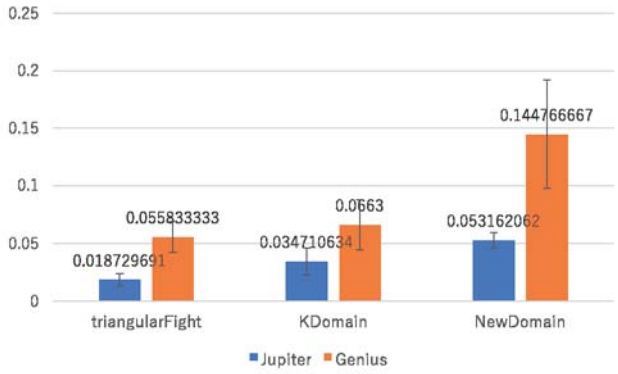


図 4: 平均交渉時間とその分散

各交渉ドメインファイルにおける 60 回の，平均交渉時間とその分散を示したものが図 4 である．効用空間の大きさに関わらず，Jupiter の方が自動交渉にかかる時間が短いことが示された．Jupiter では一部の処理を Cython で実装することにより，処理の高速化を行なっている．

4.4 定性的な評価による比較

本節では定性的な評価により比較を行う．

Genius ではパレートフロント，ナッシュ解，及びカライ・スモロデンスキー解などの分析を自動で行う．Jupiter では現在，パレートフロントのみを提供している．ナッシュ解及びカライ・スモロデンスキー解の分析については実装中である．

Genius は Java 言語による実装であり，Jupiter は Python 言語による実装である．そのため，Jupiter は scikit-learn や tensorflow などのライブラリを用いることにより，機械学習技術を応用したエージェントの実装が容易である．

また Genius では GUI 上で自動交渉が行えるが，Jupiter では基本的に Jupyter Notebook というシェル上での実行を推奨している．Jupyter Notebook 上での実行が可能なため，実行ログの視覚的な確認が容易であり，エージェントの各種パラメータの調整が容易である．

4.5 比較のまとめ

以下，本章で行った比較評価に関して，まとめる．簡単にまとめたのが表 3 である．

Genius と提案する自動交渉シミュレーション環境 Jupiter について比較評価を行った．定量的な比較項目として，交渉の実行時間と，エージェントを実装する際のコードの記述量を比較した．定性的な評価として，実装言語や使用方法を比較した．

4.6 考察

考察をもって，本章の終わりとする．

Python 言語はインタラクティブな実行が可能である，スクリプト言語である．よって，一般的には Java 言語の方が実行速度は速いと言われている．しかし，Genius は 2010 年から現在に到るまで，長期間運用されてきた自動交渉シミュレータである．内部が最適化されていないために，動作が遅いと考えている．一方で，長期間運用されてきたことからその研究分野はゲーム理論，心理学及びマルチエージェントなど多岐に渡る．例えば 4.4 節で述べた，ゲーム理論の枠組みによる，合意結果の分析は大変興味深い．また ANAC で毎年用いられていることから，留保価格や割引効用が取り入れられるようになり，より現実の交渉問題に近い交渉設定を扱えるようになって来ている．しかし現状ではまだ現実の交渉問題を扱うことは難しいと感じている．よって，交渉プロトコルや交渉ドメインについての研究を今後の課題としたい．

表 3: Genius と Jupiter の比較まとめ

比較項目	Genius	Jupiter
実装言語	Java	Python3
CUI	△	○
交渉の実行時間	△	○
エージェントのコード記述量	△	○

5. おわりに

本研究では，自動交渉シミュレーション環境 Jupiter を提案した．SAOP に基づく自動交渉シミュレーションを Python 言語により行うことができる．また実験により，自動交渉にかかる時間とエージェントのコード記述量において，先行研究である Genius よりも短いことを示した．しかし，Genius と比較して，交渉ドメインファイルの作成機能や GUI の実装など未実装である機能が存在することが問題点として挙げられる．今後の課題としていきたい．

参考文献

[Williams 2011] Williams, Colin R., et al.: ”Using gaussian processes to optimise concession in complex negotiations against unknown opponents.”, IJCAI Proceedings-International Joint Conference on Artificial Intelligence. Vol. 22. No. 1. (2011).

[Reyhan 2017] Aydoan, Reyhan, et al.: ”Alternating offers protocols for multilateral negotiation.”, Modern Approaches to Agent-based Complex Automated Negotiation. Springer International Publishing, 153-167. (2017).

[Lin 2014] Lin, Raz, et al.: ”Genius: An integrated environment for supporting the design of generic automated negotiators.”, Computational Intelligence 30.1, 48-70. (2014).

[森 2015] 森顕之, and 伊藤孝行.: ”二者間交渉問題における進化的安定戦略を考慮した交渉戦略の提案.”, 研究報告知能システム (ICS) 2015.19, 1-8. (2015).

[Baarslag 2016] T. Baarslag, R. Aydog an, K. V. Hindriks, K. Fuijita, T. Ito, and C. M. Jonker.: The automated negotiating agents competition 2010-2015., AI Magazine(2016).

[Lewis 2017] Lewis, Mike, et al. : ”Deal or no deal? end-to-end learning for negotiation dialogues.” arXiv preprint arXiv:1706.05125 (2017).

[C.Sierra 1999] Sierra, Carles, Peyman Faratin, and Nick R. Jennings.: ”A service-oriented negotiation model between autonomous agents.” Collaboration between human and artificial societies. Springer, Berlin, Heidelberg, 201-219, (1999) .

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

環境問題を対象とした多言語ディスカッションの対話分析

An analysis of multilingual communication for solving global environmental issues

廖 育琦[*1] Yuqi Liao　王 博[*1] Bo Wang　家入 祐也[*1] Yuya Ieiri　中島 悠[*2] Yuu Nakajima　菱山 玲子[*1] Reiko Hishiyama

[*1] 早稲田大学創造理工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 Department of information Science, Toho Univercity

Because of their transnational nature, environment problems are difficult-to-solve, global challenges. The goal of our research is to examine ways to clarify common features, points of similarity, and points of difference in people's thinking in order to promote understanding and co-ownership of environmental problems between people who speak different languages. Our research begins with facilitating communication between participants about environmental problems through ICT. This communication log will consist of a sequence of dialogues in two languages, the discourse analysis of which will require significant cost. However, by reducing and analyzing techniques of expression through consolidating each person's thoughts post-communication and providing illustrated diagrams of the dialogue sequences the speakers experienced, we demonstrate that we can summarize each person's points and assist in mutual understanding.

1. 始めに

昨今，地球環境問題が深刻化しメディアでも多く取り上げられ，深刻な社会問題となっている．中でも中国は，深刻な空気汚染と水質汚染で苦しんでいる．これらの環境問題は一般に越境性を伴い，一国のみでは解決が困難であるため，問題解決に向けて地球規模の対話が求められている．こうした場面では，異言語で多様な人々の意見を相互に交換できるコミュニケーション環境が必要となる．

本研究では，こうしたコミュニケーション環境で，相互の意見や議論に対する共通点，類似点や相違点を抽出し，それを比較するために有効な方法を検討する．研究では異言語の対話系列を図解としての表現技法に置き換える方法を適用し，対話系列と図解を併用して思考内容の比較のための情報を得る方法を提案し，意見の共通点や相違が抽出できることを示す．

2. 関連研究

これまで機械翻訳サービスを介した多言語のコミュニケーションに関する研究が多く行われてきた．照井ら[1]はビジネススクールの異文化にまつわる経営ケース教材を利用し，言語グリッド[2]を介した多言語コミュニケーションの対話内容を分析し，文化差を抽出した．鈴木ら[3]は専門知識が含まれる日本酒の醸造工程の知識伝達によって機械翻訳を介した知識伝達の品質に関する議論を行った．これらの一連の研究に対して，本研究は特に対話とその図解を併用する点に特徴があり，意見の共通点・類似点，相違点が把握しやすくなるよう配慮している．

3. 提案

研究では，異言語・異文化コミュニケーションによる対話においてその考え方の共通点・類似点や相違点を相互に理解するための方法として，対話系列を図解としての表現技法に置き換えて比較可能とし，相互の論点を集約することを提案する．提案ではICT環境でのチャット形式による対話に加え，思考・発想法として知られるマインドマップ[4]を活用し，対話から得られた情報をマインドマップに整理することで，その論点を整理する．これにより，対話系列だけでは把握できない相互の意見を思考の構造ベースで比較できる．

Name: Yuqi Liao
Affiliation: Graduate School of Creative Science and Engineering, Waseda University
Address: 3-4-1 Okubo, Shinjuku-ku, Tokyo 169-8555, Japan

4. 実験概要

本研究では，日本人と中国人が中国の環境問題の原因 3 点を巡り議論を行う実験を遂行した．議論参加者の 2 名は，提示された中国の環境問題 3 つの原因：火力発電，工場の排気，自動車排気について議論しながら優先順位をつけ，最も重要な原因から解決策を議論する．この作業を繰り返し，2 番目に重要な原因，3 番目に重要な原因，のように順次議論を行う．議論が終わった後，各自が議論内容と自分の考えを結合して紙上に整理し，自分なりのマインドマップを描く作業を行った．

実験は 5 回行ない，うち 3 回は，日本人 1 名と中国人 1 名を 1 組とし，日中翻訳サービスを介した異言語の議論を行った．残り 2 回は対照実験として，日本人 2 名を 1 組，中国人 2 名を 1 組とし，それぞれ同言語（母語）による実験を行った．

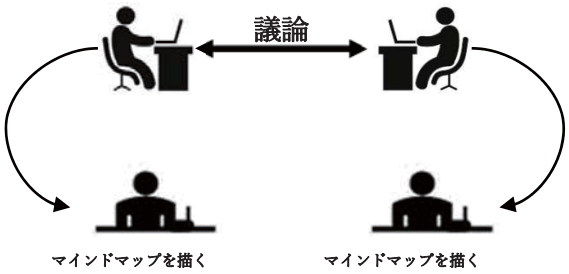


図 1：実験手順の概要

5. 結果と考察

議論の時間は，三つの原因とも 8 分間を費やした．議論された三つの原因に関し，グループ別でマインドマップに記入されたキーワードを集計した結果を図 2 に示す．三つの原因の中，グループ 1 とグループ 3 は火力発電に関するキーワードが最も多い．グループ 2 は工場の排気に関するキーワードが最も多い．実験では，グループ 1 とグループ 3 は火力発電が第一の原因であるとし，グループ 2 は工場の排気が第一の原因であるとして，

対話と議論が進行した. 順位が高い原因ほど, 利用されたキーワード数も多い. つまり, 三つの原因の中で, 優先順位が高い原因は, 時間制限内で, 単位時間あたりの伝達情報量がより多い結果となった. 残りの二つの原因には, ほぼ同じ数のキーワードを記入していた. これは残り二つの原因に対して, 同様な重みがつけられていることが考えられる. なお, 議論過程の意思決定はマインドマップ上にも反映されている.

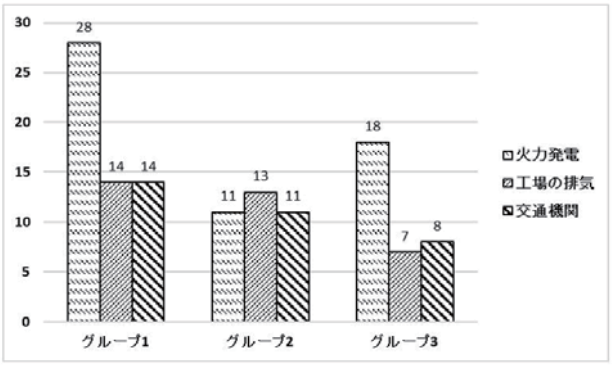


図 2:原因別のキーワードの数

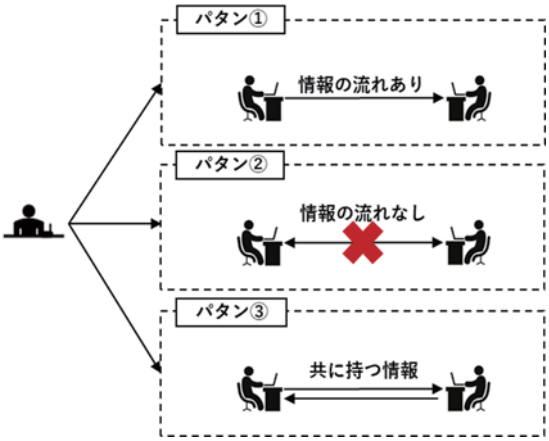
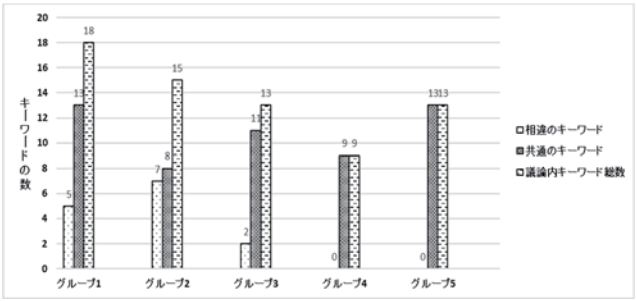


図 3:キーワードの分類

マインドマップ上に記述されることで得られたキーワードを集計し, パタン分類したものを図 3 に示す. パタン①では, 相手から情報を受け取り, マインドマップに記入したキーワードを集計する. これらは, 片方のみの意見や意見の相違点としてのキーワードを集計することを意味する. パタン②では議論していない独自の考えがマインドマップに記入されているケースを集計する. パタン③では, 共に情報を持ち, 議論中にそれを交換し,マインドマップに記入したキーワードを集計する. これらは, 意見の共通点としてのキーワードを集計することを意味する.

パタン①とパタン③は議論内で発生したキーワードであり, その集計結果を図 4 に示す. グループ 1, 2, 3 は, 日本人と中国人が議論に参加した異言語対話グループであり, グループ 4 は中国人と中国人, グループ 5 は日本人と日本人の同言語対話グループである.

日本人と中国人が議論した 3 組の異言語対話グループで, マインドマップに記入したキーワードを調べると, 情報の流れが見えるキーワードはそれぞれ 5, 7, 2 個であった. 同言語グループであるグループ 4 と 5 は, これが両方 0 になっている. このことから, 異言語(異国)間の参加者によるコミュニケーションで, 他国の情報が相互に伝達され理解される可能性を見出せる.



4:相違と共通キーワードの数

同国間コミュニケーションでは共通に持つ情報が多いとみられ, 情報の流れが表出せず, その流れの把握は容易ではない.

図 5 はマインドマップに記入されたキーワードを日本人グループと中国人グループに分け, さらにエネルギー, 政府政策, 法律, 経済, 教育の 5 つの種類に分類し集計した結果である. 環境問題の解決を巡り, 日本人と中国人はエネルギー, 政府政策, 法律, 経済, 教育の各分類に同程度の注目を行っている傾向が見えた. 特にエネルギーと経済について, 日本人と中国人は共に多数のキーワードを提示したことがわかる.

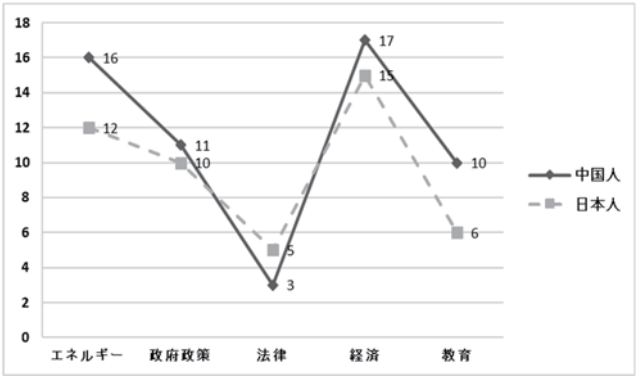


図 5: 日本人と中国人各分類におけるキーワード数

6. まとめと今後の課題

本研究は中国の環境問題に関する異言語コミュニケーションから日中間の情報の流れを分析し, 思考や理解の共通点・類似点や相違点の存在を明らかにすることを試みた. 今後の課題は, コミュニケーション前と後で, 考え方の変化を定量的に分析できる手法を見つけることである.

謝辞 本研究は中山隼雄科学技術文化財団研究助成の成果である.

参考文献

[1] 照井 賢治, 菱山 玲子:多言語コミュニケーション環境における異文化分析, ヒューマンインタフェース学会論文誌, 16(1), pp63-76 (2014).

[2] 言語グリッドポータルサイト: http://langrid.org/jp/ (閲覧日 2017/11/6).

[3] 鈴木 宏, 菱山 玲子:機械翻訳サービスを用いた専門知識伝達サービスの分析, 第 14 回情報科学技術フォーラム (FIT2015), 14(3), pp.69-76 (2015).

[4] Mind Mapping: www.tonybuzan.com/about/mind-mapping/ (閲覧日 2018/12/1).

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

議論スキームを用いた議論対話における論拠の自動生成

Premise generation based on argumentation schemes for dialogue systems

光田 航 Koh Mitsuda　東中 竜一郎 Ryuichiro Higashinaka　片山 太一 Taichi Katayama　富田 準二 Junji Tomita

日本電信電話株式会社 NTT メディアインテリジェンス研究所
NTT Media Intelligence Laboratories, Nippon Telegraph and Telephone Corporation

Towards creating an argumentative dialogue system, this paper proposes a method to create premises from a given utterance representing a conclusion. The proposed method utilizes Walton's argumentation schemes for generating premises from various inputs. The generated premises were evaluated by human subjects, and the results showed the validity of our method.

1. はじめに

自分の意見を述べたり，相手の意見に対する支持や不支持の論拠を述べる議論は，合意形成や意見交換を行うための重要な対話の一種である．近年，テキストに含まれる議論を構造化する argumentation mining と呼ばれる分野の研究が盛んに報告されており，議論が含まれるテキストから命題を抽出したり，抽出された命題間の支持や不支持の関係を推定する手法が提案されている [Lippi 16]．

argumentation mining の分野とは対照的に，ユーザと議論を行う議論対話システムの構築を試みた研究はまだ少ない [Rakshit 17, Higashinaka 17, Sakai 18]．議論対話システムが実現できれば，ユーザはシステムとの議論を通じて考えを整理したり，新たな気付きを得るといった有益な対話が可能になる．議論において，任意のユーザ発話に対して支持や不支持を表すシステム発話を生成するのは挑戦的な課題である．そのため，既存の議論対話システムは，特定の議論のテーマに関する議論の発話（結論を表す発話とその前提となる論拠を表す発話のペア）をあらかじめ人手で用意し，ユーザ発話に応じて適切な発話を選択することで応答を返す用例ベースの手法を採用している．

既存の議論対話システムの課題として，議論のテーマごとに人手であらゆる発話を網羅的に用意することは困難であるため，議論のテーマを増やしたり，一つのテーマで様々な話題に適切に答えられるようにするには限界がある．この課題を解決するためには，自動で議論に関する発話を用意できることが望ましい．argumentation mining の技術を用いて，特定のテーマに関する議論が含まれる Web テキストなどから命題を発話として獲得する抽出ベースのアプローチが考えられるが，Web テキストに頻出するテーマや命題以外には対応することができないため，獲得できる発話のカバレッジが十分とは限らない．

そこで，本稿では，argumentation mining で扱われる抽出ベースの手法ではなく，生成ベースの手法を用いて，結論となる命題の支持や不支持の論拠を表す命題を自動的に獲得する手法を提案する．生成する命題のカバレッジを高めるために，命題間の典型的な論理関係を整理した Walton の議論スキーム [Walton 13] を利用し，議論スキームごとに用意した生成用テンプレートと言語リソースを用いて命題の生成を行う．手法の有効性を確認するために，抽出ベースの手法との比較評価を実施した結果，提案手法はより幅広い命題に対して有効な命題を獲得できたことを報告する．

連絡先: 光田航，日本電信電話株式会社 NTT メディアインテリジェンス研究所，神奈川県横須賀市光の丘 1-1，239-0847，mitsuda.ko@lab.ntt.co.jp

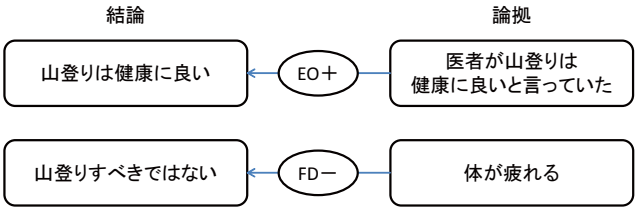


図 1: 議論スキームの例

2. 議論スキームを用いた論拠の生成

図 1 に議論スキームの例を示す．議論スキームとは，結論とその論拠の間に成り立つ典型的な支持（‘＋’），不支持（‘－’）の関係を 35 種類に分類したものである．例えば，図 1 の “EO ＋” は “Expert Opinion” というスキームを用いた支持関係を表し，“FD －” は “Fear and Danger Appeal” というスキームを用いた不支持の関係を表す．提案手法では，結論を表す命題を入力として受け取り，適切な議論スキームを適用することで，その論拠となる命題を出力する．議論スキームには，特殊な命題を結論とする 4 種類を除いた 31 種類を利用する．

図 2 に提案手法の処理の流れを示す．まず，入力命題に対して述語構造解析 [Imamura 14] を適用し，格要素，述語，モダリティ表現（当為や否定表現など）を抽出する．次に，抽出した情報を用いて，あらかじめ議論スキームごとに定義したルール（例えば，当為と否定表現が含まれていれば “FD －” が使用可能と判定するルール）に基づいて，使用するスキームを決定する．その後，使用可能スキームごとに用意した論拠の生成用テンプレートと言語リソースを用いて論拠の候補を生成する．最後に，言語モデルを用いて閾値未満の候補を除外し，スキームごとの Top 1 の候補を論拠として出力する．

表 1 に各議論スキームの生成手法を示す．提案手法では，議論スキームを大きく 6 種類に分類し，“具体例” でオントロジー，“因果関係” と “情報源” でパタン抽出，“決めつけ”，“一般論”，“その他” で固定表現を利用して生成を行う．以降，各生成手法について述べる．

表 1: 議論スキームを用いた論拠の生成手法と具体例．具体例の列に示される入力の角括弧で囲まれたテキストは，論拠の生成に利用するテキストを表し，論拠の角括弧で囲まれたテキストは，各議論スキームごとに用意された生成用テンプレートに設けられたブランクに埋められたテキストを表す．

生成手法	分類	スキーム	概要	具体例 （入力 → 生成される論拠）
オントロジー	具体例	AA +	類推	田舎は [商店] が遠い → 同じように田舎は [バス発着場] も遠い
		AD +	分割	朝食なら [パン] がよい → [手で食べられるもの] がよい
		CO +	合成	パンは [和食] と合わない → [うどん] がパンと合わない
		EX −	例外	パンは [柔らかい] → パンは [固い] 場合もある
パタン抽出	因果関係	PR +/−	推論	[都市に永住す] べきではない → [体に悪い]
		AC +	結果+	[北海道に旅行に行く] べきだ → [思い出を作る]
		FD −	結果−	[沖縄に旅行に行く] べきではない → [天気が崩れる]
		CE +	原因	[沖縄に旅行に行く] べきではない → [お金がない]
		EC +	結果	[沖縄は平地が多い] → 沖縄は [自転車に乗る]
		EH +	証拠	[ご飯を食べる] べきだ → [ご飯が健康に良い] ならば [ご飯を食べる] べきだ
		SIG +	兆候	[沖縄は平地が多い] → 沖縄は [自転車に乗る] のは [平地が多い] ことの兆候だ
	情報源	EO +	専門家	[ジャンクフードにご飯は合わない] → [食] の専門家がそう言っていた
		PK +	事情通	[都会には 100 円ショップが多い] → [東京] の人が言っていた
		PH +	援助	[田舎に永住する] べきだ → [田舎] の人が喜ぶ
固定表現	決めつけ	BI +	先入観	沖縄は物価が安い → それは [沖縄] に対する先入観だ
		EA +/−	善人悪人	ご飯を食べるべきだ → あなたは良い人なのでその通りだ
		GA +	立場	ご飯を食べるべきだ → あなたはそう言わざるを得ない立場だ
		PA +	個人攻撃	ご飯を食べるべきだ → あなたは悪いことをしたので信じられない
	一般論	PO +	世論	田舎には店がない → みんながそう思っている
		LK −	認知不足	ホットドックは主食にならない → その考えは一般的とは言えない
		ER +	ルール	[ご飯を食べる] べきではない → [ご飯を食べる] のを避けるのはルールだ
		PER +	印象	[田舎は老人が多い] → [田舎は老人が多い] という印象を持たれている
	その他	AP +	前例	[ご飯を食べる] べきだ → [ご飯を食べる] ことで後悔したことがあるはずだ
		SUN +	費用	朝食で [パンを食べる] べきだ → 過去に [パンを食べる] ことがあったはずだ
		AO +	選択	沖縄に旅行に行くべきだ → 他の選択肢よりも良い
		SS +	滑り坂	[ご飯を食べる] べきではない → 一度 [ご飯を食べる] と歯止めがきかない
		IN +	矛盾	都市に永住するべきだ → あなたの過去の行動と矛盾している
		AR +	仮説	パンは手軽に食べれるので需要は大きい → 他によい仮説が思いつかない
		CC +	相関	パンは手軽に食べれるので需要は大きい → これらの間には相関がある
		VAL +	価値	都会は人口が多いため [景気も良い] → [景気がよい] ことは重要だ
		CM +	言動	北海道に旅行に行くべきだ → 過去にそういう言動をしていた

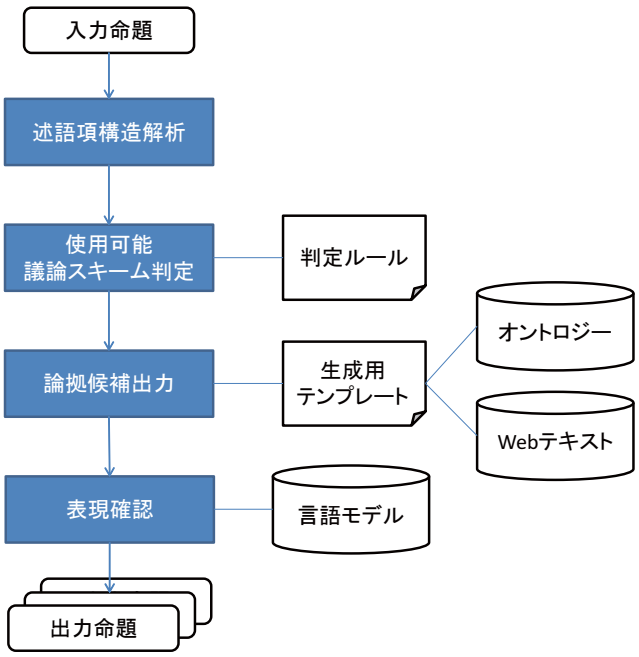


図 2: 議論スキームを用いた論拠の生成の流れ

オントロジーを用いた生成 オントロジーを用いた生成では，入力された命題中の単語をオントロジーに基づいて置換することで，論拠を生成する．オントロジーとして，“AA +” では日本語 WordNet [Isahara 08] の “synonym”，“AD +”，および，“CO +” では ConceptNet [Speer 12] の “IsA”，および，“MadeOf”，“EX −” では我々が独自に作成した反義語辞書を利用する．

パタン抽出を用いた生成 パタン抽出を用いた生成では，Web テキストからパタンを用いて抽出した表現の中から，入力された命題に適切な表現を選択し，論拠を生成する．“因果関係” に分類される議論スキームのパタンとしては “述語項構造，接続表現，述語項構造” を使用し，獲得された述語項構造のペアを利用して論拠を生成する．“情報源” に分類される議論スキームのパタンとしては，“（）の専門家”，および，“（）の人” を使用し，括弧内の表現を利用して論拠を生成する．使用する表現を選択する際には，“因果関係” と “情報源” のいずれも，入力された命題に含まれる格要素となる単語と表現の間の word2vec [Mikolov 13] における類似度を用いる．例えば，表 1 の “PR +” の例であれば，“都市に永住する” に含まれる単語の平均ベクトルを用いて，“都会に住む” という述語項構造をマッチさせ，そのペアとなる “体に悪い” という述語項構造を論拠として出力する．

固定表現を用いた生成 固定表現を用いた生成では，同一の表現，または，入力の一部をテンプレートに当てはめることで論拠を生成する．

表 2: 論拠を生成するモデル．出力される論拠の例の列は，入力された命題が「田舎は空気が良い」の場合に出力される論拠の例を表す．

モデル名	概要	出力される論拠の例
提案手法	議論スキームに基づいたテンプレートをもとに生成を行う手法（支持または不支持）	支持：田舎は自然が良い 不支持：田舎は空気が悪い場合もある
雑談ベース	雑談対話システムを用いて，入力に対する応答発話を出力する手法（支持のみ）	支持：田舎に行くのです
抽出ベース	検索エンジンを用いて，入力にヒットしたテキストを出力する手法（支持のみ）	支持：空気が綺麗で健康になるとの理由から，田舎に住む人が増えていることが○○の調査から明らかになりました（作例）
人手ベース	入力に対する論拠を人手で記述する手法（支持または不支持）	支持：田舎は自然が豊かだ 不支持：田舎は車が多いので空気が綺麗とは限らない

3. 評価実験

表 2 に示す手法を用いて，提案手法の有効性を調査するために，入力された命題に対して論拠を出力し，その論拠の評価を行った．以降，その詳細について述べる．

3.1 比較手法

雑談ベース 本手法は，結論となる命題に対する既存雑談対話システム [Higashinaka 14] の応答発話を論拠として出力する手法である．例えば，雑談対話において出力される同意を表す発話を支持の論拠とみなすことができるように，一部の発話は支持の論拠としてそのまま使用できる可能性がある．出力される論拠は支持のみを表すものとする．

抽出ベース 本手法は，Web などの大規模テキストから結論となる命題の論拠となる命題を抽出する手法に対応する．本稿では，抽出型の手法の代替システムとして，「なぜ？」などの検索が可能な NICT の WISDOM X [*1] を用いて，入力命題をクエリとした際の検索結果を論拠として利用する．出力される論拠は支持のみを表すものとする．

人手ベース 本手法は，結論となる命題の論拠を人手で記述したものをそのまま利用する手法である．結論とその論拠が記述されたデータとして，酒井ら [Sakai 18] に述べられているデータを利用する．酒井らのデータには支持と不支持の論拠が含まれているため，出力される論拠にも支持と不支持の両方が含まれる．

3.2 評価用の入力データと評価方法

評価用のデータとして前述の酒井ら [Sakai 18] で述べられているデータを利用し，条件節や複数の述語項構造を含むものを除いた命題（1 文の自然文で表されたもの）を入力として使用する．入力を選定する際には，議論スキーム全体の有効性を評価するため，提案手法の各議論スキームの出力数が同数になるようにサンプリングを行い，サンプリングされた命題に対して 3 種類に比較手法を適用することで全 4 種類の出力を得るようにした．評価用の入力として，各スキームごとに 3 事例を選択し，3 事例 × 31 スキーム = 93 事例を用意した．出力に必要なパタン抽出，word2vec の学習，および，言語モデルの学習には我々が独自に収集したブログテキスト約 2 億文書を用いた．

評価方法として，入力された命題（結論）と各モデルが出力した命題（論拠）を作業者に提示し，3 種類のラベル（出力の自然さ，命題間の関係性，出力の説得性）を付与した．論拠の自然さは，出力された命題を単体の発話として見たとき，どの程度自然かどうかを表す（1 点：かなり不自然〜5 点：とても自然の 5 段階）．命題間の関係性は，出力された命題が入力に対して正しく論拠になっているかを表す（支持，不支持，無関係の 3 種類）．付与された関係性は，出力が意図した通り支持または不支持になっているかを判定するために使用され，意図した通りの関係が付与されれば正解，それ以外は不正解となる．出力の説得性は命題間の関係性が支持または不支持と判定された場合にのみ付与し，その説得性を表す（1 点：ほとんど説得性がない〜5 点：かなり説得性がある）．2 名の作業者が作業を行った．作業の前に，付与される関係性が支持と不支持に偏らないよう，発話間の関係を付与する課題であると教示を与えた．また，提示する評価用の事例の順番はシャッフルしておき，どの手法で生成された論拠かは作業者にわからないようにした．

*1 http://wisdom-nict.jp/#top

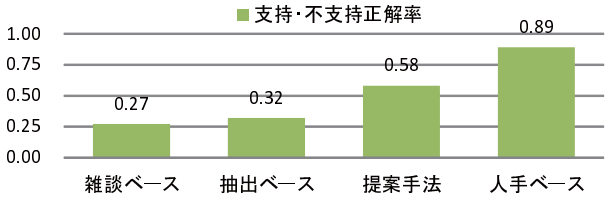


図 3: 出力した命題の支持・不支持が正しく判定された割合

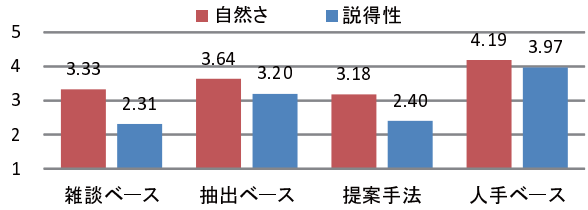


図 4: 出力の自然さと説得性（支持・不支持が正しく判定されたもののみ）

3.3 評価結果

図 3 に，付与された命題間の関係性に基づく，各手法の出力した命題の正解率を示す．図 3 から，**人手ベース**には高い適合率で正しく支持または不支持が付与されたことがわかる．**提案手法**は，**人手ベース**よりは低いものの，**雑談ベース**や**抽出ベース**と比較して，より多くの命題に対して適切な支持または不支持の論拠を生成できていることがわかる．

図 4 に，生成された命題の良さを調査するため，命題間の関係性が正しく判定された出力における命題の自然さと論拠としての説得性を示す．図 4 から，**人手ベース**は自然さ，お

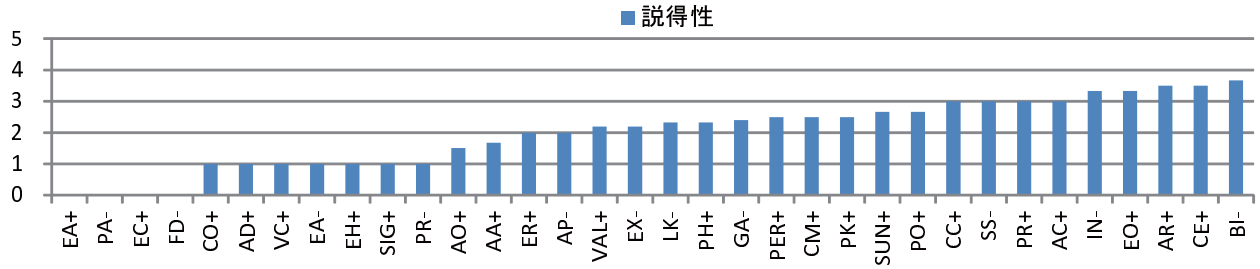


図 5: 議論スキームごとの説得性（支持・不支持が正しく判定されたもののみ）．説得性の値が 0 の議論スキームは，支持・不支持が正しく判定された出力がなかったものを表す．

表 3: 説得性が高い議論スキームのみに限定した場合の説得性の変化（支持・不支持が正しく判定されたもののみ）

使用する議論スキーム	説得性
上位 20%（CC ＋まで 6 種類）	3.38
上位 40%（PER ＋まで 12 種類）	3.12
上位 60%（VAL ＋まで 18 種類）	2.83
上位 80%（PR －まで 24 種類）	2.56
全スキーム（CO ＋まで 30 種類）	2.40

よび，説得性の両方で高い評価値が付与されていることがわかる．**提案手法**と**抽出ベース**を比較すると，自然さは共に 3 点以上であるものの，説得性に大きな差があることがわかる．この結果から，**抽出ベース**では，論拠が適切に抽出できれば，人手に近い高い説得性の論拠を出力することが可能であるとわかる．また，**提案手法**では，出力された全ての命題が論拠として説得性のあるものであるとは限らないということがわかる．

図 5 に，**提案手法**において，論拠の生成に利用した議論スキームごとの説得性の違いを調査するために，議論スキームごとの説得性の平均値を示す．図 5 から，説得性が高く判定された議論スキーム（“BI －” など）と，説得性が低く判定された議論スキーム（“EA －”）があることがわかる．説得性が低く判定された議論スキームの出力を調査したところ，論拠の出力が難しい議論スキーム（因果関係を用いる “PR ＋” や “CO ＋” など）では，不自然な命題が出力されており，説得性が低くなっている傾向がわかった．また，一般的な対話において使用されにくい議論スキーム（根拠なく相手を攻撃する “EA －” など）も含まれていることがわかった．

表 3 に，議論スキームごとの論拠の説得性の違いの傾向の調査結果をもとに，説得性が高い上位のスキームのみを使用した場合の説得性の平均を示す．表 4 から，生成に利用するスキームを上位 40%（12 種類）までに限定することで，**提案手法**でも，**抽出ベース**と同程度の説得性を持つ命題を出力可能なことがわかる．

表 4 に，提案手法の出力の例を示す．不自然な表現も一部含まれているものの，入力に対して様々な支持と不支持の論拠を出力できていることがわかる．

4. おわりに

本稿では，議論対話システムの実現に向けて，与えられた命題の論拠となる命題を議論スキームに基づき生成する生成ベースの手法を提案した．既存の抽出ベースとの比較を行う評価実験を行い，抽出ベースと比較してよりさまざまな入力に対して論拠を生成できることを確認した．今後は生成した論拠を用いた議論対話システムの構築や，生成した論拠を入力としてさらに論拠を推定する問題に取り組み，議論対話システムの実現を目指す．

表 4: 提案手法の出力例（入力が「田舎は空気が良い」の場合）

スキーム	生成された論拠
AA ＋	同じように田舎は雰囲気も良い
AD ＋	田舎は自然が良い
CO ＋	例えば田舎は葉が良い
EX －	田舎は空気が悪い場合もある
CE ＋	田舎は天気が良い
EC ＋	田舎は風に当たる
EH ＋	田舎は天気が良いならば空気が良い
SIG ＋	田舎は天気が良いのは空気が良いことの兆候だ
LK －	その考えは一般的とは言えない
BI －	それは田舎に対する先入観だ

参考文献

[Higashinaka 14] Higashinaka, R., Imamura, K., Meguro, T., Miyazaki, C., Kobayashi, N., Sugiyama, H., Hirano, T., Makino, T., and Matsuo, Y.: Towards an open domain conversational system fully based on natural language processing, in *Proc. COLING*, pp. 928–939 (2014)

[Higashinaka 17] Higashinaka, R., Sakai, K., Sugiyama, H., Narimatsu, H., Arimoto, T., Fukutomi, T., KiyoakiMatsui, , Ijima, Y., Ito, H., Araki, S., Yoshikawa, Y., Ishiguro, H., and Matsuo, Y.: Argumentative dialogue system based on argumentation structures, in *Proc. SemDial* (2017)

[Imamura 14] Imamura, K., Higashinaka, R., and Izumi, T.: Predicate-argument structure analysis with zero-anaphora resolution for dialogue systems, in *Proc. COLING* (2014)

[Isahara 08] Isahara, H., Bond, F., Uchimoto, K., Utiyama, M., and Kanzaki, K.: Development of Japanese WordNet, in *Proc. LREC* (2008)

[Lippi 16] Lippi, M. and Torroni, P.: Argumentation mining: State of the art and emerging trends, *ACM Transactions on Internet Technology*, Vol. 16, No. 10 (2016)

[Mikolov 13] Mikolov, T., Chen, K., Corrado, G., and Dean, J.: Efficient Estimation of Word Representations in Vector Space, in *Proc. CoRR* (2013)

[Rakshit 17] Rakshit, G., Bowden, K. K., Reed, L., Misra, A., and Walker, M.: Debbie, the Debate Bot of the Future, in *Proc. IWSDS* (2017)

[Sakai 18] Sakai, K., Inago, A., Higashinaka, R., Yoshikawa, Y., Ishiguro, H., and Tomita, J.: Creating Large-Scale Argumentation Structures for Dialogue Systems, in *Proc. LREC (appeared)* (2018)

[Speer 12] Speer, R. and Catherine, H.: Representing General Relational Knowledge in ConceptNet5, in *Proc. LREC* (2012)

[Walton 13] Walton, D.: *Methods of argumentation*, Cambridge University Press (2013)

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

コーパスとシソーラスを用いた比喩生成

Metaphor creation using corpus and thesaurus

佐藤　遼河[*1]
Ryoga Sato

杉本　徹[*2]
Toru Sugimoto

*1　芝浦工業大学大学院　理工学研究科
Graduate School of Engineering and Science, Shibaura Institute of Technology

*2　芝浦工業大学　工学部
College of Engineering, Shibaura Institute of Technology

We propose a method to create metaphors using corpus and thesaurus. Our system can create metaphors based on input tenors and grounds. We use word2vec to obtain word vectors for tenors and grounds, which are used to select vehicles considering cosine similarity. In order to output various vehicles that are congenial to the ground, we create a grounds-by-categories matrix using thesaurus. We evaluate appropriateness and usefulness of vehicles that are created by our system. As the result, it is shown that our system can output metaphors that are useful for user, though many of the metaphors created by the system are inappropriate. We compared vehicles created using Aozora Bunko corpus and NWJC. As the result, it is shown that our system can output vehicles that are congenial to user's literary style by using appropriate corpus.

1. 研究背景と目的

近年、小説投稿サイトの利用やセルフパブリッシングにより個人での執筆活動を公開する機会が増えている。それに伴い、読者にイメージが伝わりやすい表現を用いることへの需要が高まっている。イメージが伝わりやすい表現方法の一つとして比喩が挙げられる。しかし喩える語（喩辞）と喩えられる語（被喩辞）の関連性を考慮した上でことば選びをする必要があるため、比喩を作成することは難しい。

本研究は文章中のユーザが指定した語に対応する比喩を生成し、ユーザに提案するシステムを構築することが目的である。システムは入力された被喩辞と被喩辞の特徴を表す語（特徴語）から、執筆活動に用いることができる喩辞を複数生成し、提示する。システムが比喩の作成を支援することで、ユーザは容易にイメージが伝わりやすい表現を用いることができるようになる。比喩は直喩、隠喩、換喩、提喩に分類できるが本研究では直喩のみを扱う。

比喩の自動生成を目指した研究としては[北田　2001] [中條 2017]などがある。北田らは被喩辞と喩辞の概念的な近さ、カテゴリの近さ、共起のしやすさを考慮するために EDR 電子辞書を用いて比喩の生成を行った。中條らは毎日新聞をコーパスとした共起行列を用いて比喩の生成を行った。

本研究では word2vec[Mikolov 2013]とシソーラスを用いて比喩を生成する。word2vec を用いることでユーザが執筆する文章のジャンルに合わせたコーパスを選ぶことができる。またシソーラスを用いることで特徴語と共起しやすい意味カテゴリに属する単語を優先的に出力する。

本稿では提案手法と青空文庫コーパスを用いて生成された比喩の評価実験の結果を報告し考察を行う。また別のコーパスとして国語研日本語ウェブコーパスを用いて比喩を生成し、青空文庫コーパスを用いて生成された比喩との比較を行った。

連絡先：佐藤遼河，芝浦工業大学大学院　理工学研究科，
〒135-8548　東京都江東区豊洲 3-7-5，
E-mail:al14044@shibaura-it.ac.jp

2. 提案手法

2.1　比喩生成の処理手順

提案手法の処理の流れを図 1 に示す。

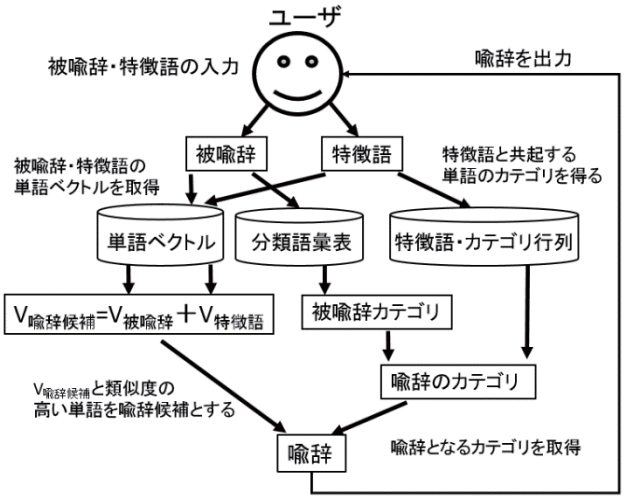


図 1　提案手法の概要

システムの処理手順を以下に示す。

①ユーザが被喩辞と特徴語を入力

被喩辞は名詞、特徴語は形容詞、形容動詞、動詞のいずれかとする。例えば「少女はＡのように美しい」という比喩を生成

するのであれば、被喩辞として「少女」、特徴語として「美しい」を入力する。

②喩辞候補のベクトルを取得

被喩辞と特徴語に対応する単語ベクトルを取得する。この単語ベクトルは予め word2vec を用いて作成したものである。次に被喩辞のベクトルと特徴語のベクトルを加算して、得られたベクトルを喩辞候補のベクトルとする。喩辞候補のベクトルとコサイン類似度が高い単語ベクトルをもつ名詞が喩辞候補となる。

③喩辞のカテゴリを取得

システムは特徴語・カテゴリ行列を参照して、特徴語と共起しやすい単語のカテゴリを得る。ここから被喩辞のカテゴリを除いたものが喩辞のカテゴリとなる。

④喩辞の出力

②で取得した喩辞候補のうち、③で取得したカテゴリに属する語を喩辞として出力する。

2.2 特徴語・カテゴリ行列

特徴語を行、分類語彙表[国立国語研究所 2004]に基づく名詞のカテゴリを列とする共起行列を作成して用いる。

特徴語は名詞の特徴を表す形容詞、形容動詞、動詞の原形である。本研究では IPA 辞書において形容詞、名詞の形容動詞語幹、動詞の自立語に属する語であり、コーパス中に出現する語を扱う。

カテゴリは分類語彙表の中項目の名前である。分類語彙表の中項目の中で喩辞として適切でない語は予め取り除いた。喩辞として適切でない語とは抽象的な語、固有名詞、倫理的に不適切となりうる語である。

行列を作成するために、まずコーパス中の文章を係り受け解析し、特徴語と共起する名詞を含むカテゴリを抽出する。ここで、共起する名詞とは、特徴語が形容詞と形容動詞の場合は係り先、動詞の場合は係り元と係り先の文節中の名詞であるとする。例えば「冷たい雪に覆われた」という文の場合、「冷たい」と「覆われる」は「雪」と係り受けの関係にあるので、「冷たい」と「覆われる」は「雪」のカテゴリである「物質カテゴリ」と共起する。

本研究ではコーパスとして青空文庫に掲載されている作家 83 人分の文章を約 313MB 用いた。また係り受け解析には CaboCha を用いた。

行列の要素 a_{ij} の値は以下の式で求める。

$$a_{ij} = \frac{\textit{特徴語}i\textit{とカテゴリ}j\textit{の単語が共起する回数}}{\textit{カテゴリ}j\textit{の単語の総出現回数}}$$

特徴語を表す行において要素の値が大きいものから順に喩辞のカテゴリの候補とする。

2.3 単語ベクトル

単語の分散表現ベクトルは word2vec の skip-gram を用いて 100 次元のベクトルを生成した。word2vec はコーパスからニューラルネットワークの学習を行い、単語の意味を表す固定長ベクトルを獲得する手法である。単語ベクトルはそれぞれの見出しの単語に対して float 型 100 次元の配列によって表現されている。入力された被喩辞、特徴語と一致する見出しを持つ単語ベクトルを求め、取得した 100 次元の配列をそれぞれ被喩辞ベクトルと特徴語ベクトルとする。

本研究ではコーパスとして前節で述べた青空文庫の文章において単語の活用形を基本形に直したものを用いた。表 1 に word2vec 実行時の各種パラメータを示す。

表 1 青空文庫をコーパスに用いたときの word2vec 実行時のパラメータ

CBOW or skip-gram	-cbow	0
次元数	-size	100
文脈長	-window	8
負サンプリング数	-negative	25
階層化 softmax	-hs	0
最低頻度閾値	-sample	1e-4
反復回数	-iter	15

3. 評価実験

3.1 生成された喩辞の適切性の評価

3.1.1 評価方法

生成された喩辞に対してアンケートによる定量的な評価を行った。10 種類の被喩辞と特徴語のペアをシステムに入力し、出力された喩辞を 5 人の被験者にすばらしい(4)、適切である(3)、判断が難しい(2)、不適切(1)の 4 段階で評価してもらった。アンケートでは被験者に「『被喩辞』は○○のように『特徴語』」という文を提示し、○○に喩辞を当てはめた場合の適切さを評価してもらう。例えば被喩辞「少女」、特徴語「美しい」の例では「少女は○○のように美しい」という文を提示する。

本実験ではシステムが生成する喩辞を喩辞候補ベクトルとのコサイン類似度が 0.5 以上かつ各カテゴリの上位 5 位以内の単語とし、最大で 50 語を出力した。

3.1.2 結果

表 2 に喩辞の出力結果の例を示す。

表 2 喩辞の出力例

入力 被喩辞, 特徴語	喩辞の カテゴリ	生成された喩辞
ひとみ, 光る	天地	二日月
		夜空
	物質	黒曜石
		夕焼け
	資材	たいまつ
		イルミネーション
ラジオ, 鳴る	物質	雷
		春雷
	道具	鐘
		ベル
	言語	サイレン
		警鐘
人生, 儚い	物質	うたかた
		泡沫
	心	夢幻
		追憶
	芸術	哀詩
		悲劇

次に喩辞の評価結果を表 3 に示す。

表 3　喩辞に対する評価の割合

喩辞数	4	3	2	1
477 個	4.2%	13.1%	12.3%	70.4%

生成された喩辞の 17.3%がすばらしい、または適切であるという結果が得られた。また入力した被喩辞と特徴語のペアのうち、コサイン類似度が 0.5 を上回る喩辞の候補が少なかったため、50 個の喩辞が得られないものが 3 組あった。

3.2 比喩の有用性の評価

3.2.1 評価方法

本実験では前節の実験で評価が高かった喩辞を被喩辞と特徴語のペアごとに上位 10 個ずつ用いて有用性の評価を行う。比較対象として文芸サークルに所属する大学生が作成した喩辞を被喩辞と特徴語のペアごとに 10 個ずつ用いる。6 人の被験者に被喩辞と特徴語を提示し、システムが生成した 10 個の喩辞と人が作成した 10 個、合計 20 個の喩辞をランダムに提示する。被験者は比喩として用いたいと思う表現を提示された喩辞の中から 5 個選択し回答する。

本実験で用いた喩辞の例を表 4 に示す。

表 4　評価に用いた喩辞の例

被喩辞：少女　特徴語：美しい	
システム	人
令嬢	サクラ
姫	女神
聖女	満月
騎士	初雪
女王	オーロラ
ヒロイン	星座
女優	花火
舞姫	宝石
花	夜空
人形	ダイアモンドダスト

3.2.2 結果

被験者が選んだ喩辞のうちシステムが生成した喩辞の割合は 35.3%、人が作成した喩辞は 64.7%であった。このことからシステムが生成した喩辞に一定の有用性があることが分かった。被喩辞ごとの評価結果を図 2 に示す。

システムが生成した喩辞と人が作成した喩辞のうち、共通して得られたのは「被喩辞:ラジオ,特徴語:鳴る」に対する喩辞「雷」のみだった。この点から本システムは人が比較的思いつきにくい喩辞を提案できることが分かった。

生成された喩辞のうち 10 個中 9 個の比喩において有用な喩辞が得られた。有用な喩辞を得られなかった比喩は被喩辞「船」、特徴語「大きい」だった。これは「大きい」という特徴語が相対的な特徴語であるからだと考えられる。被喩辞「船」、特徴語「大きい」の評価に用いた喩辞とアンケートの結果を表 5 に示す。

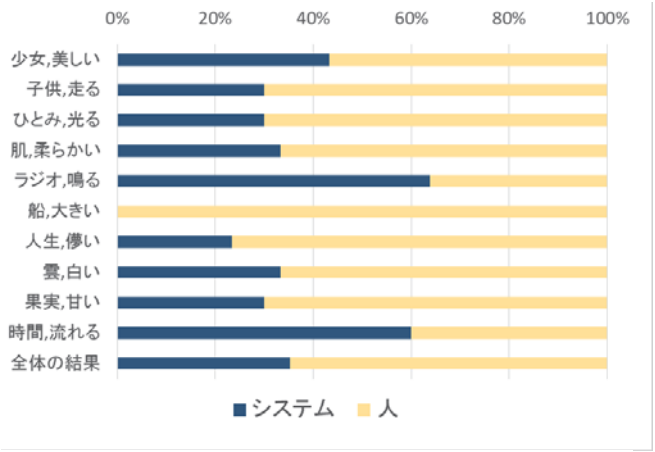


図 2　有用性の評価結果

表 5 「船が大きい」のアンケートの結果

被喩辞：船　特徴語：大きい			
システム		人	
太鼓腹	0人	山	5人
頭でっかち	0人	鯨	4人
巨体	0人	島	5人
海	0人	建物	1人
陸	0人	軍艦	3人
防波堤	0人	城	6人
ガスタンク	0人	要塞	3人
倉庫	0人	岩	2人
格納庫	0人	ドーム	1人
ロケット	0人	マンモス	0人

他の比喩における特徴語は「美しい」、「走る」、「光る」、「柔らかい」、「鳴る」、「儚い」、「白い」、「甘い」、「流れる」であり、いずれも絶対的な特徴である。例えば「花」の「美しい」という特徴は比較対象がある場合でも存在する。また「子猫」が「走る」という特徴も他の比較対象が「走る」場合でも失われない。一方「太鼓腹」の「大きい」という特徴は相対的な特徴であるため、「船」と比較した場合は失われる。つまり「太鼓腹」は「船」よりも小さい。「船」の「大きい」という特徴を強調するために「太鼓腹」という船より小さいもの用いたことで比喩として不適切になったと考えられる。

4. コーパスによる出力の差異

4.1 実験

コーパスによる出力の差異について調べる。本システムはユーザの執筆する文章のジャンルに合わせたコーパスを用いることで、より文章に適したことば選びができると期待できる。

本実験では word2vec を作成する際のコーパスとパラメータを変え、異なる単語ベクトルを用いて比喩を生成する。喩辞を生成する際に入力する被喩辞と特徴語は前節で用いた組み合わせと同じものを用いる。

4.2 使用する単語ベクトル

比較するベクトルは青空文庫をコーパスとして作成した単語ベクトル（以下「青空文庫単語ベクトル」と称する）と浅原らの作成した nwjc2vec[浅原 2017]である。nwjc2vec は国語研日本語ウェブコーパス（NWJC）から word2vec の CBOW を用いて生成した 200 次元の単語ベクトルである。国語研日本語ウェブコーパスはウェブ上の日本語テキストを利用した大規模コーパスである。

表 6 に nwjc2vec を生成する際の word2vec 実行時の各種パラメータを示す。

表 6 nwjc2vec を生成する際に用いられた word2vec 実行時のパラメータ

CBOW or skip-gram	-cbow	1
次元数	-size	200
文脈長	-window	8
負サンプリング数	-negative	25
階層化 softmax	-hs	0
最低頻度閾値	-sample	1e-4
反復回数	-iter	15

4.3 結果

はじめに前節の実験と同様にシステムが生成する喩辞をコサイン類似度が 0.5 以上かつ各カテゴリの上位 5 位以内の単語とし、最大で 50 語を出力した。その結果得られた喩辞は 108 個だった。青空文庫単語ベクトルが 477 個の喩辞を得たことと比較すると、得られた喩辞は少なかった。これはコサイン類似度が 0.5 以上の喩辞の候補が少なかったためである。そこで本実験では多くの喩辞を得るため、コサイン類似度が 0.4 以上の語を喩辞として出力する。

nwjc2vec を用いた場合の喩辞の出力例を表 7 に示す。

表 7 nwjc2vec を用いた喩辞の出力例

入力 被喩辞, 特徴語	喩辞の カテゴリ	生成された喩辞
ひとみ, 光る	植物	さゆり
		まゆみ
	物質	三日月
		流れ星
	物質	陽子
		ルビー
ラジオ, 鳴る	物質	遠雷
	道具	チャイム
		ホイッスル
	成員	DJ
	言語	サイレン
		警鐘
人生, 儚い	社会	今生
		現世
	心	夢
		思い出
	芸術	物語
		悲喜劇

コサイン類似度が 0.4 以上かつ各カテゴリの上位 5 位以内の単語を最大で 50 語を出力するという条件で喩辞は合計 332 個得られた。

nwjc2vec を用いたことで青空文庫単語ベクトルとは異なる表現を得ることができた。例えば「被喩辞：ラジオ,特徴語：鳴る」に関して nwjc2vec を用いたことで「DJ」や「ホイッスル」などの喩辞を取得した。これは「DJ」や「ホイッスル」のような単語は青空文庫には用いられないが、ウェブでは一般的に用いられているからであると考えられる。一方、青空文庫単語ベクトルを用いた場合と同様に「遠雷」や「サイレン」や「警鐘」や「鐘」などの喩辞が得られた。nwjc2vec と比較すると、青空文庫単語ベクトルの方が同じ意味の語でも仰々しい言い回しの語が出力された。例えば nwjc2vec では「夢」や「思い出」が出力されているのに対し、青空文庫単語ベクトルでは「夢幻」や「追憶」が出力された。このことから nwjc2vec は現代が舞台の物語や説明的文章を書くときに用いる比喩に適している。一方青空文庫単語ベクトルは古風な表現が求められる歴史小説や伝奇小説、荘厳な世界観を表現するファンタジー小説を書くときに用いる比喩に適している。

nwjc2vec を用いた場合、多義語の問題があった。例えば「被喩辞：ひとみ,特徴語：光る」では被喩辞の「ひとみ」が nwjc2vec のベクトルでは眼球や目という意味だけでなく、女性の人名を表す語としての意味を表している。その結果コサイン類似度の上位に植物カテゴリからは「さゆり」や「まゆみ」、物質カテゴリから「陽子」などの女性の人名を表す語が出力されている。これはウェブで出現する人名の中に一般名詞としての意味をもつ語が多いからだと考えられる。

5. 結論

本研究では被喩辞と特徴語の入力に対してコーパスとシソーラスを用いて喩辞を生成する方法を提案した。今回行った実験により提案手法に一定の有用性があることが分かった。またコーパスを変えることで執筆する文章に合わせた喩辞が出力できることも分かった。提案手法を用いることでユーザは容易に比喩を用いることができるようになると期待できる。

今後の課題は出力された喩辞の適切性の低さの問題、相対的な特徴を表す喩辞をどのように扱うかという問題、多義語によって想定と異なるカテゴリの語が出力される問題の 3 つが挙げられる。

参考文献

[北田 2001] 北田純弥, 萩原将文：電子辞書を用いた比喩による文章作成支援システム, 情報処理学会論文誌, Vol.42, No.5, pp.1232-1241 (2001)

[中條 2017] 中條寛也, 松吉俊, 内海彰：意味空間に基づく文脈情報を用いた比喩生成, 情報処理学会研究報告, Vol.2017-NL-231, No.14, pp.1-10 (2017)

[国立国語研究所 2004]国立国語研究所：分類語彙表 増補改訂版, 大日本図書 (2004)

[Mikolov 2013] T. Mikolov, K. Chen, G. Corrado, and J. Dean：Efficient Estimation of Word Representations in Vector Space. In ICLR Workshop (2013)

[浅原 2017]浅原正幸, 岡照晃：nwjc2vec：『国語研日本語ウェブコーパス』に基づく単語分散表現データ, 言語処理学会第 23 回年次大会発表論文集 (2017)

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

統合物語生成システムの未結合諸要素と属性情報による概念辞書の拡張

Uncombined Elements in an Integrated Narrative Generation System and Expanding Conceptual Dictionaries by Attribute Information

小野淳平*1 Jumpei Ono
伊藤拓哉*2 Takuya Ito
小方孝*2 Takashi Ogata

*1 岩手県立大学大学院 Graduate School of Iwate Prefectural University
*2 岩手県立大学 Iwate Prefectural University

Although we have been studying diverse elements of narrative generation, many of the elements have not been combined with our basic narrative generation system called Integrated Narrative Generation System (INGS). In this paper, we list these elements and especially focus on the part of the attribute information of noun concepts in the noun conceptual dictionary in the INGS. We introduce the attribute information into the noun conceptual dictionary to aim at various effects including detailed conceptual explanation generation and rich narrative character formation.

1. はじめに

統合物語生成システム（Integrated Narrative Generation System: INGS）[Ogata 2016]は，物語生成に関連した筆者らの研究及び開発の成果を有機的に結合したシステムである．INGS は物語において生起した内容，語り手が如何にしてその内容を語るかといった部分，さらに文字，音，絵などの物語の表現部分まで，一貫した生成を行うことが可能である．

INGS における物語生成の流れは，固定されていない．生成を開始する機構を柔軟に変化させることで，文，音楽，映像など様々な入力に対応し，そして，各種機構を利用するタイミングもまた動的に変化することで，循環的な生成が可能となる．

また，生成パラメータを自動的に調整する手段として，ランダム生成を試みた[小方 2016; Ono 2018]．ランダムに決定されたパラメータに基づき生成された結果を，「良い」あるいは「悪い」といったように単純に評価し，生成パラメータのどのような点が評価に影響を及ぼしたのかを，システムに検討させる方法である．生成・評価・検討を繰り返すことで生成パラメータを徐々に，特定の方向へ調整させる．しかし，INGS に自由な生成を行わせるためには，大きな知識ベースが必要となる．そのため，筆者らは，自動的な知識獲得も試みている[小野 2014; Ono 2018]．

既に筆者らは，概念辞書及び言語表記辞書の構造並びに利用方法の拡張構想[小方 2015a]について述べており，3 節ではそれらも踏まえた形で，変更点・拡張点を示す．また，3 節で述べる成果統合に関する課題のうち，属性情報に関する成果統合，本稿で実施しさらに課題を考察する．

2. 統合物語生成システムの構造に関して

図 1 は INGS の各種機構の構成図である．大きく分けて，ストーリー生成機構，物語言説機構，物語表現機構があり，物語表現機構は，文生成機構，音楽生成機構，映像生成機構を持つ．ストーリー生成及び物語言説生成では，物語の構造を生成し，物語表現機構は物語の表層表現を生成する．各機構の周辺には，物語生成のための知識ベースや概念辞書がある．

連絡先：小野淳平，岩手県立大学大学院，岩手県滝沢市巣子 152-52，019-694-2000，g236m001@s.iwate-pu.ac.jp

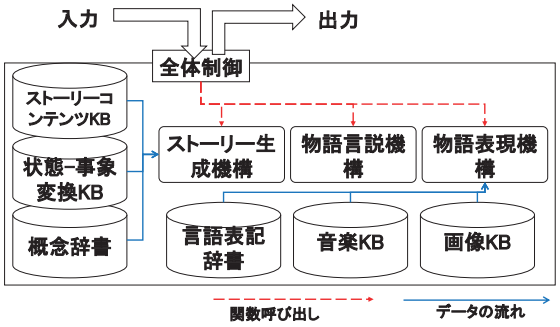


図 1 INGS における各種機構の構成

INGS における物語は木構造が基本である．図 2 は，抽象化したストーリーの木構造である．実際のデータ構造では，事象が終端ノードとなり，関係が中間のノードとなる．状態は，ID によって二つの事象と論理的に結びつく．物語言説では，物語言説構造用の関係ノードがあり，音楽木は，ストーリー木や物語言説木と対応する音楽専用の構造を持つが，物語言説構造も含めて別稿[Ogata 2016]に任せてここでは説明を省略する．

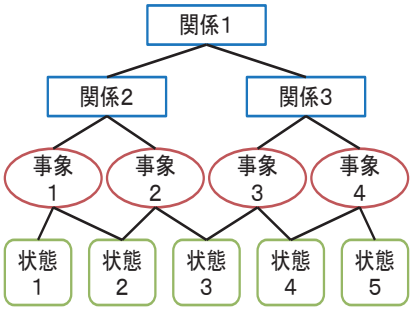


図 2 ストーリーの木構造の例

INGS の開発ではその大部分を Common Lisp により実装した．そのため，生成に用いる辞書や知識ベースの多くは，Lisp 言語におけるリスト形式（またはフレーム形式）によるデータ構造を持つ．音声や画像など上記データ構造で表現が難しいデータも，階層化されたリスト形式のデータと対応関係を持つ．入出

力でやりとりするファイルの形式は，基本的に拡張子「txt」ファイルであり，音楽生成では「mml」や「midi」，画像/映像生成では「jpg」をシステム内で編集する．

文字・記号は，Lisp 言語により開発した機構で処理を行うが，音声処理や映像処理では，他のプログラミング言語やツールを用いており，インタプリンタ言語『Hot Soup Processor』[1]，Music Macro Language による音楽作成ツール『テキスト音楽「サクラ」』[2]，NHK 放送技術研究所が開発した 3D の映像作成ツール『TVprogram Making Language』[3]，歌声合成ツール『UTAU』[4]を利用した．また，知識獲得等においてテキスト解析には，形態素解析器『MeCab』[5]，文章統計分析ツール『KH Coder』[6]を利用している．

3. 開発成果の統合における課題

ここでは，INGS に関連する筆者らの研究・開発のうち，現状の INGS と未統合の成果を列挙し，その課題を示す．加えて，知識ベースや辞書を編集するために開発したツールも示す．

3.1 生成に関する知識ベース及び辞書

まず，物語の構造の生成や表層的な表現を生成するうえで必要となる，知識ベース及び辞書に関連した内容を説明する．また知識構造の修正や規模の拡張だけでなく，知識の自動獲得についても触れる．

- **動詞概念辞書の修正**：動詞概念辞書は，動詞を階層的に体系化した辞書である．中間ノードは動詞のカテゴリを示す中間概念であり，終端ノードは実際のストーリーに現れる動詞を示す動詞概念である．動詞概念は，文生成に用いる基本的な表現を示す文型パターン，必須格を示す格構造，各々の格がとり得る値を示す制約条件を持つ（制約条件は後述する名詞概念の中間概念によって記述される）．以上の三要素は格を媒介として，論理的に結びついている．記述形式上の問題として，後述する知識獲得により，生成の際に参照される動詞概念の種類が大幅に拡大されたため，現状，格構造及び制約条件における記述形式上のミスによる生成エラーが多く網羅的に修正する必要がある．意味的な側面では，階層構造の粗さや制約条件の緩さが挙げられ，3.2 節で述べる逸脱機構において，動詞概念に対するより細かい逸脱の調整が可能となる．
- **固有名詞概念辞書の導入**：名詞概念辞書は，名詞を体系化した辞書である．一般名詞を格納した辞書は，カテゴリを示す中間概念と実際にストーリーに現れる名詞概念を持つ．固有名概念辞書は，一般名詞の終端概念と論理的に結びついた固有名詞のカテゴリ及び固有名詞概念を格納した辞書である．現状は一部分だけ実験的に連結した[寺田 2014]．
- **属性情報の結合**：属性情報は，ある物事の特徴・性質に関する記述である．以降では属性情報を属性と記述する．名詞概念辞書における名詞概念は，一般名詞，固有名詞を問わず属性を持つ．筆者らは属性の自動獲得を試み，Wikipedia から属性を獲得した．それらの属性を実際の概念辞書と結びつける．本稿では，属性の統合の試みを行っており，4 節にてさらに具体的な説明を述べる．
- **修飾概念に対する言語表記辞書の利用方法**：言語表記辞書とは，名詞概念，動詞概念，修飾概念及び助詞に対して，文字による記述方法を指定する辞書である．特に文生成機構で用いる辞書であり，「漢字＋ひらがな」，「ひらがなのみ」，「カタカナのみ」，「ローマ字のみ」の 4 種類の表記方法を格納した（カタカナ語など一部は漢字表記を含まない）．修飾概念は，形容詞概念，形容動詞概念，副詞概念を持つ．
- **スクリプト知識ベースの拡張**：ストーリーコンテンツ知識ベースは，ストーリーの構造を生成するための知識を格納した知識ベースであり．ストーリー生成の形式的手法であるストーリー技法と対応関係にある．ストーリーコンテンツ知識ベースは，因果関係の知識など格納する知識ごとに知識ベースは存在する．筆者らは主にスクリプト知識の自動獲得[荒井 2017]を試みてきた．スクリプト知識は，二つ以上の事象によって構成された，生起順に基づく事象の連なりである．獲得したスクリプトはランダム生成の試み[Ono 2018]でも使用したが，現状，INGS におけるスクリプト知識ベースは，獲得したスクリプト知識を格納していない．
- **CM 分析における中核使用法**：物語生成の応用例として，TV で流れる CM(CF)分析を筆者らは試みてきた[萱森 2003; 阿部 2009]．この分析では，実際の CF におけるストーリーの流れをショットごとに分析した．その分析では，商品の種類ごとに，その商品を使用する際の流れ（中核使用法）が知識として用意できており，それらの知識は，スクリプト知識として利用できると考えており，そのために中核使用法を現在の知識ベースの記述形式で整理する必要がある．
- **プロップに基づくストーリーコンテンツグラマー**：プロップに基づくストーリーコンテンツグラマー(Propp-based Story Contents Grammar: PBSCG)[小方 2015b]は，プロップが述べた物語の構造に関する理論をモデル化し，ストーリーグラマーとして実装したストーリー技法である．知識及び形式的手続きの各一部分の統合に留まり，最新バージョンは未統合である．

3.2 物語の構造の生成及び変形に関連する成果

この節では，INGS における生成過程のうち，特に物語の構造に関連する成果を整理する．一部は 3.1 節や続く 3.3 節と関連する内容もある．

- **統計情報の利用**：ここでの統計情報とは，任意の既存のテキストの範囲内における，ある語についての出現頻度や他の語との共起関係を表す値である．獲得した統計情報は，概念辞書の概念と結びつけられ，各概念の統計情報として利用可能とした（但し現状，語の言語表記を基準に対応付けしたため，意味的な対応付けは不完全である）．筆者らは，青空文庫に格納された既存の作品を対象とし，頻度情報[吉田 2016]及び共起情報[照井 2016]を獲得した．さらに概念辞書に格納された各概念選択の機構を最新の INGS に統合する必要がある．
- **属性の利用（説明文生成）**：3.1 節で述べたように，属性はある物事の特徴・性質に関する記述である．そのため，ストーリー生成などにおいて，属性を用いた説明文構造の

[1] http://hsp.tv/ (最終アクセス 2018.3.4)
[2] https://sakuramml.com/index.php? (最終アクセス 2018.3.4)
[3] https://www.nhk.or.jp/strl/tvml/index.html (最終アクセス 2018.3.4)
[4] http://utau2008.xrea.jp/ (最終アクセス 2018.3.4)
[5] http://taku910.github.io/mecab/ (最終アクセス 2018.3.4)
[6] http://khc.sourceforge.net/ (最終アクセス 2018.3.4)

挿入が可能である. 属性を参照する程度によって, 説明文の量や質が変化し, 例えば冗長さといったストーリーの質を調節する. 説明文機構の試作では, 獲得した属性の参照範囲によって, 説明文の文量を変化させる仕組みを導入した.

- **逸脱機構:** 3.1 節で述べた広告分析に基づく広告ストーリー生成手法から, 異化的修辞[Zhang 2012]を開発した. これは非常識的・非現実的な事象を生成し, 商品など特定要素を際立たたせる技法である. 生成の際には, 逸脱度を指定し, 逸脱度に基づいて動詞概念の持つ制約条件外の名詞概念を選択し, 逸脱した事象を生成する. INGS では一部実装済みであり, 異化的修辞を連続的に適用する異化的ストーリー生成技法を試作した.
- **ギャップ技法によるストーリー生成:** ある線形の時間的な流れにおいて, 人は, その先の事象を予測し, 実際に生起した事象との差(ギャップ)によって驚く. ギャップ技法とは, ストーリーに任意のギャップを与え, 受け手に対して驚きを与える技法である[小野 2017a]. 上で述べた異化的修辞を援用し, 筆者らはギャップ技法を開発した.
- **俳句生成:** 五・七・五の音で構成された俳句を生成する機構である. ストーリーと俳句の循環的な生成[伊藤 2017]を目指す方法と, 深層学習を用いる方法[五十嵐 2017]が存在する. どちらの生成結果も, データ構造の側面から見て, 現状の INGS の標準的な記述形式から異なる仕様のため, 直接的な統合は難しい.

3.3 表層表現の生成に関連する成果

この節では, INGS における生成過程のうち, 特に文・音楽・映像に関連する成果を説明する.

- **カメラワーク**: 筆者らは映像生成におけるカメラワーク技法として, 小津安二郎監督の東京物語におけるカメラワークの分析し, OZU ルールを開発した[小方 2009]. OZU ルールは, 小津監督のカメラワークのルールベース化であり, TVML による映像に対して, 小津監督風のカメラワークを与える. 現状の INGS における映像生成機構は, 二次元的画像を編集して映像生成するため, 三次元的な表現を伴うカメラワークの研究結果を反映しづらい. そのため, 共有可能な部分の検討が必要である. また, 東京物語における行為と動作の関係も分析した. その成果と映像生成機構が持つアニメーションデータベースとの統合することで, より細かなアニメーションの生成も可能となる.
- **音楽生成機構:** 物語の概念構造と音楽の構造の循環的な生成を目指した機構である[Akimoto 2013]. 音楽生成機構単独では, ストーリーから原曲, 物語言説から変奏曲, 原曲から変奏曲を生成可能である. 現状の INGS では, 以上の中から一部の機能を統合した. また応用システムでは, 音楽生成に用いる知識ベースのモチーフを偏らせ, 民話風の音楽が生成されるように調整した.
- **歌生成機構:** 研究としては未発表であり, 小さな試作を行った段階である. 音楽生成機構で出力される原曲と, 文生成機構で出力される文を組み合わせることで歌を生成する. 無伴奏であり, 原曲の音符一つに文の一文字を対応づけた midi ファイルが生成される.

3.4 知識の可視化・編集ツールなどその他の成果

この節では, 3.1 節で述べた生成に関連する知識や辞書の構造の可視化や編集を目的としたツールを示す.

- **階層構造可視化ツール:** INGS における物語の構造や概念辞書の構造は全容を一望しづらいため, リスト形式によるデータ構造を図形で表現するツールを用意した.
- **概念辞書記述形式チェッカー:** 動詞概念辞書における形式的な記述ミスをチェックするツールである. Lisp プログラミング上の括弧の数の間違いの他, 格構造と制約条件における格の数, 制約条件の記述ミスを判別する.
- **PBSCG における知識登録簡易ツール:** 任意のストーリーのあらすじを分解し, ストーリーコンテンツグラマーへ変換するためのツールである[藤原 2015]. あくまで人手による知識作成作業を補助するためのツールであり, 自動的な知識獲得の要素は持たない.
- **スクリプト半自動構成ツール:** 日本語で構成された文章を入力とし, 文章に含まれる動詞からスクリプト知識を構成するためのツールである[荒井 2017]. 動詞の抽出, 動詞概念の選択候補の列挙, スクリプト知識化した際の格構造の内容はツールが決定するが, より細かい動詞の意味の決定や格構造の修正はユーザが行う.

4. 属性と概念辞書の結合

この節では, 3 節で述べた成果のうち, 属性情報を取り上げ, INGS における概念辞書と結合する.

4.1 属性の概要

[影山 2012]は恒常的に持続する性質を記述する文を属性叙述文と呼び, 筆者らは属性叙述文の解析により, ある概念の特徴・性質を記述する属性の自動的な獲得を試みた[小野 2014].

INGS における属性は, 名詞概念辞書に格納された終端概念が持つ. 属性は構造化されたフレーム形式で記述される. これを属性フレームと呼ぶ. ストーリーに登場する人・物・場所・時間は, 名詞の終端概念に基づき生成されるインスタンスである. ストーリーに現れるあらゆるインスタンスは, 属性フレームにおける is-a スロットにより名詞概念と結びつく. あるインスタンスは, 結びついた名詞概念が持つ属性に加え, その時々における状態を記録するスロットにより, 属性フレームが構成される.

図 3 は獲得された属性の記述形式である. <対象概念>は属性と結びつく名詞概念を示し, <テーマ>は属性の種類を示す. 例えば「所在地に関する属性」,「外見に関する属性」等がある. <テーマに対する属性>は, 構造化された文が入る.

```
(<対象概念>
 (<テーマ 1>
    <テーマ 1 に対する属性 1>
    <テーマ 1 に対する属性 2>
    …<テーマ 1 に対する属性 n>)
  …(<テーマ m> …) …)
```

図 3 属性フレームの記述形式

名詞概念辞書に含まれる名詞概念のうち, 一般名詞の名詞概念の数は, 115765 個である. この名詞概念は, 具体的な物体を表すもの(食べ物や建物, 地形等の何らかの形を持つもの)から物事を表すもの(季節や思想, 職業等の形を持たない抽象的なもの)まで含まれる. これに対して, Wikipedia から獲得

された一般名詞の属性は 5615 個である(全一般名詞概念の約 5%)[小野 2017b]. さらに固有名詞の名詞概念は, 188340 個あり, 獲得できた属性は, 28932 個である(全固有名詞概念の約 15%).

4.2 属性の利用と課題

現状の INGS が生成する物語の木構造は, ある二つの状態間における変化を示した, 動的な情報である事象によって構成される. しかし, ある物事の特徴や外見の明ないし描写, ある時間における状態等の静的な内容の生成もまた必要な要素である. 例えば, 受け手にとって理解しづらい概念に対して説明文を挿入し, 受け手の理解を補助することが考えられる. そのため, 筆者らは知識獲得や説明生成を試みた[小野 2017b]. 4.1 節で述べた 5615 個の属性では, 60 のインスタンスで構成されたストーリーうち, 約 1 割のインスタンスに説明文が付与できた[小野 2017b]. しかし, より多くのインスタンスに対して, 説明文の付与を考える場合, 属性情報を持つ概念の数を増やすことが課題となる. 現状, 例えば日本語 Wikipedia の範囲のみで獲得を行った. そのため, テキストの解析と解析結果の属性化だけでなく, 関連テキストの収集も必要となるだろう.

5. おわりに

本稿では, INGS と統合していない筆者らの成果を列挙し, また統合による効果や統合に向けた課題等を示した. 特に名刺概念が持つべき属性に関して, 詳しく説明した. 以上の成果の統合は, INGS における物語生成を拡張し, 新たな応用システムの可能性を示すことができる.

参考文献

[阿部 2009] 阿部弘基, 小方孝, 小野寺康: 広告における商品導入の修辞の分析とシステムの構築, 2009 年度人工知能学会全国大会(第 23 回)論文集, 1J1-OS2-4, 2009.

[Akimoto 2013] Akimoto, T., Endo, J., & Ogata, T.: The Expansion of Paths in the Mutual Transformation Mechanism of Music and narrative, International Journal of Cognitive Informatics and Natural Intelligence, 7(4), 44-63, 2013.

[荒井 2017] 荒井達也, 小野淳平, 小方孝: 統合物語生成システムにおけるスクリプト型事象連鎖の獲得と利用, 言語処理学会第 23 回年次大会論文集, 703-706, 2017.

[藤原 2015] 藤原朱里, 小野淳平, 小方孝: プロップに基づくストーリーコンテンツグラマーを利用した知識登録・格納簡易ツールに基づく考察, 人工知能学会第二種研究会ことば工学研究会(第 48 回)資料, 57-66, 2015.

[五十嵐 2017] 五十嵐広太, 伊藤拓哉, 小方孝: 単語・文字をベースとした深層学習用いた俳句生成, 第 56 回ことば工学研究会資料, 33-34, 2017.

[伊藤 2017] 伊藤拓哉, 小方孝: 俳句／物語生成システムに関する考察, 第 56 回ことば工学研究会資料, 35-37, 2017.

[影山 2012] 影山太郎: 属性叙述の世界, くろしお出版, 2012.

[萱森 2003] 萱森修, 小方孝: 物語ーブランド関係に注目した TVCF の分析と CF シナリオ自動生成, 人工知能学会全国大会(第 17 回)論文集, 2G2-06, 2003.

[小方 2016] 小方孝, 荒井達也, 小野淳平: 統合物語生成システムを用いたランダム物語生成, 第 15 回情報科学技術フォーラム講演論文集, 133-134, 2016.

[小方 2015a] 小方孝, 小野淳平, 戸来裕紀, 五十嵐航, 白井柊太: 統合物語生成システムのための概念辞書及び言語表記辞書の構成・利用の拡張構想, 人工知能学会第二種研究会ことば工学研究会(第 48 回)資料, 51-56, 2015.

[小方 2015b] 小方孝, 藤原朱里:「機能」を具体化する方式の一般化―統合物語生成システムにおける Propp-based ストーリー生成機構の拡張―, 第 29 回人工知能学会全国大会論文集, 3G4-OS-05b-3, 2015.

[Ogata 2016] Ogata, T.: Computational and Cognitive Approaches to Narratology from the Perspective of Narrative Generation in Ogata, T., & Akimoto, T. (eds.), Computational and Cognitive Approaches to Narratology, IGI Global, 1-74, 2016.

[小方 2009] 小方孝, 立花卓, 富手瞬: 物語概念表現からの映像の生成と自動カメラワーク―『東京物語』の分析とシミュレーション, P2-32, 2009.

[小野 2014] 小野淳平, 小方孝: 名詞句の分類を利用した名詞概念の属性フレームの自動獲得―統合物語生成システムの一機構として―, 第 13 回情報科学技術フォーラム講演論文集 第二分冊, 335-338, 2014.

[小野 2017a] 小野淳平, 小方孝:「ギャップ技法」を利用して「驚き」を作り出すストーリー生成の方法―テーブルトークロールプレイングゲームに基づく物語自動生成ゲームへの一アプローチ―, 認知科学, 24(3), 410-430, 2017.

[小野 2017b] 小野淳平, 小方孝: Wikipedia を利用した概念辞書における属性情報の獲得と物語自動生成ゲームでの利用, 2017 年度人工知能学会全国大会(第 31 回)論文集, 1D3-OS-29b-2in2, 2017.

[Ono 2018] Ono, J. & Ogata, T.: Acquiring Short Scripts and Setting a Case Frame in Each Acquired Script: Toward Random Story Generation, Proc. of the 2018 International Conference on Artificial Life and Robotics, 663-667, 2018.

[寺田 2014] 寺田貴範, 秋元泰介, 小野淳平, 小方孝: 統合物語生成システムにおける固有名詞概念の体系的記述, 言語処理学会第 20 回年次大会, 217-220, 2014.

[照井 2016] 照井和舎, 小野淳平, 小方孝: 語の共起情報による概念・単語選択の改善―統合物語生成システムにおける利用―, 人工知能学会全国大会(第 30 回) 予稿集, 3P1-7in2, 2016.

[吉田 2016] 吉田和樹, 小野淳平, 小方孝: 語の頻度情報による概念・単語選択の改善―統合物語生成システムにおける利用―, 人工知能学会全国大会(第 30 回) 予稿集, 2P1-6in1, 2016.

[Zhang 2012] Zhang, Y., Ono, J. & Ogata, T.: The Rhetoric of Defamiliarization for Narrative Generation Using the Constraints in a Conceptual Dictionary, Proc. of the 34th Annual Meeting of the Cognitive Science Society, Poster 183, 2012.

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

Research on Sharing of Robotics Skills

Guilherme C. Affonso*1 Kei Okada Inaba Masayuki

The University of Tokyo, JSK Laboratory

Growing number of robots and increase in its capabilities impose new demands on meta robotic systems, capable of performing hardware abstraction and sharing skills between different robots. In this work such systems are studied, in order to make evident what can actually be done now and what are the problems that must be dealt with in the future.

1. Introduction

Holding the advent of deep learning and the third artificial intelligence boom as background [Matsuo 15], one of the keys of current robotics research is to be *Adaptable* and *Universal*. This gives place to the rise of robots as a new and tangible market, with total sales of household and personal service robots forecast to grow 23.5% per year from 2015 to 2020 [Grace Market Data 15]. Such demands feed robotics research back, in a cycle that leads to growth in both overall number and capabilities of robots.

Under such situation, the administration of specific programs build for specific platforms becomes more and more complex, urging for the unification of software into meta robotic systems capable of abstracting hardware and sharing skills between different robots. Although the creation of a system that can both solve different problems and be compatible with several robots is a common goal for robot software architects, as described in [Ferland 15], robotics research nowadays proves to be highly dependent on hardware platform and software implementation, focusing on environment adaptability rather than universality of execution.

In this work the sharing of skills between robots is explored, in order to delimit what can currently be done towards its solving and make clear what kind of problems still need to be overcome.

2. Definition and Classification of Skills

In order to reason about the sharing of robotic skills, it is necessary to first properly define them in clear and concrete terms. In this work we use the definitions proposed by Affonso et al. [Affonso 18b], modified from Jacobsson et al. [Jacobsson 16] and described as follows.

- **Skill**: *The potential for a robot to reproduce a certain task.*
- **Task**: *A set of actions with meaningful outcome.*
- **Action**: *A set of motions which cause an effect on the outside environment.*
- **Motion**: *Movements that alter the robot's physical state.*

Furthermore, classification of skills into joint, action point and objective level, also given at Affonso et al.'s [Affonso 18b] work, are used. These are described as follows.

1. **Joint level**
   At joint level, each motion is described by a vector gathering angle values for all of robot's degrees of freedom. Skills are the enumeration of such motions.
2. **Action point level**
   At action point level, skills are described by the trajectory of the end effector, with emphasis on its points of application. Possible relations with target objects and effects on the outside environments are also considered, being equivalent to the overall procedure for achieving the task in question.
3. **Objective level**
   At objective level, skills are solely described by the final state to be achieved, without further instruction on motions and subprocedures to be taken.

The above definitions are treated as equivalent statements for appearance level, action level and purposive task level imitation of human behavior, defined by Kuniyoshi et al. [Kuniyoshi 07], for being the sharing of skills between two robots comparable to the imitation between them.

3. Sharing Robotic Skills

3.1 Requirements on Skill Sharing

To share a skill between two robots means, in simple statements, that both of these robots will be able to achieve a task that previously only one of them could accomplish. In further analysis, for being tasks characterized by its *meaningful outcome*, or, in other words, objective, we can understand skill sharing as both the sharing of objectives and the ability to achieve them.

Regarding the sharing of objectives, it is easy to conclude that it can be accomplished through the description of skills in objective level. The opposite is also valid, being possible to say that the generation of objective level statements is a

Contact: Guilherme C. Affonso, The University of Tokyo, 113-8656 Tokyo, Bunkyo-ku, Hongo, 7-3-1, tel. 03-5841-7416, affonso@jsk.imi.i.u-tokyo.ac.jp

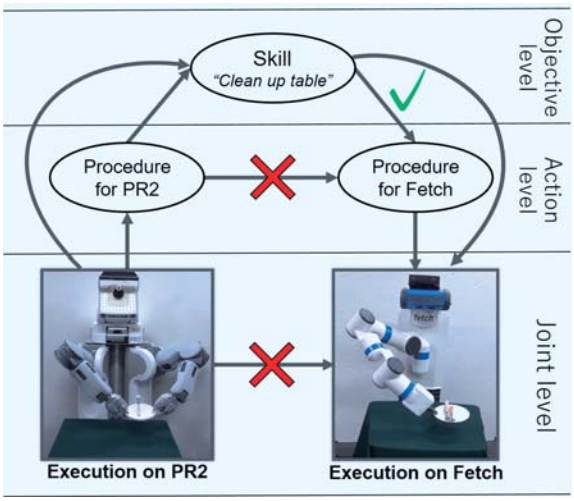


Figure 1: Sharing of robotic skills, as the transition between objective level and task level descriptions.

necessary step for the sharing of objectives and, therefore, skills.

Regarding the ability to achieve a certain objective *i.e.* final state, it is vital to observe that, as any machine, robots are only capable of executing sufficiently concrete and small orders. This means that all commands send to the real robot must be ultimately translated into joint level orders before execution. Therefore, the ability to achieve a certain objective is held as being equivalent to the potential to generate joint level orders based on a given final state.

Above reasoning leads to the conclusion that in order to attain general and certain sharing of robotic skills, it is necessary to (i) share objective level descriptions, and (ii) generate joint level commands accordingly.

An interesting point to notice is that, although being impossible to share skills between different robots directly on joint level, for those being extremely hardware dependent, it is possible to obtain functional results when sharing directly on action point level. This happens in cases where both robots have sufficiently similar hardware properties, such as number of limbs and overall reachability, enough to grant that the original procedure remains valid on the new robot. However, these are limited cases, having general and certain sharing of skills relying on, as previously stated, the combination of objective and joint level descriptions.

3.2 Difficulties on Skill Sharing

The main difficulty imposed by the sharing of robotic skills is the necessity for the machine to deal with objective level descriptions, either in its extraction or in its conversion into joint level commands. Differently from humans, who act consciously of the cause and effect of each motion, knowing what they should and should not do in order to achieve certain objectives; robots – and machines, in general – are only able to process concrete and simple orders, which are executed without any concern on its original purposes or potential side effects. This is due to the incapability for machines to comprehend the cause-consequence nexus, widely known as the *Frame Problem*. The *Frame Problem* can also be understood as the difficulty for artificial intelligence to classify phenomena between related and unrelated [Matsuo 15], in more basic levels. Because it is impossible to know the relations of a certain event with other ones, it is impossible to know which phenomena is directly influenced by which event, being therefore impossible to understand the consequences of actions taken by others or themselves.

4. Past Work

In the past years great effort have been made to build up objective level interfaces, in which programming would be resumed to the definition of the desired final state, using syntax resembling natural language or logical programming like statements. Some examples of such task level programming languages can be verified on [Lozano-Perez 77] [Lieberman 77] [Okano 88], holding the merit of (i) intrinsically attaining the sharing of objectives, and (ii) easing the act of programming itself, for providing methods closer to the objective-oriented human behavior. However, even making use of such interfaces, the necessity of assigning appropriate joint level commands still prevails, making the sharing of skills between different hardware unable to be achieved.

When attempting to deal with the Frame Problem, KnowRob [Tenorth 09] can be pointed out as being of notable interest. Knowrob is a knowledge database implemented on Prolog and the Web Ontology Language OWL, in which the analysis of its enormous database allows robots to learn from experience and reason about the environment and effects of its actions. However, although it is possible to correctly assign subprocedures to higher level commands using this method, it is still limited to specific cases.

Extraction of joint level commands from higher descriptions also finds precedents on the inverse kinematics field [Buss 04] [Nakamura 86], which enables conversion of coordinate based action point level commands into joint level orders. Even though inverse kinematics calculation relies on the number of links and its length, being highly hardware dependent, common interfaces capable of building appropriate solvers based on each robot's hardware descriptions are observed [Matsui 90]. Use of such interfaces allows writing programs fully in action point level, being able to share overall procedures between robots. Although not able to attain complete sharing of skills, sharing of procedures can also be effective on platforms with similar hardware. However, since inverse kinematics result depends on initial position, such codes tend to rely on environment conditions, generating unstable outcomes.

5. Joint - Action level Transition

In this work the extraction of action point level procedures from joint level commands is tested. When combined with common interfaces capable of translating coordinate based commands back into joint level orders, as the ones introduced above, this method makes possible to share procedures of any robotic skill. This is done through source code

and run-time data analysis, by (i) determining and translating motion patterns, and (ii) identifying each action and the relations between them. Details of such method are given on [Affonso 18b], which also proposes the use of a visual and natural language-like programming based interface for facilitating the manipulation of extracted procedures, making therefore possible to share skills in a semi-automatic way.

At the first step, motions patterns are identified by (i) segmenting and labeling original code into minimal, unconditional divisions, and (ii) searching for common sets of labels between executions. Each motion is then translated into action point level descriptions by comparing end effector position relative to the robot base, target object center and previous position. Coordinate systems capable of describing the end effector position in unchanged statements are taken to be the application point of the motion, process illustrated on Fig. 2.

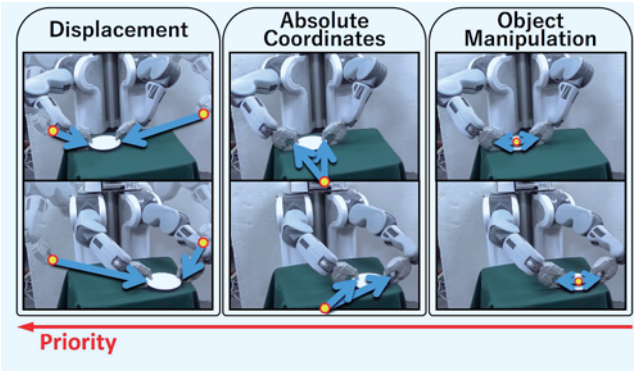


Figure 2: Example of coordinates analysis on motion translation. Here, object centered coordinate system allows unchangeable representation of end effector position, signalizing the application point.

At the second step, the heading label for each motion pattern is analyzed, identifying its trigger conditions and other related motion patterns included on its context. Nested structures containing several motion patterns related to the same conditional clause are interpreted as actions, and bound accordingly. Detailed procedure is given on [Affonso 18a].

6. Experimentation

Experimentation is conducted on the simple domestic task of cleaning up a table after a meal, removing dishes and cutlery left on it. This task is schematically shown at Fig. 3, and is executed a total of seven times for collecting run-time data. Conditions of each trial are given at Table 1.

Without counting the action describing initial pose, five motions patterns and three actions were extracted from given task. Overall procedure, including the relation between such actions and motion patterns, is shown at Fig. 4. Here, actions A, B and C are verified to correspond to original actions of piling-up dishes, collecting cutlery and picking-up (refer to Fig. 3).

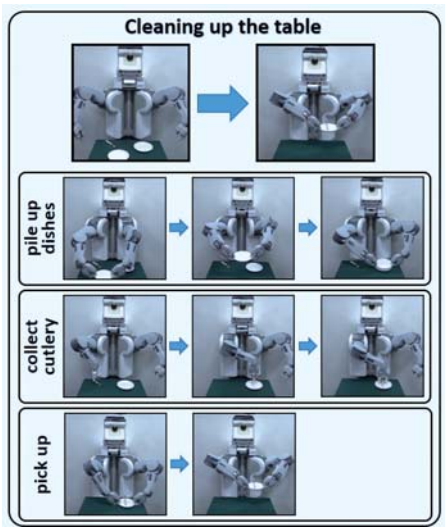


Figure 3: Task of cleaning up table, executed by piling up dishes, collecting cutlery and picking everything up.

Table 1: Conditions of conducted experiments.

trial number	1	2	3	4	5	6	7
number of plates	1	1	1	1	2	2	2
number of cutlery	0	1	1	2	0	0	1
pile plate executions	0	0	0	0	1	1	1
collect cutlery exec.	0	1	1	2	0	0	1
pick up executions	1	1	1	1	1	1	1

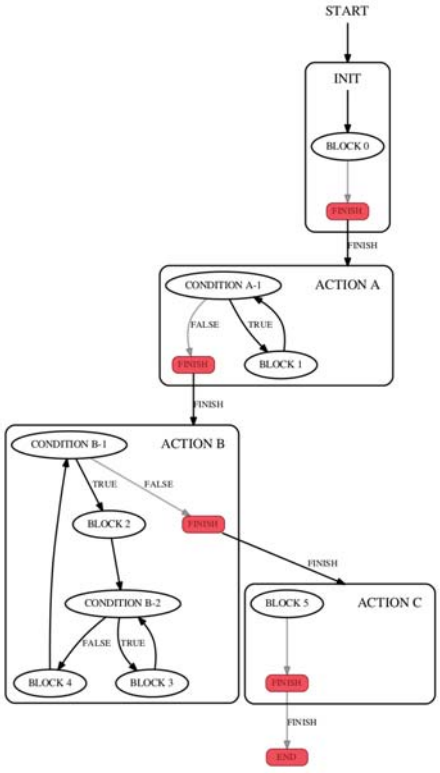


Figure 4: Flow diagram describing task's overall procedure, showing relations between extracted motion patterns (*blocks*) and actions. Conditions are abbreviated.

7. Conclusion

In this work the sharing of robotic skills was dealt with, analyzing its current situation and problems that must be dealt with.

From past work, we can conclude that now it is possible to:

1. Share objectives between robots, by *e.g.* using task level programming languages.
2. Translate coordinate based action point level descriptions into joint level orders, by *e.g.* using inverse kinematics solvers.

In order to attain the complete sharing of skills among different robots, however, it is also necessary to be capable of executing shared objectives, by assigning joint level orders appropriately. This involves dealing with reasoning on higher level objectives, being required to overcome the Frame Problem – difficulty for machines to understand the cause-consequence nexus – at some extent.

We also note that, although not being able to accomplish sharing in general and certain ways, the extraction of action point level procedures can be helpful, for being able to both give functional results on similar hardware and attain certain degree of hardware abstraction. When willing to share a certain skill between robots, even if incomplete this methods can save a lot of time and human work.

References

[Affonso 18a] Affonso, G. C., Okada, K., and Inaba, M.: Detection of Motion Patterns and Transition Conditions for Automatic Flow Diagram Generation of Robotic Tasks, in *International Conference on Intelligent Autonomous Systems (IAS)* (submitted on 2018)

[Affonso 18b] Affonso, G. C., Okada, K., and Inaba, M.: Extraction and Modularization of Procedures Towards Sharing of Robotic Skills, in *International Conference on Intelligent Robots and Systems (IROS)* (submitted on 2018)

[Buss 04] Buss, S. R.: Introduction to inverse kinematics with jacobian transpose, pseudoinverse and damped least squares methods, *IEEE Journal of Robotics and Automation*, Vol. 17, No. 1-19, p. 16 (2004)

[Ferland 15] Ferland, F., Cruz-Maya, A., and Tapus, A.: Adapting an hybrid behavior-based architecture with episodic memory to different humanoid robots, in *24th IEEE International Symposium on Robot and Human Interactive Communication (RO-MAN)*, pp. 797–802 (2015)

[Grace Market Data 15] Grace Market Data, : Global Domestic Service Robots Market Size And Trends To 2020 (August 2015)

[Jacobsson 16] Jacobsson, L., Malec, J., and Nilsson, K.: Modularization of skill ontologies for industrial robots, in *Proceedings of 47st International Symposium on Robotics(ISR)*, pp. 1–6 (2016)

[Kuniyoshi 07] Kuniyoshi, Y.: Adaptive and emergent imitation as the fundamental of humanoid intelligence, *Journal of the Robotics Society of Japan*, Vol. 25, No. 5, pp. 671–677 (2007)

[Lieberman 77] Lieberman, L. I. and Wesley, M. A.: AUTOPASS: an automatic programming system for computer controlled mechanical assembly, *IBM Journal of Research and Development*, Vol. 21, No. 4, pp. 321–333 (1977)

[Lozano-Perez 77] Lozano-Perez, T. and Winston, P. H.: LAMA: A Language for Automatic Mechanical Assembly., in *IJCAI*, pp. 710–716 (1977)

[Matsui 90] Matsui, T. and Inaba, M.: Euslisp: An object-based implementation of lisp, *Journal of Information Processing*, Vol. 13, No. 3, pp. 327–338 (1990)

[Matsuo 15] Matsuo, Y.: 人工知能は人間を超えるか ディープラーニングの先にあるもの [Will Artificial Intelligence overcome humans? What lies beyond Deep Learning., KADOKAWA (2015)

[Nakamura 86] Nakamura, Y. and Hanafusa, H.: Inverse kinematic solutions with singularity robustness for robot manipulator control, *Journal of dynamic systems, measurement, and control*, Vol. 108, No. 3, pp. 163–171 (1986)

[Okano 88] Okano, A., Matsubara, H., and Inoue, H.: Design and implementation of a task-oriented robot language, *Advanced Robotics*, Vol. 3, pp. 177–191 (1988)

[Tenorth 09] Tenorth, M. and Beetz, M.: KnowRob – knowledge processing for autonomous personal robots, in *International Conference on Intelligent Robots and Systems (IROS)*, pp. 4261–4266 (2009)

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

Hybrid Policy Gradient for Deep Reinforcement Learning

Thakur Praveen Singh[*1], Masaru Sogabe[1], Katsuyoshi Sakamoto[2], Koichi Yamaguchi[2], Dinesh Bahadur Malla[2], Shinji Yokogawa[2], Tomah Sogabe[*1,2]

[1] GRID Inc. [2] i-PERC, The University of Electro-communications

In Reinforcement Learning, to solve complex continuous action tasks, it requires a policy with stable learning and faster convergence, since policy may converge to sub-optimal solutions at the early stage of policy learning. Deterministic Policy Gradient(DDPG) algorithm which is a limiting case of stochastic policy gradient in actor-critic approach used for solving continuous tasks. In this paper, we propose an alternative way of updating the actor (policy) in DDPG algorithm to increase convergence and stable learning process. In the basic actor-critic architecture with TD (temporal difference) learning of critic, the actor parameters are updated in the gradient ascent direction of TD-error of critic. Similar to basic actor-critic approach, in our proposed hybrid method, Hybrid-DDPG (shortly H-DDPG), at one time step actor is updated similar to DDPG (gradient of critic output with respect to policy parameters) and another time step, policy parameters are moved in the direction of TD-error of critic. The algorithm is tested on OpenAI gym's RoboschoolInvertedPendulumSwingup-v1 environment. Once among 5 trial runs, reward obtained at the early stage of training in H-DDPG is higher than DDPG. In Hybrid update, the policy gradients are weighted by TD-error. This results in 1) higher reward than DDPG 2) pushes the policy parameters to move in a direction such that the actions with higher reward likely to occur more than the other. This implies if the policy explores at early stages good rewards, the policy may converge quickly otherwise vice versa. However, among the remaining trial runs, H-DDPG performed same as DDPG.

1. Introduction

Reinforcement Learning (RL) has shown successful result in the past few years in the discrete action space such as Atari games using DQN (Mnih et al. 2015), Go game using actor critic with Monte Carlo Tree search (Silver et al. 2017). For continuous control problems, there are mainly two types of algorithms: vanilla policy gradient and actor-critic architecture. Deep Deterministic Policy Gradient (DDPG) (Lillicrap et al. 2016), Asynchronous Advantage Actor Critic (A3C) (Mnih et al. 2016) has actor-critic architectures, Trust Region Policy Optimization (TRPO) (Schluman et al. 2015), Proximal Policy Optimization (PPO) (Shluman et al. 2017) can use vanilla policy gradient and actor-critic architecture. Except DDPG, the above mentioned RL algorithms use stochastic policy gradients and policy is parameterized as Gaussian distribution, from which action is sampled. Whereas in DDPG, policy maps state space to action value. In the policy evaluation, for exploration, policy output is summed with Ornstein-Uhlenbeck noise. DPG is a limiting case of stochastic policy gradient in the limit of variance approaches to zero (Silver et al. 2014). Due to the deterministic behavior in DDPG, in the early stages of policy iteration, if the policy has seen good immediate reward, the policy converges to sub-optimal region and policy has hard time to reach global optimum. Here, we propose a method to find the global optimal policy and faster convergence by using actor update similar to stochastic policy gradient. In this Hybrid-DDPG at one time step of policy update, same as DDPG, the policy parameters are moved in the direction of action-value gradient at another time step, instead of calculating the action-value gradient, TD error calculated for critic is applied at the action gradient of the actor network. It is believed that since the critic network does not reach optimum solution at the early stages of learning, the policy parameters may not converge to sub-optimal solution.

Contact: Tomah Sogabe, i-PERC, The University of Electro-communications, sogabe@uec.ac.jp

2. Background

2.1 Preliminaries:

In the Reinforcement Learning, the control problem is formulated as Markov Decision Process (MDP). A MDP consists of state space (s), an agent to take an action from action space (a), transition dynamics $p(s_{t+1}|s_t, a_t)$, Reward process ($r(s,a)$) and initial state distribution $p(s_1)$ (Sutton et al. 1998). The goal of an agent is to find an optimum policy (π^*) such that it maximizes the total expected cumulative discounted reward.

Total discounted reward $R_t = \sum_{i=t}^{T} \gamma^{(i-T)} r(s_i, a_i)$.
Here, γ is the discount factor $\in$ [0~1].

2.2 Actor-critic method:

In RL, actor-critic architecture is one of the policy gradient algorithm, used to tackle continuous action problems. The actor is the agent (policy) which takes the action, and the critic criticizes the action how good or bad the sampled action from actor. The policy is parameterized with neural network and critic is the value-function. There are two types of actor-critic methods: stochastic and deterministic.

In the stochastic actor-critic off-policy setting, the performance objective is typically modified to be the value function of target policy, averaged over the state distribution of the behavior policy (Degris et al. 2012)

$$\nabla_\theta J_\beta(\pi_\theta) = \mathbb{E}_{s\sim\rho^\beta, a\sim\beta}\left[\frac{\pi_\theta(a|s)}{\beta_\theta(a|s)}(\nabla_\theta \log \pi_\theta(a|s))Q^\pi(s,a)\right] \quad \text{--- (1)}$$

Instead of the $Q^\pi(s,a)$ in Equ. (1), the temporal difference (TD) error, $\delta = r_{t+1} + \gamma V(s_{t+1}) - V(s_t)$ is used for actor update.

In off-policy deterministic policy gradient, the actor update becomes

$$\theta^{k+1} = \theta^k + \alpha \mathbb{E}_{s\sim\rho^{\mu^k}}\left[\nabla_\theta Q^{\mu^k}(s, \mu_\theta(s))\right] \quad \text{--- (2)}$$

By applying the chain rule, the policy improvement is decomposed into the gradient of action-value with respect to actions, and the gradient of policy with respect to policy parameters.

$$\theta^{k+1} = \theta^k + \alpha \mathbb{E}_{s\sim\rho^{\mu^k}}\left[\nabla_a Q^{\mu^k}(s,a)|_{a=\mu_\theta(s)} * \nabla_\theta \mu_\theta(S)\right] \quad \text{--- (3)}$$

In the calculation of gradient of Q with respect to actions in Eq. (3), the error is considered as 1.0 at the output neuron which is propagated until the action gradient. Here, in this paper, we propose, similar to stochastic actor-critic, the TD-error (δ) is applied at the Eq. (3) instead of the action-value Q gradient. The TD-error is

$$\delta = r_t + \gamma Q'(s_{t+1}, \mu'(s_{t+1})) - Q(s_t). \quad \text{--- (4)}$$

For critic update, this TD-error (TD(0) error) is used for backpropagation. We call this method as Hybrid Deep Deterministic Policy Gradient (H-DDPG) method. At one time step, use the Eq. (3) and the next time step use the Eq. (5).

$$\theta^{k+1} = \theta^k + \alpha \mathbb{E}_{s\sim\rho^{\mu^k}}\left[\delta * \nabla_a Q^{\mu^k}(s,a)|_{a=\mu_\theta(s)}\right] \quad \text{--- (5)}$$

3. Propose method

3.1 Hybrid-DDPG Algorithm:

Randomly initialize actor $\mu(s|\theta^\mu)$ and critic $Q(s,a|\theta^Q)$ neural networks with weights θ^μ and θ^Q.
Initialize target network μ' and Q' with weights $\theta^{\mu'} \leftarrow \theta^\mu$ and $\theta^{Q'} \leftarrow \theta^Q$. (Initially copy the same weights)
Initialize Replay Buffer R.
For episode 1 to m do:
  Initialize Ornstein-Uhelnbeck(OU) noise for $\mathcal{N}$ for exploration
  Environment reset to get initial observation s_0
  For t = 1 to Terminal state do
    Select action $a_t = \mu(s_t|\theta^\mu) + \mathcal{N}_t$ by adding noise
    Apply action a_t to environment and observe next state s_{t+1} and reward r_t and terminal situation
    Store following tuple in (s_t, a_t, r_t, s_{t+1}, terminal) in R
    If Replay Buffer size > mini batch size
      Sample K (mini batch) from R
      Calculate $TD(0)_{target} = r_t + \gamma Q'(s_{t+1}, \mu'(s_{t+1}|\theta^{\mu'}))$
      Update critic with mean squared loss:

$$L = \frac{1}{K}\sum(TD(0)_{target} - Q(s_t, a_t))^2$$

      Update Actor (Hybrid):
        At time step: t

$$\nabla_{\theta^\mu} J \approx \frac{1}{K}\sum_i \nabla_a Q(s,a|\theta^Q)|_{s=s_i, a=\mu(s_i)} * \nabla_{\theta^\mu}\mu(s|\theta^\mu)|_{s_i}$$

        At time step: $t+1$

$$\nabla_{\theta^\mu} J \approx \frac{1}{K}\sum_i TD(0)_{target} * \nabla_{\theta^\mu}\mu(s|\theta^\mu)|_{s_i}$$

      Update target networks:

$$\theta^{Q'} \leftarrow \tau\theta^Q + (1-\tau)\theta^{Q'}$$
$$\theta^{\mu'} \leftarrow \tau\theta^\mu + (1-\tau)\theta^{\mu'}$$

  end for
end for

4. Results and Discussion:

4.1 Simulation settings and results:

For fair comparison of the DDPG and H-DDPG, the neural network architectures and hyper parameters are kept same as (Lillicrap et al. 2016). In the OU-noise the parameters are $\sigma = 0.3$, and $\theta = 0.15$. The replay buffer size is 200000. The discount factor gamma (γ), Actor learning rate, critic learning rate are 0.999, 0.0001 and 0.001 respectively. The τ is set as 0.001.

RoboschoolInvertedPendulumSwingup-v1 (OpenAI Gym environments) is tested using both algorithms. Each run is continued for 500 episodes. The reward threshold is 800. For brevity, the Figure 1 is plotted for 300 episodes. The total reward achieved in each episode is plotted. The game is run for 5 times. To test the learned policy without noise for stability, we tested the learned policy every after 10 episodes (after 0,10,20,…,500th episode) The average reward of 10 test episodes is plotted in Figure 2.

4.2 Discussion:

Once among 5 trial runs, In H-DDPG4 curve in Figure 1, reward obtained at the early stage of training is higher than DDPG2 trial run. In Hybrid update, the policy gradients are weighted by TD-error. This results in 1) higher reward than DDPG 2) pushes the policy parameters to move in a direction such that the actions with higher reward likely to occur more than the other. This implies if the policy explores at early stages good rewards,

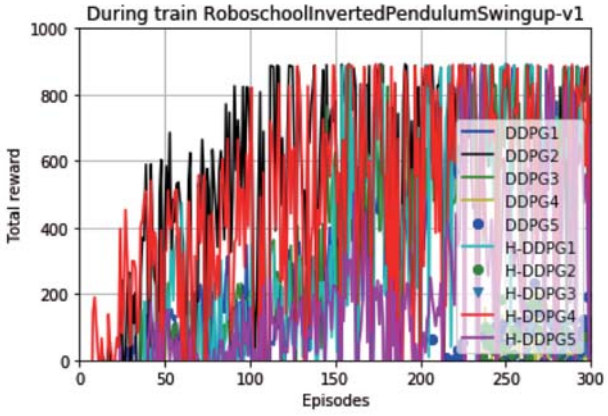


Figure 1. During training rewards obtained in both algorithms

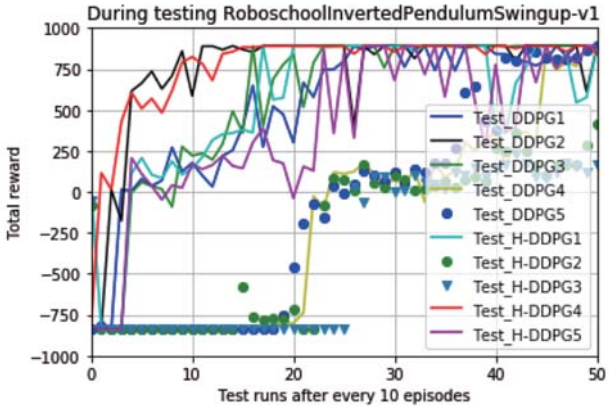


Figure 2. During testing after every 10 episodes of training

the policy may converge quickly otherwise vice versa. However, among the remaining trial runs, there is no much difference between both of the algorithms. In the Figure 2, for the case H-DDPG4 and DDPG2 curves have the same stability of test runs. Briefly, at least the Hybrid performance same as DDPG.

Although it is promising in one trail run of H-DDPG over DDPG, there is a lot rooms to improve the HDDPG for more complex continuous tasks including the introduction of the experienced replay and reward clipping, which are undergoing and the results will be presented at the conference.

References

[Minh] Human-level control through deep reinforcement learning, Nature, 2015.

[Silver] Deterministic policy gradient algorithms, In Proceeding of the 31st International Conference on Machine learning(ICML-14), 2014.

[Silver] Mastering the Game of Go without Human Knowledge, Nature, 2017.

[Sutton] Reinforcement learning: An Introduction, MIT press Cambridge,1998.

[Lillicrap] Continuous control with deep reinforcement learning. In Proc. International Conference on Learning Representations (ICLR),2016.

[Schulman] Trust Region Policy Optimization, In proceedings of the 32nd International Conference on International Conference on Machine Learning (ICML'15), JMLR.org, 2015.

[Schulman] Proximal policy optimization algorithms, Arxiv, abs/1707.06347, 2017.

[Degris] Linear off-policy actor-critic, In 29th International Conference on Machine Learning, 2012.

[Mnih] Asynchronous methods for deep reinforcement learning, Proceedings of the 33rd International Conference on Machine Learning, Vol 48 of Machine Learning Research, 2016.

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

人から評価を得てリアルタイムに強化学習する移動ロボット

A mobile robot based on real-time reinforcement learning using human evaluation

山根 健 *1　植月 宏昌　横松 秀康 *2
Ken Yamane　Hiromasa Uetsuki　Hideyasu Yokomatsu

*1帝京大学　*2株式会社タイトー
Teikyo University　Taito Corporation

In develping intelligent robot systems, it is necessary for designers to make robots by fine-tuning parameters and modifying programs in detail. However, this conventional method is a big burden not only for designers but also general users. In this paper, we present a new design method based on reinforcement learning in real time through human-robot interaction. We also develop an autonomous mobile robot system and show its possibilities.

1. はじめに

知能ロボット開発において，一般的には，ロボットのために環境を整えて，パラメータやプログラムを細かく調整するなど設計者がシステムを作り込む．しかし，作り込みには大きな労力が必要であるし，実環境では想定外のことが頻繁に起こる．また，非技術者である一般ユーザがロボットの行動を望む方向へ変更したい場合，いわゆるプログラミングによって機能を修正したり追加したりすることはできない．

これらに対して，我々は人との相互作用を通じてロボット自らが行動を学習する方法を検討している．例えば，ユーザがロボットへ行動を教示したり，ロボットの行動に対してその良し悪しを評価したりする中で，ロボットがリアルタイムに学習して必要な機能を獲得する方法である．これは設計者やユーザにとっても負担の少ない設計方法として期待される．

その実現のために，強化学習 [Sutton 98] の枠組みを利用できると考えている．しかし，実環境において強化学習を行う場合，膨大な学習時間が必要であるなど幾つかの大きな問題がある．これに関して，強化学習の価値関数近似器として選択的不感化ニューラルネット（SDNN）を用いる方法が提案され，単純なアルゴリズムである Q 学習でも従来手法に比べて効率よく学習できることが示された [新保 10]．しかし，実環境で強化学習するための具体的な方法や人という不確定な要素を系に含んでも安定して学習できるかについては明らかではない．

そこで本研究では，SDNN を価値関数近似器として用いて強化学習するロボットを実際に構築し，人との相互作用の中で学習可能か検証する．具体的には，事前知識をほとんど与えずに，ロボットの行動に対する良し悪しの評価を人から得て，ロボットが適切な行動をリアルタイムに学習可能か，ウェイポイント経路を追従させる課題において調べる．

2. 方法

2.1 ハードウェアとセンサ情報の前処理

使用するロボット，測域センサおよび評価用ボタンを図 1 に示す．ロボットは独立 2 輪駆動方式であり，市販のノートパソコンにより走行制御される．なお，安全のために，緊急停止スイッチを取り付け，最大速度を 0.15m/s に制限する．

連絡先: 山根健，帝京大学理工学部情報電子工学科，〒 320-8551 栃木県宇都宮市豊郷台 1-1，028-627-7224，yamane@ics.teikyo-u.ac.jp

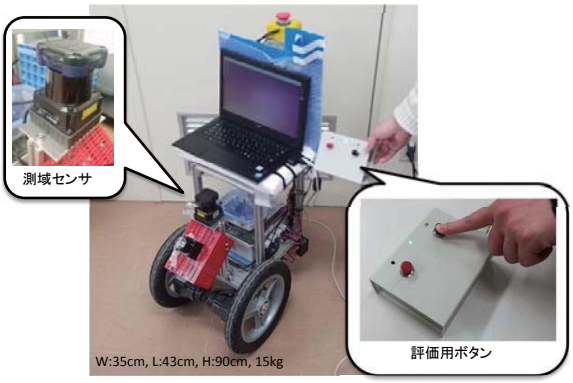


図 1: ハードウェアの構成

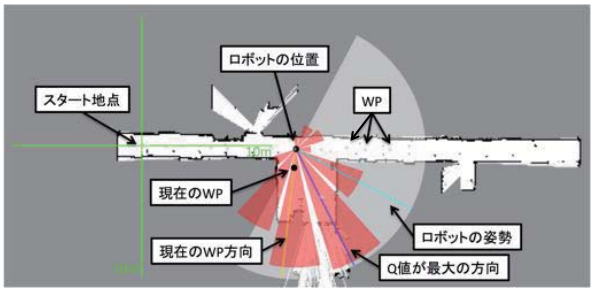


図 2: 実験コースと可視化したロボットの状態

環境情報を取得するため，測域センサ（UTM-30LX-EW，北陽電機）を用いて床面から 0.49m の高さにおける周囲 ±135° の範囲で 1080 点の距離情報を取得し，前処理して状態変数とする．具体的には，5m を超えるものに関して 5m とし，30° ずつの範囲でグループに分け（120 点ずつ 9 つに分け），それぞれの範囲における平均値を求める．次に，最大値 5m で割ることで 0〜1 の値に正規化し，これらを x_1〜x_9 と表す．また，推定したウェイポイント方向とロボットの姿勢の差（±90°）を 0〜1 の範囲で正規化したものを x_{10} として状態変数に含める．これら状態変数の構成イメージを図 2 に示す．

2.2 学習方法

ロボットの学習方法を図 3 に示す．ここでは強化学習アルゴリズムとして Q 学習を，価値関数近似器として SDNN[新保 10, 小林 15] を用いる．SDNN は前述した入力変数 x_1〜x_{10} を受

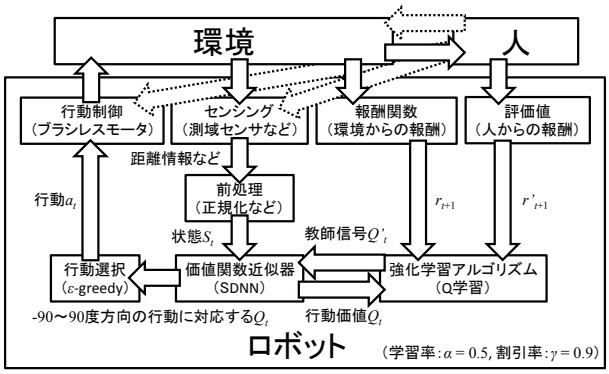


図 3: 学習方法

けて，ロボットの現在の姿勢から $-90°$〜$90°$ 方向へ直進または旋回する行動の価値（Q 値）を計算する．この連続的な Q 値を表現するため，小林らが提案する連続状態行動空間における学習に対応した SDNN[小林 15] を用いて，181 個の行動（1° 刻みの行動）に対する Q 値を出力する．

行動選択では，最大の Q 値に対応する行動を選択する．なお，学習初期のみある一定の確率でランダムに行動を選択すると，連続状態行動空間を効率よく探索できる．

行動実行後，予め設計した報酬関数に基づいて環境から報酬が与えられる．加えて，図 1 に示す評価用ボタンを用いて，人から行動の良し悪しの評価を受ける．2 つのボタンはそれぞれ正の評価（良い）と負の評価（悪い）に対応し，ロボットの行動に対して人が自由なタイミングでボタンを押すことができる（押さなくてもよい）．このボタン押しの頻度から一次元的な値である評価値が計算されて報酬として与えられる．

最終的に，Q 学習の更新式で得られた新しい Q 値（図 3 の Q'_t）を教師信号として SDNN を 1 回だけ学習する．なお，学習には誤り訂正学習を用いる．以上の処理を行動毎に繰り返す．

3. 実験

実際にロボットシステムを構築して，複数のウェイポイント（WP）を順番に繰り返し通過させる課題を行った．具体的には，図 2 に示す 1 周およそ 46.5m の屋内コースにおいて，事前知識なしの状態でスタート地点にロボットを置き，人の評価がある条件とない条件でそれぞれ 4000 step まで行動させた．

このとき，Q 学習のパラメータについて，学習率 $\alpha = 0.5$，割引率 $\gamma = 0.9$ とし，ランダム行動の確率については 1000 step まで 20%，さらに 1000 step まで 10%，その後は 0%とした．報酬関数について，障害物との距離が 0.55m 未満になった場合に-7，WP から離れる場合に-3，ロボットの姿勢と WP 方向の差が 5.6° 未満の場合に 2 を与える．さらに，SDNN を構成する素子数について，入力層 1,000 個，中間層 9,000 個，出力層 3,000 個とし，出力層において -30〜30 までの Q 値を表現した．また，学習係数 $c = 0.01$ とした．

それぞれの条件で 3 回ずつ実験を行った，コース 1 周にかかるステップ数の変化を図 4 に示す．評価の有無に関係なく学習が進むとステップ数が減少した．また，2 周目以降は「評価あり」の方が「評価なし」よりも少ない結果が得られた．

「評価あり」における報酬について見ると，環境から得られた報酬（予め設計した報酬関数から得られた報酬）については，スタート地点，道幅が狭いところや障害物付近などで負の報酬が多かった．一方，人の評価から得られた報酬については，それらの付近でも正の報酬が与えられており，全体として

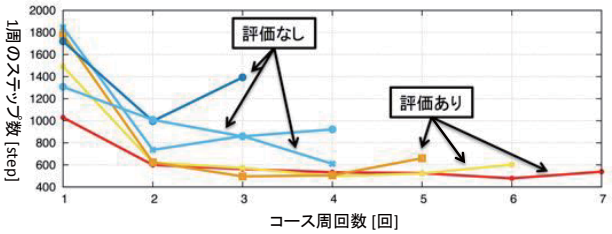


図 4: 1 周にかかるステップ数（4000 step まで）

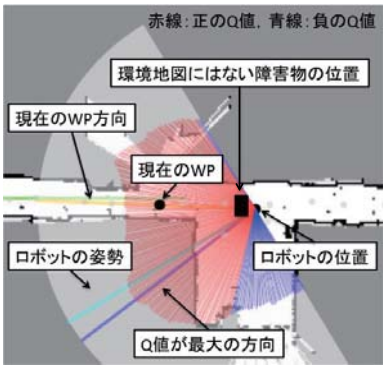


図 5: 障害物を回避しているときの Q 値の構成

も正の報酬が多かった．そこで両者を比較したところ，報酬の正負について 79%が一致していなかった．また，壁に向かう行動に対して人が良い評価をするなど，人が非協力的な条件ではまったく課題を遂行できなかった．これらから報酬関数では対応できない部分を人がカバーしていたと考えられる．

詳しく見るために，障害物付近での Q 値を図 5 に示す．WP 経路追従が本来の目的であるから，現在の WP 方向へ向かう Q 値が学習により高くなると予想される．しかし，実際には WP 方向の Q 値は抑えられており，障害物を回避する方向の Q 値が最も高くなっている．このような Q 値の構成は曲がり角や道幅が狭いところでも見られ，人の評価に基づいて学習する中で簡単な障害物回避機能が獲得できた．

4. おわりに

本研究では，人の評価を利用して強化学習するロボットを示した．詳しい分析は課題として残されているが，人を含む系でもリアルタイムに学習でき，人が協力的な条件では学習効率が高いことや簡単な障害物回避も可能であることがわかった．

今後の課題として，人の評価の効果について調べることや複数の行動次元（例えば，進む方向と速度の組み合わせなど）を扱えるようにシステムを拡張することなどが挙げられる．

参考文献

[小林 15] 小林高彰, 渋谷長史, 森田昌彦:選択的不感化ニューラルネットを用いた連続状態行動空間における Q 学習, 信学論 D, Vol.J98-D, No.2, pp.287-299 (2015).

[新保 10] 新保智之, 山根健, 田中文英, 森田昌彦:選択的不感化ニューラルネットを用いた強化学習の価値関数近似, 信学論 D, Vo.J93-D, No.6, pp.837-847 (2010).

[Sutton 98] Sutton, R. S. and Barto, A. G.:Reinforcement Learning, MIT Press (1998), (邦訳：強化学習, 三上貞芳, 皆川雅章 訳, 森北出版 (2000)).

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

水中ロボットの形状決定を例とした 物理実験からのフィードバックによる進化的計算の研究

Study on evolutionary calculation by real world feedback from physical experiment determining the shape of an underwater robot.

中村 亮太[*1]
Ryota Nakamura

井上 聡[*1*2]
Satoru Inoue

[*1] 埼玉工業大学大学院 工学研究科
Graduate School of Engineering, Saitama Institute of Technology

[*2] 埼玉工業大学
Saitama Institute of Technology

Several kinds of model to solve the problem existing in the real world have been proposed. On the other hand, it is difficult to infer the elements and measure the physical quantities which are necessary for simulation. We propose a system that searches solutions for specific problem by the real world feedback. As an example, we attempted to improve the function of underwater robot by optimize its caudal fin shape based on genetic algorithm.

1. はじめに

実世界における実体の最適化は広く行われており、その解決手段としてコンピュータシミュレーションによる手法が多くみられる。コンピュータシミュレーションは、空間的、時間的な制約が少ないというメリットが存在する。たとえば、製品の性質をコンピュータ上で再現し、設計や製造過程の事前検討を行う CAE (Computer Aided Engineering)技術が広く浸透している。これを用いることで、実物を試作する前に構造を確認することや、実際に試験を行うことなく製品の性能が十分かどうかを検証することができる。一方で、コンピュータシミュレーションを行う際には、扱う対象に関する知識と実験での科学的データの収集が不可欠であるため、対象の性質が未知の場合や、物理量の計測が困難な場合には運用することが難しい。

そこで、対象に関する多くの事前知識を必要とせず、あるいは多くの物理量の計測を省いたとしても、ある程度複雑な目的を達成できる手段が必要だと考えた。動作環境が設計段階で再現でき、モデルの試作にかかるコストが低いという条件下ならば、実際のモデルを用いた開発手法が考えられるのではないだろうか。本研究ではその例として、水中で「尾びれ」を振りながら進むロボットについて、遊泳速度が向上するような形質を求めるというテーマを設定し、有用な設計手法を模索した。

2. 研究目的

物理的な実体が稼働するシステムをコンピュータ上に再現する場合、関係する物理法則を推定し、必要なデータを計測する必要がある。これには、対象に関する専門的な知識と、正確な測定データが必要となるため、人間の知識量によって結果が左右される。また、シミュレーションは実際の物理法則に従うように行わなければならないという制約が存在する。このように、実世界の実体に関するコンピュータシミュレーションには多くの難点が伴う。そこで、コンピュータシミュレーションを用いることなく最適化アルゴリズムを適用し、最適解を求める方法について考える(図 1)。

本研究では、そのような手法の具体的な例として、小型ロボットの遊泳速度を改善するシステムを構築した。コンピュータ上に仮想のモデルを構築することはせず、現実の機械を動作させた結果を探索アルゴリズムにフィードバックすることでのみ解を求め、目的を達成できることを示す。また、設定したテーマにおける提案手法のメリットとデメリットを考察する。

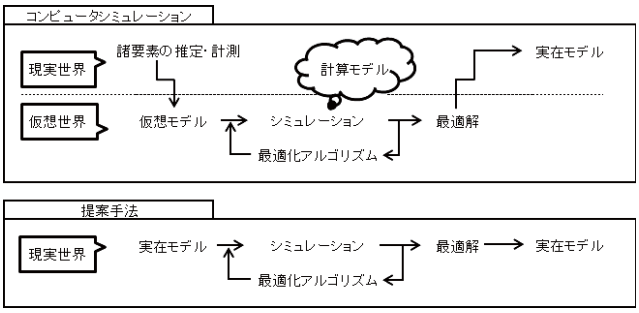


図 1: コンピュータシミュレーションによる方法と提案手法の比較

3. 実験内容

本実験では、「ある往復運動を与えたときに、効率の良い推進力を生み出す『尾びれ』の形質」を求めることにした。問題を単純化するために、外部からの刺激をセンサで感知したり、アクチュエータで運動を制御したりすることはせず、モーターから一定の力を加えて「尾びれ」を動かす。形質を変化させる方法は無数に考えうるが、ここでは「尾びれ」に使用するパーツの形状と剛性を変化させることで推進性能を改善する。

実世界で稼働する物体の中でも、流体を扱うものの最適化は複雑な問題である。まず、物体が受ける抗力、浮力、推力などといった要素は非線形な関数で表現される。また、そのことに起因して目的関数は局所的な最適解を多く持つため、大域解は確率的に求めることになる。水中ロボットおよび遊泳環境は複雑な様相を呈するため、本実験において解の探索には遺伝的アルゴリズム(GA)を用いることにした。GA は、生物が進化する過程を模倣して最適解を探索するアルゴリズムである。GA による解法は、まず解く対象を任意のコードで表現し(染色体とよぶ)、これを複数集めた集団に対して選択、淘汰、突然変異という操作を適用しながら集団を更新していき、終了条件に達するまで繰り返すというものである。他の探索アルゴリズムと比較すると、勾配法のように1点からの探索ではなく、多点からの同時探索を

行うことや、解の評価は評価関数(その染色体から作られる個体の優秀さを比較できるような関数)のみを用いることが特徴である。実験を行うにあたっては、関係する物理法則の推定と計測は行わず、遺伝的アルゴリズムを適用する際に必要な「コーディング」、「適応度の評価」、「遺伝的操作(選択、交叉、突然変異)」の各要素のみを決定する。

3.1 コーディング

本システムでは、遊泳模型の後部に装着する「尾びれ」の形質を変化さていく。「尾びれ」は樹脂で形成された板状のパーツを、1個体につき 1〜3 つを連結して駆動部に装着したものである(図 2)。それぞれのパーツは長さ、表面の加工、可動範囲、連結部分の剛性が違う複数のパーツから成り、その組み合わせによって複数の物理的な特性を表現する意図がある。「長さ」は 15mm から 25mm までの 5mm 刻みと 0mm(その節のパーツなし)の 4 水準、「表面の加工」はフラットなものと溝を付加したものがあり、溝の向きが縦か横かの 2 パターンに加え、溝の間隔が粗・密の 2 パターンを設定した。パーツの長さや表面の加工は水と作用した際の力のかかり方を変化させるほか、連結されているパーツどうしの運動にも影響がある可能性がある。また、ロボット本体と「尾びれ」どうしはジョイントでつながっており、可動範囲と曲がりやすさを変更できるようになっている。可動範囲は 0° ~180° まで 30° 刻みの 7 水準、「連結部分の剛性」はなし、弱、強の 3 水準とした。以上の要因が遊泳能力に影響する可能性を考慮する。このパーツどうしの最適な組み合わせを発見することが実験の目標となる。

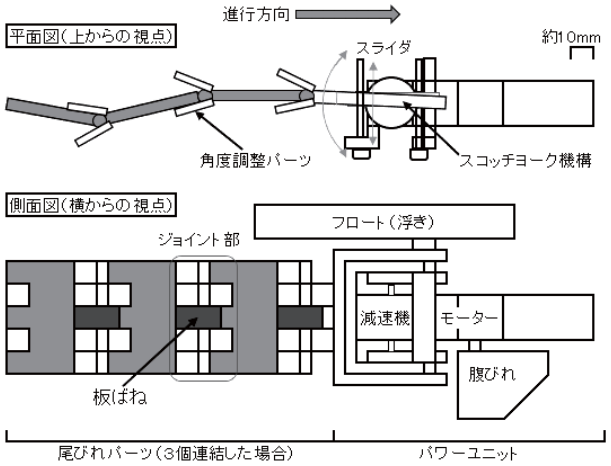


図 2: ロボット全体の模式図

本実験において遺伝的アルゴリズムに用いる染色体は長さ 12 の整数列とし、1〜6 までの整数 12 個が、1 つのパーツに 4 つずつ割り当てられる。この数字がそれぞれのパーツにおける長さ、表面の加工、可動範囲、剛性を決定する(表 1)。

表 1: 「尾びれ」の因子と対応するパーツ、水準の一覧

因子	対応するパーツ	水準(数字は遺伝子にコーディングする際に割り振られるもの)						
		0	1	2	3	4	5	6
長さ(mm)	板	※0	15	20	25			
表面の加工		フラット	横溝(粗)	横溝(密)	縦溝(粗)	縦溝(密)		
可動範囲(度)	角度調整パーツ	0	30	60	90	120	150	180
剛性	板ばね	なし	弱	強				

※「長さ0」は、その節のパーツが存在しないことを表現する。

これを 3D モデルに変換し、3D プリンタでプリントしたものを表現型とする。3D プリンタは、主に材料を薄い層に積み重ねて 3 次元形状を作成する工作機械であり、従来の切削加工等と比較すると、段取りや作業員の熟練度が必要なく、3D データさえ存在すれば人の解釈に依らず造形することができる。また、単品であれば安価かつ高速で試作品を製造できるため、本研究では実験機のパーツを作る目的で利用した。染色体データと、それを元に造形した「尾びれ」の例を図 3 に示す。

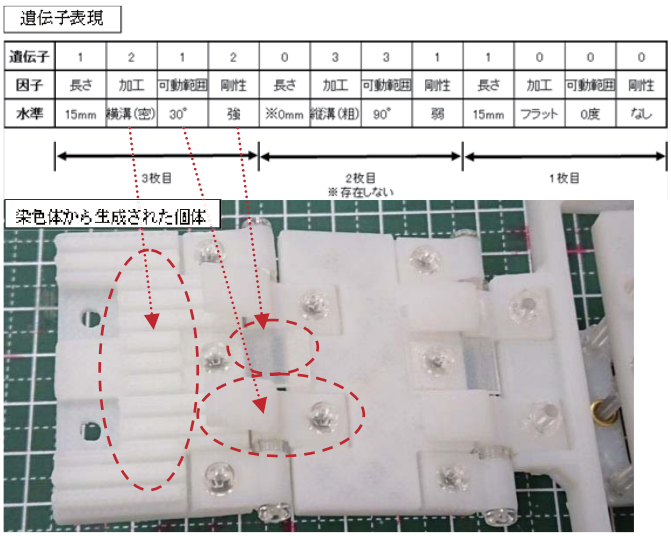


図 3: 遺伝子表現と表現型の対応例

3.2 評価

水中ロボットの動作には様々な評価方法が考えられるが、ここでは最も単純なものとして一定距離を泳ぎ切るまでのタイムを評価値として採用した。造形した「尾びれ」を水中ロボットに装着し、スタート地点を中心とする同心円状のラインで一定距離を泳ぎ終えるまでの時間が短いほど評価値を高く設定する(図 4)。



図 4: 遊泳タイム測定の模式図

3.3 遺伝的操作

選択方式はエリート保存ありのルーレット選択方式とし、交叉は1点交叉とする。また、子の個体の各遺伝子を 5%の確率で別のランダムな値に置き換えることで突然変異を発生させる。

4. まとめ

実世界でのシミュレーションは作業時間の大部分が評価に費やされるため、効率の良い評価方法が必要とされる。また、最適解へ早く収束するような遺伝的アルゴリズムのパラメータを定めることも重要である。

参考文献

[Long 2004] J.H. Long, A.C. Lammert, C.A. Pell, M. Kemp, J.A. Strother, H.C. Crenshaw, and M.J. McHenry: “A navigational primitive: biorobotic implementation of cycloptic helical klinotaxis in planar motion”, IEEE Journal of Oceanic Engineering 29, no.3, 2004

[樋口 1993] 樋口哲也, 北野宏明 : 遺伝的アルゴリズムとその応用, 情報処理 , 情報処理学会, 1993.

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

領域ベース CNN と Triplet Loss を用いた 移動ロボット向けオンライン転移学習型人物再同定

Person Re-identification by Online Transfer Learning for Mobile Robot using Region-based CNN and Triplet Loss

村田　祐樹[*1]
Yuki Murata

渥美　雅保[*1]
Masayasu Atsumi

[*1]創価大学大学院工学研究科情報システム工学専攻
Information Systems Science, Graduate School of Engineering, Soka University

We propose a person re-identification method for mobile robots that periodically provides services to specific groups. This method consists of a feature extractor that learns to extract person features based on the Triplet Loss from person regions detected by a region-based CNN and a person re-identifier that learns to identify persons through transfer learning of person features while moving around a room. The person re-identification incorporates adaptive transfer learning to periodically re-learn the same persons with different appearance, such as clothes etc. Performance of the proposed method is evaluated by an experiment using a public large-scale data set and an experiment using the self-made dataset periodically collected for the same group by the mobile robot.

1. はじめに

人物再同定とは一般に，視野を共有しない複数のカメラに映る人物から同一人物を識別する問題である[Zheng 16]．応用例としては屋外空間に設置された防犯カメラ映像を利用した警備システムや，商業施設におけるマーケティングなどが挙げられる．移動ロボットによる人物再同定は，移動ロボットが移動中に再会した同一人物を識別する問題となる．本研究では，特定の集団に定期的にサービスを提供する移動ロボットのための人物再同定手法を提案する．

本手法は，領域ベース CNN が検出する人物領域から Triplet Loss[Florian 15]に基づき人物特徴表現を学習する特徴抽出器と人物特徴の転移学習を行う人物再同定器とから構成される．人物再同定器には服装等部分的に外見が異なる人物を定期的に再学習するための転移学習が組み込まれる．公開されている大規模データセットを用いた実験，及び移動ロボットにより同一集団に対して定期的に収集した自作データセットを用いた実験により，提案手法の性能を評価する．

2. 人物再同定手法

2.1 概要

提案手法は，図 1 に示す 3 つの CNN-人物検出 CNN，人物特徴抽出 CNN，人物再同定 CNN-から構成される．人物検出 CNN は画像から人物領域を検出する．人物特徴抽出 CNN と人物再同定 CNN は検出された人物領域の座標とその中間層の特徴を受け取り，それぞれ Triplet Loss を用いた人物特徴表現学習と移動しながらのオンライン転移学習に基づき人物特徴抽出と再同定を行う．

連絡先：村田 祐樹，創価大学大学院工学研究科，
〒192-8577 東京都八王子市丹木町 1-236，Tel: 042-691-2211，
Email: y.murata0105@gmail.com

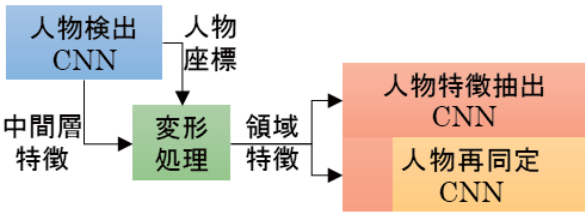


図 1　人物再同定手法

2.2 人物検出 CNN

人物検出 CNN は，画像から人物再同定のための人物領域を取り出す CNN である．高精度で実時間の人物再同定を実現するためには，まず，人物検出において人物の見落としや誤検出を極力減らし，リアルタイムに検出処理を行う必要がある．本研究では，検出器として YOLOv2[Redmon 16]を用いることで，これら課題を解決する．YOLOv2 の CNN は COCO データセットで事前に学習されたものを使用し，人物を含む 80 種類の物体を検出することができる．

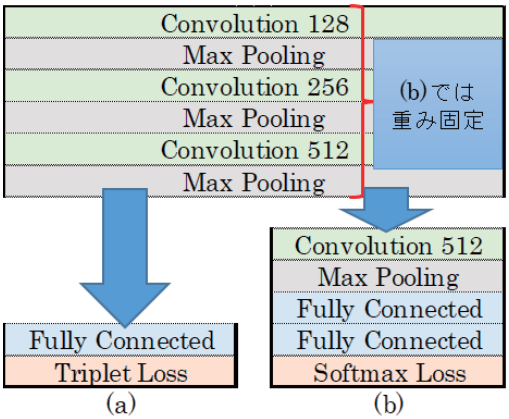


図 2　特徴抽出器(a)と再同定器(b)の CNN 構成

2.3 人物特徴抽出 CNN

人物特徴抽出 CNN(図 2(a))は複数の畳み込み層とプーリング層で構成され，最後の全結合層で 512 次元の人物特徴を出力するネットワークである．損失関数には Triplet Loss が用いられる． Triplet は基準となるサンプル(anchor)，それと同クラスのサンプル(positive)，別クラスのサンプル(negative)の 3 つの組で構成される．それぞれが重みを共有する同一の特徴抽出 CNN へ入力されて，出力される特徴量同士を比較したときに，同一クラス間では距離が小さく，別クラス間で距離が大きくなるように学習が行われる．

2.4 人物再同定 CNN

人物再同定 CNN(図 2(b))は，前半部分が特徴抽出 CNN と共通の層構成をとり，後半部分に再同定用の畳み込み層とプーリング層，及び全結合層を追加したネットワークで，出力層には人物クラスを分類するソフトマックス関数，損失関数には交差エントロピーを用いている．前半部分は人物特徴抽出 CNN 学習時の重みを利用し，後半で追加された層のみパラメータの更新を行う転移学習を取り入れることで，変化への適応と収束の促進を図っている．

3. 実験：人物特徴抽出と再同定の性能評価

3.1 実験概要

特徴抽出 CNN と再同定 CNN の性能評価実験を行う．特徴抽出 CNN の実験では，出力される特徴量間の類似度を利用して識別精度を評価する．再同定 CNN の実験では異なるデータセットで学習した特徴抽出 CNN の重みを利用して転移学習を実施した際の再同定精度を評価する．事前に行った複数の実験から，各 CNN に入力する領域特徴は検出 CNN の 2 番目の畳み込み層から取得し，サイズは 20×20×64 とした．

3.2 データセット

実験に使用する 2 種類のデータセット構成を表 1 に示す．

表 1 データセット構成（サンプル数 / クラス数）

	Train	Gallery	Query
PRW	17690 / 483	16343 / 450	2057 / 450

	Train	Test
SOTARO-1	12789 / 41	3193 / 41
SOTARO-2	12825 / 48	3194 / 48

(1) PRW データセット

公開されている人物再同定向けデータセットの多くは，人物領域が切り取られた画像で構成されている．一方，Person Re-identification in the Wild(PRW)[Zheng 16]では，画像全体と人物領域の座標情報が提供されている．提案手法では人物検出と同時に CNN の中間層から特徴を取り出すため，人物領域が切り取られる前の画像全体のデータが必要となる．そこで，今回はこのデータセットを，人物特徴表現の学習のために使用する．

(2) SOTARO データセット

SOTARO-1 および SOTARO-2 は，当研究室で開発を進めている授業支援ロボット SOTARO[渥美 17]で収集したデータを再構成して作成したデータセットである．2 種類のデータセットは別日に収集されており，服装等見え方の異なる同一人物のサンプルが含まれている．

3.3 人物特徴抽出器の評価

まず，訓練データ(表 1 の Train)からクラスラベルに基づいて Triplet を作成し，特徴抽出 CNN を学習する．次に，学習した CNN を使って全サンプルの人物特徴を抽出し，サンプル間のコサイン類似度を求めて分類を行う．PRW データセットではギャラリデータ(表 1 の Gallery)とクエリデータ(表 1 の Query)間，SOTARO データセットでは訓練データとテストデータ(表 1 の Test)間の類似度を算出する．結果を表 2 に示す．

表 2 類似度評価の結果

dataset	r1	r5	r10	r20	mAP
PRW	78.7	89.0	92.2	94.3	33.6
SOTARO-1	84.1	86.0	86.9	87.8	79.8
SOTARO-2	78.9	82.2	83.3	84.5	74.6

ここで r1, r5, r10, r20 は類似度の高い上位 1, 5, 10, 20 サンプル中に 1 つでも正解となるサンプルが含まれる場合に正しいと評価する指標である．また，mAP は mean Average Precision を表す．

3.4 人物再同定器の評価

3.3 で学習済みの特徴抽出 CNN と SOTARO データセットを用いて人物再同定 CNN の転移学習を実施し，分類性能を評価する．結果を表 3 に示す．

表 3 再同定評価の結果

feature	trans	r1	r5	r10	r20	mAP
PRW	SOTARO-1	79.9	92.7	96.3	98.4	85.3
PRW	SOTARO-2	71.4	85.3	90.7	95.4	77.9
SOTARO-2	SOTARO-1	81.3	93.6	97.2	98.4	86.8
SOTARO-1	SOTARO-2	78.3	91.9	95.0	98.2	84.5

ここで，1 列目の ‘feature`は特徴抽出 CNN の学習に使用したデータセットを，2 列目の‘trans`は再同定 CNN の転移学習に使用したデータセットを表す．

1･2 行目と 3･4 行目の比較から，特徴抽出 CNN の学習に PRW データセットを用いた場合より SOTARO データセットを用いた方が転移学習後の再同定性能が優れていることが分かる．この結果から，特徴表現の学習には，転移学習を行う環境と類似するデータセットを用いるべきであるといえる．

また，転移学習の収束に要した時間は GPU 環境下で 5 分ほどであり，短時間で異なるデータセットに適した再同定器の学習ができることが分かった．

4. オンライン転移学習型人物再同定システム

4.1 概要

人物検出から再同定までの各処理を同時並行的に行うシステムの構成を図 3 に示す．図 1 との違いは，データセット作成のための領域特徴･人物特徴の保存や人による GUI を用いた半自動的なラベル付け処理が追加されている点である．図中の Gallery には，人物が検出されるたびにその特徴が蓄積される．その時点で検出･取得した人物特徴と，Gallery 内に保存されている全サンプルの特徴のコサイン類似度を求め，ある条件に従って自動的にラベルを与えるか，GUI を利用したラベル付けを行うかを判断する．現在試作段階のシステム構成では，最も類似するサンプルの類似度が事前に設定した閾値以上なら自動

的にラベルを与え，そうでない場合は GUI による操作でラベルを付ける処理へ切り替えることとしている．

人物再同定 CNN の転移学習は，訓練データが集まり次第，任意のタイミングで実施する．再同定器生成後は，人物特徴の Gallery サンプルとのコサイン類似度の代わりに人物再同定結果の分類クラス確率を半教師付きラベル付けに利用する．この場合は，再同定 CNN が出力する分類クラス確率が閾値以上なら自動的にラベルを与え，そうでなければ GUI による操作へ切り替えることとしている．

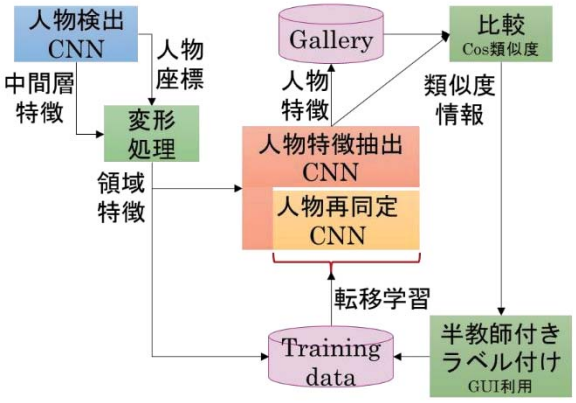


図 3 オンライン転移学習型人物再同定システム構成

4.2 実験：データセット分割による段階ごとの性能評価

本実験では，システムによる半自動ラベル付け処理が正確に行われたと仮定し，サンプル数の増加に対する再同定精度の推移を評価する．3.2 で紹介した SOTARO データセットを 6 分割し，図 4 で示すように 5 段階の再同定精度を比較した．

各段階におけるサンプル数とクラス数（人数），そして再同定精度をまとめた結果を表 4・表 5 に示す．表 4（分割実験 1）は特徴抽出 CNN の学習に SOTARO-2 を，再同定 CNN の転移学習に SOTARO-1 を使用した結果，表 5（分割実験 2）はその逆の条件で実験を行った結果を示している．分割実験 1 では学習に使用するサンプル数が増えるたびに再同定精度も向上する結果となった．一方，分割実験 2 では段階 3 において精度が若干低下した．これは段階を踏むごとにデータ量とともにクラス数も増加しており，分類問題としての難易度が上がっているためと考えられる．2 つの実験から，データ量を増やすことが精度向上に繋がり，早い段階から多くの人数のサンプルを集めることが重要であることが分かった．

4.3 ラベル付け GUI 設計

現在開発中の GUI を図 5 に示す．この GUI は，ラベル選択部とラベル調節部で構成される．画面上部のラベル選択部では，左端に表示されたサンプルと比較して，類似度の高い 5 つのラベル候補サンプルからユーザが手動でラベルを付けることができる．また，それまで出会ったことのない人物を見つけた場合，新たなラベルを追加することができる．画面下部のラベル調節部では，各ラベルに含まれるサンプル数やその代表となる画像を表示するほか，ラベルの修正が可能である．

5. むすび

本論では，領域ベース CNN の中間層特徴から Triplet Loss に基づく特徴学習と転移学習により人物再同定を行う移動ロボット向けの手法を提案した．そして，大規模データセットと自作のデータセットに対して行った実験により，その有用性を確かめた．また，データセットを分割して行った追加の実験から，再同定精度の向上とサンプルとなるデータ量の関係が明らかとなった．今後の課題としては，高精度に人物再同定を行うために早い段階でデータ量を増やす工夫や，再同定結果を移動ロボットのサービス提供に活かすことが挙げられる．

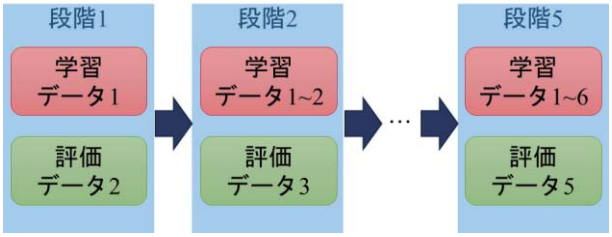


図 4 再同定精度の段階的評価方法

表 4 データセット分割実験 1

	段階1	段階2	段階3	段階4	段階5
サンプル数	2663	5327	7991	10654	13318
クラス数	35	40	40	40	40
精度	19.5	27.4	56.8	59.7	81.4

表 5 データセット分割実験 2

	段階1	段階2	段階3	段階4	段階5
サンプル数	2668	5336	8004	10672	13340
クラス数	28	42	45	48	48
精度	26.2	35.0	26.3	52.4	74.9

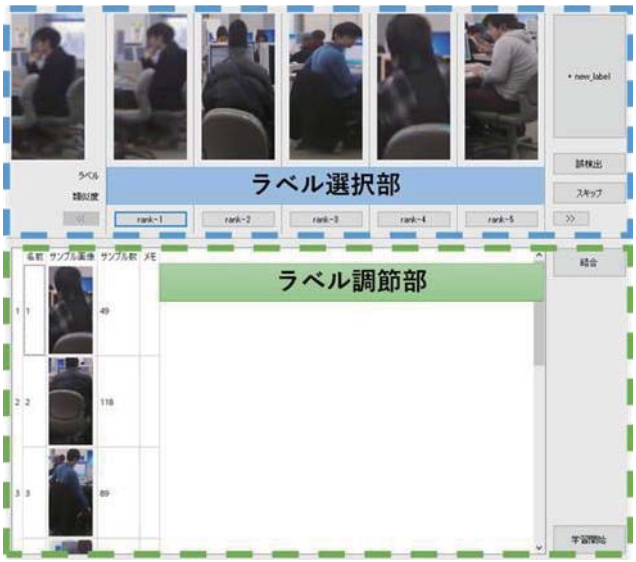


図 5 ラベル付け GUI

参考文献

[Zheng 16] L. Zheng, et al.: Person Re-identification in the Wild, arXiv preprint arXiv:1604.02531, 2016.

[Florian 15] S. Florian, et al.: FaceNet: A Unified Embedding for Face Recognition and Clustering. arXiv preprint arXiv:1503.03832, 2015.

[Redmon 16] J. Redmon, and A. Farhadi.: YOLO9000: Better, Faster, Stronger. arXiv preprint arXiv:1612.08242, 2016.

[渥美 17] 渥美雅保, et al.: SOTARO:オープン チャットとロボットの連携による演習授業支援シス テム―Human-in-the-loop 型機械学習によるアプローチ―. 情報処理学会第 79 回全国大会, 2017.

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

遺伝的アルゴリズムによるシューティングゲームにおけるゲーム AI

An AI game player trained by a genetic algorithm that avoids bombardments in a shooting game

滑川　静海[*1]　　手塚　太郎[*2]
Shizuma Namekawa　　Taro Tezuka

[*1] 筑波大学知識情報・図書館学類
College of Knowledge and Library Sciences, University of Tsukuba

[*2] 筑波大学図書館情報メディア系
Faculty of Library, Information and Media Science, University of Tsukuba

Making programs play games has contributed significantly to the advancement of AI research. It is partly because popular games often resemble real-world problems. Tackling them has enabled AI to cope with real-world scenarios as well. Now that AI has surpassed humans in strategy board games such as chess and go, one next target would be to train it to play video games. This paper focuses on a shooting game and optimizes a program to avoid bombardments deployed by the opposing player. Using a genetic algorithm, the AI player was optimized to move around without hitting enemy attacks. The results of experiments showed that it can successfully learn to do so, although with much computation time.

1. はじめに

人工知能の発展と共に、それにゲームをプレイさせる試みが盛んである。人間がゲームを好むのは本能的な欲求と親和性があるからであり、ポピュラーなゲームは人間の生存に必要なタスクと何らかの類似性を持っていることが多い。そのためゲームで人工知能を鍛えることは今後、人工知能を現実社会に進出させていく上で有益であると考えられる。ゲームは現実世界のタスクと比較してシミュレーションが容易であり、その学習プロセスを研究しやすいというメリットもある。

現在、ゲームに使われている AI には様々な種類が存在している。大別するとゲーム自体をコントロールするメタ AI、ゲームの NPC（non-player character）として機能するキャラクターAI、その時々に応じたゲームの進行を支えるナビゲーション AI の三種類に分けることができる。今回はそのうちのキャラクターAI に分類されるものを扱う。

本研究では AI 技術のうち、特に遺伝的アルゴリズムを用いて戦略を学習させるアプローチをとる。遺伝的アルゴリズムとは生物が進化していく仕組みから着想を得た最適化アルゴリズムである。多数の個体のそれぞれが解の候補を持ち、それらが突然変異や交叉と呼ばれる形で値を変化させながら、最適解を探索する。また、損失関数が小さい個体ほど自らの複製を多数生成するため、その解候補周辺で重点的に探索が行われる。

使用したゲームは PC を中心に生産されている東方 project シリーズの東方妖々夢（図 1）というゲームである。これはいわゆる弾幕シューティングゲームというジャンルに該当する。弾幕シューティングとは、敵機が大量の弾を発射し、自機がそれを避けつつ敵を倒していくというゲームを指す。

熟練した人間のプレーヤーはシューティングゲームにおいて敵が放った大量の弾幕を驚くほどの器用さで回避できる。本研究の目標は遺伝的アルゴリズムを用いてそのようなプレーを AI にも実行させることである。

連絡先：滑川静海，筑波大学知識情報・図書館学類，〒305-855
茨城県つくば市春日 1-2，s1511536@u.tsukuba.ac.jp

このような能力の実現は、たとえば混雑した交通状況の中で自動運転の車をスムーズに移動させる機能にも繋がることが期待される。



図1：東方妖々夢のスナップショット

2. 関連研究

2.1 ゲーム AI

ゲーム AI は様々なジャンルのゲームで研究開発されている。将棋や囲碁といったパズルゲームだけでなく RPG やアクションゲームにも応用されてきている。例えば、昔のアクションゲームは、敵の出現位置や強さが固定されていた。しかし現在はオンライン学習という技術が研究されている。Marc Ponsen（2004）によると「オンライン学習とは、ゲームがリリースされた後に、AI がプレイ中に最適な行動を選択していくというものである。」としている。これはどういうことかというと、以前までのゲームでは完全にランダムにするか決められた環境で遊ぶことしかできなかった。しかしこのオンライン学習という技術を用いると、ゲームの進行中に AI が自分のプレイに適応する、つまり自分の実力にあった難易度や自分のリズムにあったプレイスタイルでゲームを進行することができるようになる。

他の AI を用いた研究としては、AlphaGo が挙げられる。これは碁のプログラムであるが、ニューラルネットワークやディープラーニング、強化学習などを用いて学習をしている。特徴的な学

習方法として、囲碁の AI 同士で対戦することによってお互いを高め合う形で強化学習をしている。これは遺伝的アルゴリズムにおいても応用可能性があり、研究として扱うことができるだろう。

2.2 遺伝的アルゴリズム

遺伝的アルゴリズムに関しても様々な研究がなされている。遺伝的アルゴリズム自体が物事の最適化を進めることのできるものであるため、ゲーム分野との親和性が高い技術と言える。したがってゲーム分野において有効に応用することができる。例えば、本研究で扱うようなシューティングゲームや、アクションゲーム、RPG など多岐にわたる分野で使うことができる。三宅(2008)によると「ゲーム内のキャラクタの進化などに使用される」としている。具体的には、いくつも個体を用意し、それらに何度もトラップを課すことで進化させるというものである。他にもレースゲームに遺伝的アルゴリズムを適用することで効果を得た例もある。このように遺伝的アルゴリズムはゲーム AI の実現に高い適合性を持っていることがわかる。

3. 提案手法

3.1 遺伝的アルゴリズムの概略

本研究で提案する手法では、プレイヤーキャラクターを操作して条件をクリアする個体が現れるまで繰り返し解の探索を続けることである。具体的には、上下左右と動きなしの五種類のコマンドを遺伝子として持った個体を 30 体用意し、各個体でステージをプレイさせ、その個体の中から親候補となる 10 個体をエリート選択方式で選択する。そして選ばれた10個体の中から2個体をルーレット選択方式で選び交叉を行い、3体の個体を生成する。これを10回繰り返すことで新たな世代の30個体を生成する。以上の一連の操作をクリア個体が出るまで繰り返し行い、その経過を見る。

3.2 遺伝子データ

今回は左右のコマンドが選ばれる確率を 5%、上下が選ばれる確率を3%とし、動かない確率を残りの84%とする。これらにより作られた遺伝子データを持つ個体を 30 体用意する。今回の実験ではゴールまでにかかるコマンド数が未知数であるため、また交叉の質を保つため第一世代や上の世代のコマンド数を超えた場合は逐次コマンドを上記の確率に基づいて生成する。この際、なぜ上記のような偏りのある確率にしたかというと、シューティングゲームにおいて、時期が動くことはリスクが高いからである。通常プレイするときは、飛んでくる弾を避ける際にむやみに動かず、自分に当たると予測される球を見つけた際に動いて避けるという動作を行う。従って、動き続けるのではなく動くべき時に動く AI が実用的かつ人間味のある動きと言える。このような理由からそれぞれのコマンドに偏りを持たせている。また、左右と上下の確率に違いがあることもシューティングゲームの特徴が起因していて、東方 project は縦方向シューティングであるため敵の弾は上から飛んでくることになる。その弾を避ける際、縦方向に動くことよりも横方向に動いて避ける方が避けやすいということは感覚的にも明らかだろう。以上のような理由からある程度試行錯誤した結果今回の確率分布に設定した。

3.3 ゲームのプレイ

用意した 30 体の個体を実際にプレイさせる。ここでのプレイ方法であるが、実際に売られているゲームであるためソースコードが公開されていない。そのような理由で UWSC という OS マクロツールを用いて、実際にゲーム上でキー操作を行う形でコマンド操作を行う。

この実験におけるゲーム内の設定であるが、自機の残機は 1(一度被弾した時点で死亡)とする。また、弾は常に発射している状態でボム(一定時間無敵かつ強力な攻撃)は使わないという制約のもと操作を行う。また、実験を行う際のゲームの難易度は easy として進める。

今回の実験においては、第一世代に限り、コマンド生成→コマンド入力→死亡判定→コマンド生成…のように繰り返す。第二世代以降は、引き継いだコマンドを入力→死亡判定の操作を繰り返すが、引き継いだコマンド数を超えて生存していた場合、第一世代と同様にコマンド生成フェーズを挟む。以上のようにゲームのプレイを行い、ひとつの個体がゲームオーバーになる度にそのログを保存する。

3.4 遺伝子の評価と選択、交叉

ゲームのプレイにより得たログを元に遺伝子の評価を行う。今回は単純にステージで最も長く進んだ個体、つまり終了時のコマンド数が大きい個体ほど優秀とする。これによりそれぞれの個体に優秀さの序列をつけることができる。この序列を用いて親の遺伝子を決定するが、今回の実験ではエリート選択方式とルーレット選択方式を掛け合わせた形で選択を行う。具体的には、先に親候補となる遺伝子上位 10 体を選択する。その後、選ばれた 10 個体の中からルーレット選択により親となる二個体を選択する。これにより選択された親二個体から二点交叉で二個体、一様交叉で一個体の計三個体を生成する。

ここで二点交叉は複数交叉に分類されるが、複数交叉とは、北野(1991)によると、「交叉位置が複数ある方法である。例えば、交叉位置が 4 と8なら、新たな個体 B の 5 番目から 8 番目まで、個体 A の 9 番目から最後までによって、遺伝子が作られる。同時に、その逆の組み合わせで、もう一つの新たな個体の遺伝子が作られる。」としている。これは図2、図3を用いて説明する。図2が交叉前の遺伝子を持つ個体 A、B であり、交叉位置としてランダムに選択された二点に囲まれた部分を入れ替えることで、新たな二つの遺伝子を持つ個体(図3)を生成する。また、一様交叉とは、北野(1991)によると「交叉時にマスクをかけてそれによってどちらの親の遺伝子を受け継ぐかを決定する方法である。」としている。これは図4で示している。今回はどちらの遺伝子を引き継ぐ確率はどちらも等しく 1/2 としている。

以上の一連の操作を子孫が 30 体になるまで、つまり 10 回繰り返す。これにより次の世代が決定する。

ここで一つ問題となる点がある。それは、遺伝子の長さが一定ではないため交叉をする際に存在しない点で交叉をしてしまうことがある点である。これを解消するために、交叉をするフェーズに入ったタイミングで遺伝子の大きい個体のコマンド数に合わせて、小さい個体にコマンドの確率を条件通りに保った状態で新たなコマンドを追加する。以下で表を用いて説明する。長さ 9 の遺伝子を持つ個体 1(表 1)と、長さ 3 を持つ個体 2(表 2)を親として選んだ場合を考える。

表における矢印はコマンドの入力された向き、S は stay の S でその場から動かないコマンドを指す。また、×は被弾したことによりゲームオーバーになった状態を示している。

この二つの個体で交叉を行う際に、個体 2 においては 4 以降のコマンドが抜け落ちてしまっている。この状態で交叉を行ってしまうと、表 3 のように被弾した後にコマンドが入力されうるという、ありえない遺伝子データが出来上がってしまう可能性がある。これを解消するために、交叉直前の個体 2 の遺伝子に個体1と比

べた不足コマンド数を条件で指定した確率で追加する。つまり、表 4 のように遺伝子の大きさが等しくなるようにコマンドを補充した後に交叉を行う。

これは最初に遺伝子の長さを一定にした状態で交叉することと本質的には変わらない操作であるため、実験上問題にはならない。

最後に、生成された 30 個体に突然変異を施す。突然変異が起きる確率は 1%と設定し、突然変異に選ばれた子孫個体は、ランダムに選ばれたコマンド二つが入れ替わる。

以上の操作により次世代を構成する子孫を生成する。

表 1:個体 1 のコマンド系列

Index	1	2	3	4	5	6	7	8	9
Command	←	S	S	S	↑	→	S	S	↓

表 2:個体 2 のコマンド系列

Index	1	2	3	4	5	6	7	8	9
Command	↑	S	S	×	×	×	×	×	×

表 3:個体 1 と個体 2 を交叉してできた遺伝子の一例

Index	1	2	3	4	5	6	7	8	9
Command	↑	S	S	×	↑	×	S	S	×

表 4:個体 2 にコマンドを補ってできた遺伝子の一例

Index	1	2	3	4	5	6	7	8	9
Command	↑	S	S	S	←	S	S	S	↑

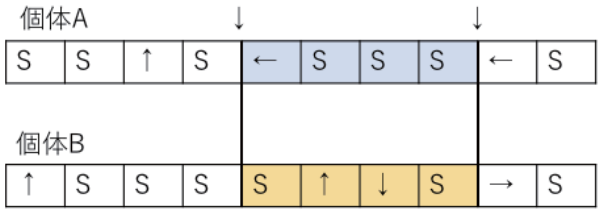


図 2:二点交叉前の個体 A、B

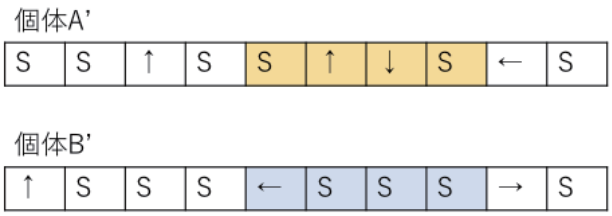


図 3:二点交叉後の個体 A、B

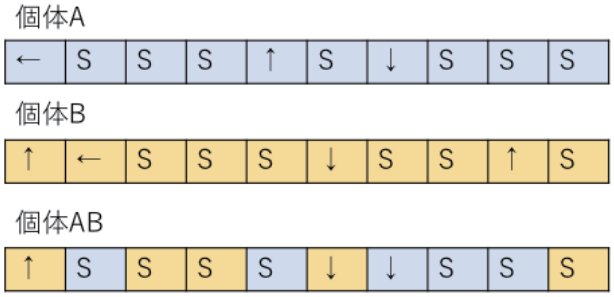


図 4:一様交叉

4. 実験結果

今回は自機が目標とする地点まで到達できるようなコマンド系列が得られることを終了条件とし、終了までに 76 世代を要した。実験により得られた各世代のコマンド数の平均値を図 5 に示した。コマンド数とは遺伝子の長さを指す。

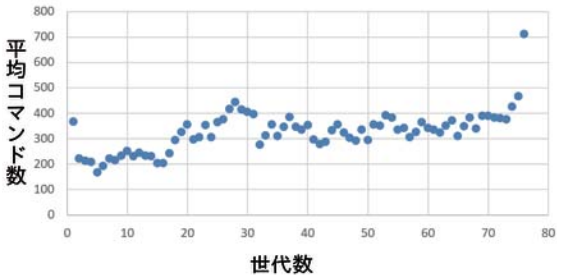


図5:遺伝的アルゴリズムの進行に伴う各世代における平均コマンド数の変化

平均コマンド数を見ることによって学習が進んでいるかを見ることができる。今回の実験においては、平均コマンド数が伸びているならば、よりステージの先に進んでいる個体が多いことを示す。図5から分かるように全体としては徐々に学習していき、右肩上がりになっている。今回の実験で特徴的だった世代としては、第 1 世代、第 28 世代、第 76 世代である。これらの世代では平均コマンド数の局所的なピークが現れている

まず第 1 世代に焦点を当てると、平均値が第 2 世代に比べて高いが、原因としては外れ値として高いコマンド数を持つ遺伝子がいたため、平均値が高くなっていたことが挙げられる。しかし第 2 世代になった途端に一気に平均コマンド数が落ちてしまった。この原因に関してはシューティングゲームの特性が関わっている。シューティングゲームというのは、プレイ中連続的に自機が動いていく、言い換えると、前の瞬間の状況を引き継いだ上で次の行動をとる。つまりこの場合、コマンド一つ一つが独立しているわけではないので、一つ前のコマンドが変わってしまうだけでそこより後のコマンド全てに影響が出てしまう。この特性のために第2世代では平均コマンド数が落ちてしまったと考えられる

第28世代も同様のことが言え、偶然28世代付近では上手くいっていたが、まだ収束するに至っていなかったために次以降の世代では落ち込んでしまったと考えられる。

最後に規定の場所に達した第76世代であるが、これは平均が急激に高くなっている。この理由としては、第75世代における最優秀個体が多く選ばれ、かつ運良く追加されたコマンドが上手く噛み合う形になったからということが考えられる。第69世代から第73世代にかけて横ばいで、かつ第74世代から伸びていることから、この辺りで第73世代までの部分が収束していた可能性が考えられる。遺伝子が収束することで、収束した部分までは同じ動きをするため、その部分までは安定的に到達することができる。従って平均コマンド数の伸びることにつながる。以上のような理由で第76世代において急激に平均コマンド数が伸びたと考えられる。

5. 結論

本研究ではシューティングゲームにおいて敵が打つ弾幕を回避する戦略を遺伝的アルゴリズムを用いて学習させた。

実験の結果、シューティングゲームにおける遺伝的アルゴリズムの適用は有効であった。しかし同時に様々な問題点や課題点が浮上してきた。

一つ目に挙げられるのは、その学習にかかる膨大な時間である。一般にプログラムを動かすのと異なり、60FPS という条件下でコマンドの入力を行うため、ソースコードの有無にかかわらずプレイさせるのに時間を要する。従って、シューティングゲーム、あるいは、より複雑なゲームの AI に適用することを考えると、相応の量の学習時間を見積もる必要がある。それを防ぐためにGUI 上で操作しなくても済むシミュレートツールを作ることが解決策として挙げられる。

次に挙げられる問題点としてはシューティングゲームという特性上遺伝子を組み替えることのリスクが大きいということである。これは 3 でも説明した通り、コマンド一つ一つが独立していなく連続であるがゆえのリスクである。これのために交叉をした際に、一つ前の世代と比較して平均コマンド数が大きく落ちてしまうという現象が見られた。今回は親の選択にエリート選択とルーレット選択を掛け合わせたものを用いたが、やはりこれだけでは良い個体を失ってしまうリスクがあるため、エリート選択で最低でも 1 個体は最優秀のものをそのまま残すという形をとった方が良いと考えられる。

以上のような問題点を解決することができれば学習効率が大幅に上昇し、よりゲーム AI の発展につながるだろう。また、RPG やパズルゲームなどではニューラルネットやディープラーニング等の技術と遺伝的アルゴリズムを組み合わせた AI を組み合わせた AI を作る研究も行われており、シューティングゲームにおいてこれらを利用することも今後の課題である。

謝辞

本研究は, JSPS 科研費 JP16K00228, JP16H02904 の助成を受けたものである。

参考文献

[Marc Ponsen 2004] Marc Ponsen: Improving Adaptive Game AI with Evolutionary Learning , Faculty of Media & Knowledge Engineering Delft University of Technology , 2004.

[伊瀬 顕史 2011] 伊瀬 顕史, 馬野 元秀, 瀬田 和久: Tuning of Fuzzy Rules with a Real-Coded Genetic Algorithm in Car Racing Game, The 27th Fuzzy System Symposium, 2011.

[三宅 洋一郎 2008] 三宅 陽一郎 : How to Use AI Technologies to Develop Digital Games, 人工知能学会誌, 23 巻1号, 2008 年 1 月.

[北野 宏明 1991] 北野 宏明: 遺伝的アルゴリズム, 人工知能学会誌, 7 巻 1 号 , 1991.

[Michael Genesereth 2005] Michael Genesereth, Nathaniel Love, Barney Pell: General Game Playing: AI Magazine, 62-72, 2005.

[David Silver 2016] David Silver, Aja Huang, Chris J. Maddison: Mastering the game of Go with deep neural networks and tree search, Nature 529, pp.484-489, 2016

[Pieter Spronck 2006] Pieter Spronck, Marc PonsenIda Sprinkhuizen-Kuyper: Adaptive game AI with dynamic scripting, Machine Learning, Vol. 63, No. 3, pp. 217-248, 2006.

[川野 洋 2006] 川野 洋: シューティングゲームの敵機攻撃弾発射アルゴリズムに関する考察, 情報処理学会研究報告, 2006.

[片岡 俊 2007] 片岡 俊: 遺伝アルゴリズムを用いたシューティングゲームの攻撃弾発射手法, 高知工科大学 情報システム工学科, 2007.

[Georgios N. Yannakakis 2018] Georgios N. Yannakakis and Julian Togelius : Artificial Intelligence and Games, Springer, 2018.

ZUN: 東方妖々夢, http://www16.big.or.jp/~zun/html/th07.html(2018/03/08)

umiumi, “UWSC”, UWSC, http://www16.big.or.jp/~zun/html/th07.html(2018/03/08)

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

事前知識を活用したMemory Reinforcement Learningによる行動獲得

Action acquisition by Memory Reinforcement Learning useing a prior knowledge

稲盛 有那 *1 Yuna Inamori　平川 翼 *1 Tsubasa Hirakawa　山下 隆義 *1 Takayoshi Yamashita　藤吉 弘亘 *1 Hironobu Fujiyoshi　柏原 良太 *2 Ryota Kashihara
稲葉 正樹 *2 Masaki Inaba　二反田 直己 *2 Naoki Nitanda

*1 中部大学 Chubu University　*2 株式会社デンソー DENSO CORPORATION

Obtaining a human-level control through reinforcement learning (RL) requires massive training. Furthermore, a deep learning-based RL method such as deep Q network (DQN) is difficult to obtain a stable control. In this paper, we propose a novel deep reinforcement learning method to learn stable controls efficiently. Our approach leverages the technique of experience replay and a replay buffer architecture. We manually create a desirable transition sequence and store the transition in the replay buffer at the beginning of training. This hand-crafted transition sequence enables us to avoid random action selections and optimum local policy. Experimental results on a lane-changing task of autonomous driving show that the proposed method can efficiently acquire a stable control.

1. はじめに

Alpha Go[1] が囲碁の世界チャンピオンに勝利して以降，様々な分野で強化学習の活用が期待されている．強化学習は，一般的な教師あり学習と異なり，環境とエージェントのやりとりで得られる報酬を手掛かりに学習する手法であり，未知の環境でも学習が行えるというメリットがある．強化学習は車両やロボットの自律制御 [2] や物体把持 [3] など様々なタスクに応用されている．近年では，Deep Q-Network(DQN)[4] をはじめとする深層強化学習により，複雑なゲームや制御問題を解決することが可能となっている．

深層強化学習による行動獲得は高い性能を示す一方で，複雑な問題に対する学習が難しいという問題が存在する．例えば，DQN のようなニューラルネットワークを用いる手法では，状態を連続値としてネットワークに入力しネットワークの演算を経て行動を出力する．この時，多層のネットワークを用いることで，複雑な問題に対する制御を獲得することが可能となる．しかし，このような多層のネットワークを学習する場合，学習するパラメータ数の増加や勾配消失等により学習が困難となる．また，パラメータはランダムに初期化され学習を開始するが，これはランダムな行動選択から学習を行うことに等しい．特に，時系列行動を強化学習によって獲得する場合，現在の状態に対する制御が過去の制御に依存するため，離散的な行動に比べて困難となる．DQN における学習を安定化させる手法として，過去の行動遷移を蓄積し，蓄積したデータを繰り返しランダムサンプリングして利用する experience replay がある．しかし，ランダムな初期値からの学習では，学習に寄与しない行動選択を蓄積するため，最適な行動を選択するまでに多くの時間を要する．さらに，大規模な状態空間や複雑なタスクに対する学習では局所解に陥りやすく，望ましい行動を獲得することが難しい．

画像認識における Convolutional Neural Network(CNN) では，上記の問題を回避し高い認識性能を実現するために，ImageNet[5] などの大規模な一般物体認識のためのデータセットを用いて学習したモデル (事前学習モデル) のパラメータを初期値とし，個々のタスクに対して学習を行う転移学習が広く用いられている．この事前学習モデルの活用は，タスクが異なった場合でも画像中の特徴が類似していると仮定した上で用いられている．しかし，深層強化学習では問題に応じてその状態空間および入力が異なるため，事前学習モデルの導入が困難である．

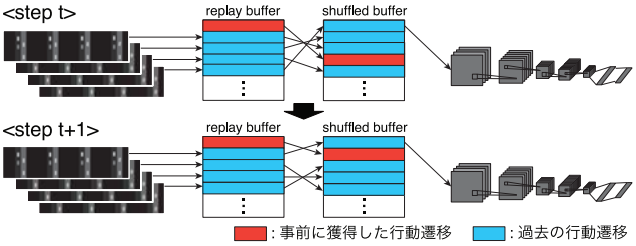
そこで本稿では，事前学習モデルではなく，安定した行動に対する事前知識を学習に導入することで，上記の問題を抑制し，効率的に安定した制御を獲得するための Memory Reinforcement Learning を提案する．提案手法では，事前に獲得した行動遷移を experience replay の replay buffer にあらかじめ保存し，学習を行う．学習時に，replay buffer 内の主導で作成した行動遷移が活用されることで，学習の初期から安定した行動を生成し，効率的に安定した制御を獲得することが可能である．

自動運転車両の車線変更を行うシミュレータを用いた実験にて，提案手法を用いることで安定した動作を効率的に獲得できることを示す．また，replay buffer 内の一部を常に事前知識にして学習した場合および，事前知識のみで学習を行った後に通常の学習を行う場合の性能比較および，事前知識と報酬の組み合わせによる精度の変化について確認する．

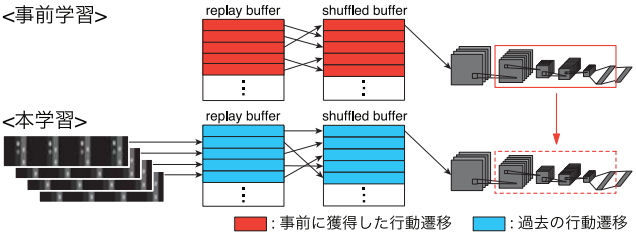
2. 関連研究

強化学習において，効率的に安定した制御を獲得する手法はいくつか提案されている．Peng ら [6] は二足歩行の動作獲得を目的とし，階層的な強化学習手法を提案している．この手法では，目的地まで到達するための長期的な制御と歩行動作を制御する短期的な制御を行う 2 種類の制御システムを用いるこ

連絡先:
稲盛 有那：yuna@mprg.cs.chubu.ac.jp
平川 翼：hirakawa@mprg.cs.chubu.ac.jp
山下 隆義：yamashita@cs.chubu.ac.jp
藤吉 弘亘：hf@cs.chubu.ac.jp
柏原 良太：RYOTA_KASHIHARA@denso.co.jp
稲葉 正樹：MASAKI_INABA@denso.co.jp
二反田 直己：NAOKI_NITANDA@denso.co.jp



(a) 事前知識 A



(b) 事前知識 B

図 1: 提案手法での事前知識の与え方

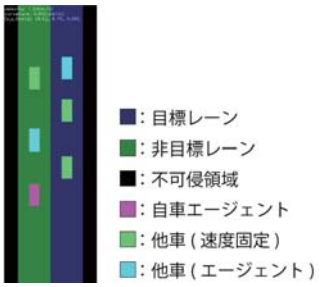


図 2: 環境画像例



図 3: 入力画像例

とで，複雑な地形や環境に対応した歩行動作を獲得している．一方，提案手法では事前に獲得した安定した行動遷移を学習開始時から活用することで，安定した動作を獲得する．

高次元な状態空間における行動を獲得するために，Memory Network[7] を用いて過去の行動を効率的に活用する手法が提案されている [8]．Parisotto ら [9] は長期にわたる過去の記憶を保存し学習に用いるために，Neural Map と呼ばれる手法を提案している．この手法は，3D 環境における強化学習エージェント専用に設計された構造化メモリである．適応可能な書き込み操作を使用しているため，メモリサイズと計算コストは時間の経過と共に増加しない．また，書き込み操作に特定の帰納バイアスを課しており，ナビゲーションが正常な動作の中核要素である 3D 環境に適している．一方，提案手法では単純な過去の行動ではなく，事前に獲得した安定した行動を replay buffer に記憶し学習を行う．

また，事前に獲得した行動を活用する方法として，模倣学習 [10] を導入した手法が存在する [11]．まず模倣学習で他社の行動を真似ることで大まかに望ましい行動を獲得し，その後副報酬を伴う強化学習を行う．模倣学習で得た方策を強化学習による試行錯誤で修正することで，最終的に望ましい行動を獲得する．しかし，模倣学習による行動獲得そのものが難しい問題であり，安定した動作が獲得できなければその後の学習が困難になるという問題が考えられる．一方，提案手法では安定した行動遷移を事前知識として用いるため，不安定な動作の獲得を回避することが可能である．

3. 提案手法

本節では，提案手法について述べる．前述の通り，深層強化学習において安定的な制御を効率よく獲得するために，experience replay を活用する．これは，試行により獲得した状態，行動，報酬のデータを Replay buffer と呼ぶメモリに蓄積する．そして，学習する際に蓄積したデータを繰り返しランダムサンプリングして利用する．通常の強化学習では，学習開始時には Replay buffer の中身は空であるため，一定のエピソードを経て Replay buffer にデータを蓄積させてから学習が始まる．また，初期の Replay buffer 内のデータは殆どランダムな行動をした時のデータである．そのため，膨大な状態と行動の組み合わせから最適な行動を学習するのに時間がかかる．そこで提案手法では，事前知識として望ましい行動遷移を手動で作成し，replay buffer へ格納し，それをもとに学習を開始する．あらかじめ replay buffer に事前知識を蓄積しておくことで，学習の初期から事前知識を用いて学習されるためランダムな行動選択を抑制できる．これにより，効率よく学習を行うことができる．本稿では，作成した事前知識の与え方を 2 種類提案する．図 1 に，事前知識の与え方のイメージを示す．図 1 の replay buffer，shuffled の中の赤色は事前知識，青色は学習中に得た行動遷移を表す．

3.1 事前知識 A

図 1(a) に示すように，replay buffer 内の 1 割に事前知識を常に蓄積しておく．残りの 9 割では従来の replay buffer と同様に，学習が進むにつれデータが入れ替わっていく．これにより，repray buffer 内には常に望ましい行動遷移が蓄積されているため，一定の割合で事前知識を用いた学習を行い，ランダムな行動選択を抑制することが可能となる．

3.2 事前知識 B

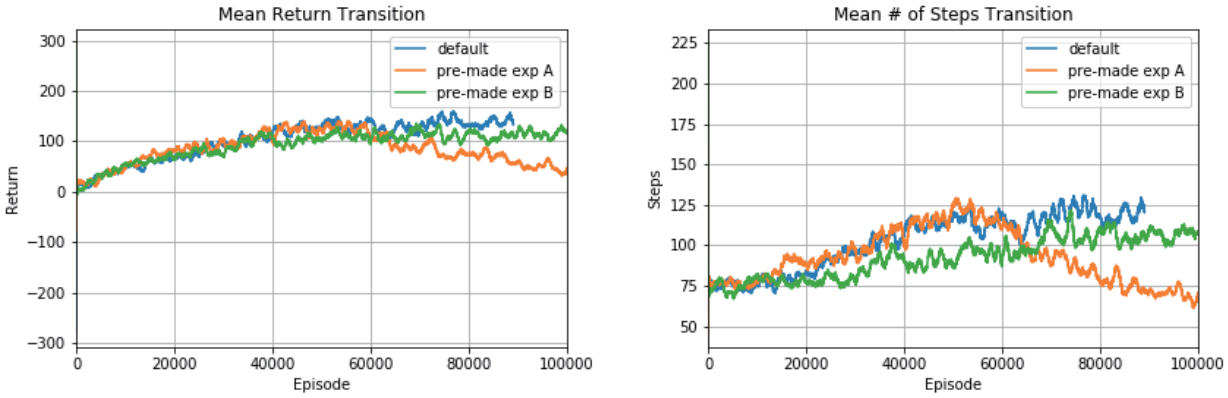
はじめに replay buffer に事前知識として作成した行動遷移データを蓄積しておく．この状態で深層強化学習を行う．この処理を事前学習とする．その後に本学習として，学習したモデルを初期値にして従来の深層強化学習を行う．これにより，事前知識をもとに獲得した行動から，さらに最適な行動を獲得することが期待できる．

4. 評価実験

事前知識の有効性を評価するためのタスクとして，車線変更タスクを用いる．車線変更タスクでは，現在の走行レーンから隣の走行レーンへ移動する．その際，他車が複数台おり，衝突を回避しながら移動しなければならない．また，明確なゴール地点が存在せず，長期の行動を獲得することが必要なタスクである．そのため，事前知識なくランダムな行動から最適な行動を獲得することが困難なタスクとなっている．

4.1 実験概要

図 2 に，車線変更タスクのシミュレータ環境を示す．青色は目標レーン，緑色は非目標レーン，黒色は不可侵領域であり，ピンク色は自車エージェント，黄緑色と水色は他車とする．他車の総数は，学習時は全エピソードで 5 台固定，テスト時はエ



(a) 平均収益　　(b) 平均生存ステップ

図 4: 各エピソードにおける平均収益および平均生存ステップ数の推移

ピソード毎に 0〜5 台のランダムで行う．他車は，固定速度で直進する黄緑色のものと，自車エージェントのモデルをコピーして作られる水色のものの 2 種類存在する．他車が一定速度，または実車と同じエージェントであると，タスクとして簡単になるが，実環境ではドライバの運転スキルにより行動が異なる．そのような環境を想定し，他車に自車エージェントの過去のモデルをランダムに選択して用いる．環境を表した画像から，自車周辺を 84×84 ピクセルに切り出したグレースケール画像 4 フレームを入力とする．図 3 に，入力画像の例を示す．エージェントが可能な行動は，速度 3 種，曲率 3 種を掛け合わせた 9 つである．速度は，$\pm$0m/s（速度維持），+0.1m/s(加速)，$-$.0.1m/s(減速) の 3 種である．曲率は，0(車体角度維持)，+0.01rad/m(左回転)，$-$0.01rad/m(右回転) の 3 種である．これらは，実環境での動作を想定し，実際の車両で制御可能な範囲である．

本実験では，強化学習法として Double DQN[12] を用いる．従来の Double DQN で学習したものをデフォルトとし，事前知識 A，事前知識 B と比較を行う．表 1 に学習条件，表 2 に学習に用いる CNN の構造を示す．

4.2 実験結果

図 4 に，学習時の平均収益，平均生存ステップ数の推移を示す．事前知識 A は，平均収益が 5 万エピソードをピークに途中から低下している．また，平均生存ステップ数も同様に 5 万エピソード付近から低下している．10 万エピソード時点では事前知識 A が最もスコアが低い結果となった．一方，事前知識 B は，平均収益が低下することなく学習できている．また，平均生存ステップ数も同様に低下することなく，増加していることが分かる．

また，表 3 にテストスコアを示す．テスト回数は 100 回であり，成功時に 1 点として計測している．初期レーンは，スタート時の自車エージェントの位置を表す．初期レーンがランダムの場合，初期レーンが必ず非目標レーンである場合の 2 通りでテストを行った．生存スコアは 300 ステップ到達時までに自車が他車や壁に衝突しなかった回数，目標到達スコアは 300 ステップ到達時に自車が車線変更し，目標レーンに達した回数である．人の項目のスコアは，6 名に 100 回ずつテストプレイを行ってもらったスコアの平均である．事前知識を用いないデフォルトは学習後期において，収益，ステップ数ともに最も高くなっている．しかしながら，表 3 に示すようにテストスコアでは事前知識 B よりも低くなっている．これは，最適ではない局所解に陥ったためと考えられる．一方で，デフォルト

表 1: 実験での学習条件

報酬	他車または壁に衝突：-5 衝突していない場合は下記を合算 車線中央付近：+1 停止：-1 目標車線：+1 非目標車線：-2
エピソード終了条件	衝突または 300 ステップ経過
学習エピソード数	最大 100000 エピソード
割引率	0.95
探索法	Linaer decay epsilon greedy
Replay buffer サイズ	$1e+5$

表 2: CNN の構造

	処理	詳細
入力層	サイズ	$4 \times 84 \times 84$
畳み込み層 1	活性化関数	ReLU
	フィルタ	$3 \times 3 \times 16$
	maxpooling	2×2
畳み込み層 2	活性化関数	ReLU
	フィルタ	$3 \times 3 \times 16$
	maxpooling	2×2
畳み込み層 3	活性化関数	ReLU
	フィルタ	$3 \times 3 \times 16$
	maxpooling	2×2
全結合層	活性化関数	ReLU
	ユニット数	256
出力層	ユニット数	9

と比較して，事前知識 A は生存スコアが同等であるが，目標到達スコアが低い．これは，事前知識として与えた経験に頼りすぎ，新たな経験の獲得が十分にされていないことが考えられる．事前知識 B はデフォルトおよび事前知識 A と比べて，高いスコアとなっている．事前知識 B では学習初期は事前知識のみで，学習が進むにつれ replay buffer 内は新しい経験に入れ替わる．しかし，初期で既に人に与えられた行動遷移を得ており，ランダムに参照を行なった場合でも全てに事前知識が導入されているため，さらによい行動を獲得し，テストスコアが上昇したと予想される．したがって，事前知識からタスクで実行するのに有効な基本行動を獲得し，それをもとにさらにタスクに適した行動を獲得できていると考える．

また，人のスコアと比較しても，事前知識 B は生存スコアは約 32%，目標到達スコアは約 31%高い結果となっている．このことから，事前知識 B の手法は車線変更に伴う車体制御が

表 3: テストスコアの比較

	初期レーン	生存スコア	目標到達スコア
デフォルト	ランダム	53	50
	非目標	33	29
事前知識 A	ランダム	49	37
	非目標	37	10
事前知識 B	ランダム	**67**	**66**
	非目標	**51**	**48**
人	ランダム	50.7	50.3

安定しており，効果的であると言える．

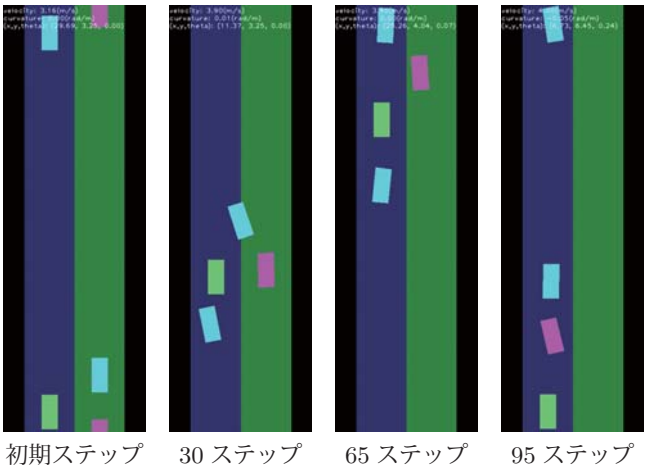
4.3 考察

本実験でテストスコアが最も高かった事前知識 B について，テストシーンにおける動作例を図 5 に示す．図 5(a) では，他車が 3 台いるシーンにおいて，スタート時に自車の前方を走行する他車が車線変更を試みている．その際，自車は他車との衝突を避けるために加速せずに追従している．そして，他車が車線変更後，他車間の間隔が十分に空いたところにスムーズに入る行動を取ることが出来ている．また，図 5(b) では，他車が 3 台おり，隣の車線に 2 台走行している．このようなシーンにおいて，自車は加速して目標車線にいる他車を追い抜き，充分な車間距離になってから車線変更を試みている．このように他車との速度と車間距離を考慮することが出来ている．これらの結果より，提案手法では，人が実環境で車線変更を行う際に取りうる動作を深層強化学習により獲得することができた．

5. おわりに

本稿では，深層強化学習において効率的に安定した制御を獲得するための Memory Reinforcement Learning を提案した．提案手法では，experience replay の replay buffer を活用し，事前に獲得した行動遷移を replay buffer に保存し学習を開始する．これにより，学習初期のランダムな行動選択を抑制し，不安定な行動の獲得を回避することが可能である．自動運転車両の車線変更タスクを用いた実験にて，事前に獲得した行動遷移を用いずに学習した場合と比較し，安定した制御を効率的に獲得できることを確認した．

今後の課題として，事前知識を効果的に活用する方法の検討や事前知識を踏まえた報酬の設計などが挙げられる．



(a) 他車に追従してから車線変更する例

(b) 他車を追い抜き車線変更する例

図 5: 事前知識 B のテストシーンにおける動作例，青:目標レーン，緑色:非目標レーン，黒:不可侵領域，ピンク:自車，黄緑・水色:他車を表している．

参考文献

[1] D. Silver, et al., “Mastering the game of Go with deep neural networks and tree search,” Nature, Vol. 529, pp. 484–489, 2016.

[2] T.P. Lillicrap, et al., “Continuous control with deep reinforcement learning,” In ICLR, 2016.

[3] L.Pinto, *et al*. Learning Hand-Eye Coordination for Robotic Grasping with Deep Learning and Large-Scale Data Collection. In IEEE, 2016.

[4] V. Mnih, *et al*. Human-level control through deep reinforcement learning. Nature 518, pp.529–533, 2015.

[5] J. Deng, et al., “ImageNet: A large-scale hierarchical image database,” In CVPR, 2009.

[6] X.B.Peng, *et al*. DeepLoco: Dynamic Locomotion Skills Using Hierarchical Deep Reinforcement Learning. ACM Transactions on Graphics, Vol. 36, No. 4, Article 41, 2017.

[7] S. Sukhbaater, et al., “End-to-end memory networks,” In NIPS, 2015.

[8] J. Oh, et al., “Control of Memory, Active Perception, and Action in Minecraft,” In ICML, 2016.

[9] E.Parisotto, et al., “Neural Map: Structured Memory for Deep Reinforcement Learning,” In ICLR, 2018.

[10] E. Parisotto, et al., “Imitation Learning: A Survey of Learning Methods,” ACM Computing Surveys, Vol. 50, No. 2, pp. 21:1–21:35, 2017.

[11] 田渕一真ら, “模倣学習と強化学習の調和による効率的行動獲得,” 人工知能学会全国大会論文集, pp. 212–215, 2016.

[12] H. Hassel, et al., “Deep Reinforcement Learning with Double Q-Learning,” In AAAI, 2016.

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

自己学習を用いたニューラル見出し生成

Neural Headline Generation with Self-Training

竹前 慎太郎 *1 Shintaro Takemae　村尾 一真 *2 Kazuma Murao　谷塚 太一 *2 Taichi Yatsuka　小林 隼人 *2*3 Hayato Kobayashi　野口 正樹 *2 Masaki Noguchi　西川 仁 *1 Hitoshi Nishikawa
徳永 健伸 *1 Takenobu Tokunaga

*1東京工業大学 Tokyo Institute of Technology　*2ヤフー株式会社 Yahoo Japan Corporation　*3理化学研究所 AIP センター RIKEN AIP

In this paper we propose a novel method which incorporates self-training into a sequence-to-sequence model in order to improve the accuracy of the headline generation task. Our model is based on neural network-based sequence-to-sequence learning with an attention mechanism and trained with approximately 100,000 labeled examples and 2,000,000 unlabeled examples. Through experiments, we show our proposal significantly improves the accuracy and works effectively.

1. はじめに

自動見出し生成は, 自動要約研究における重要な課題のひとつである [Nenkova and McKeown 2011]. 見出し生成課題は一般的に, 新聞記事などの文章に対して, その文章の内容をより少ない文字数で表す文を生成する課題である. 自動要約によって作成された見出しを提供することで, 読み手は少ない文字数の見出しから記事の内容を把握し, 読むべきかどうかをより迅速に判断できるようになるため, この課題は実用上非常に有用である. 見出し生成における一般的な設定では記事に付属しているタイトル（記事タイトル）が生成されるが, 本論文では, あるニューストピックを指し示すための, 記事タイトルよりもさらに短い文字数の見出し（トピックス見出し）を生成する方法を提案する. Yahoo!ニューストピックスのような総合ニュースサイトにおいては, 記事タイトルの全文字を描画領域に表示できないことが頻繁に起こるため, 記事タイトルよりも短く, そのトピックにおける重要な情報を含む見出しを生成することができれば, 読み手の負担を減らし効率よく記事を提供できるようになる.

一方で, 近年, 自動要約システムは機械学習を用いた手法に大きく依存している. 機械学習の枠組みにおいては, 訓練データ, すなわち入力とそれに対応する出力の組を準備することが必要である. しかしながら, 出力に相当するトピックス見出しは記事タイトルや内容から編集者の手によって作成されており, その作業コストが高いことからこのようなデータセットを十分に用意することは困難である. 学習のためのデータが不足しがちという問題点を克服するため, 本論文では自己学習によって学習データを拡張する手法を提案する. 提案手法では, まず最初のモデルを人間の手によって作成された学習データセットから作成し, 続いて, 記事タイトルのみを持つデータに対して, このモデルを用いて疑似トピックス見出しを付与する. その後, 疑似トピックス見出しが付与されたデータと, 人間がトピックス見出しを作成したデータの両方のデータセットを学習データとしてモデルの再学習を行う. 比較実験により, 提案手法がベースライン手法よりも統計学的に有意に高い精度を達成することを確認した.

連絡先: *1{takemae.s.aa@m, hitoshi@c, take@c}.titech.ac.jp
*2{kmurao, tyatsuka, hakobaya, manoguch}@yahoo-corp.jp

2. 関連研究

自動要約についての手法は, 抽出的要約と生成的要約の大きく 2 つに分類される. 抽出的要約では, システムは入力文章の一部分を抜き出し, それを組み合わせることで出力文を構成する. 生成的要約では, 入力文書に含まれない全く新しい表現を含む出力文を生成する. 後述するように, 編集者がトピックス見出しを作成するときにはしばしば入力文にない表現を用いることがあるため, 本研究課題では生成的要約のアルゴリズムを適用することが望ましいと考えられる.

見出し生成については多くの研究がなされており [Banko et al. 2000, Knight and Marcu 2002, Alfonseca et al. 2013], 近年ニューラルネットワークを用いる手法が活発に研究されている [Rush et al. 2015, Filippova et al. 2015, Takase et al. 2016, Ayana et al. 2016, Xu et al. 2016, Chopra et al. 2016, Zhou et al. 2017, Tan et al. 2017, Tilk and Alumäe 2017]. ニューラルネットワークを用いたアルゴリズムでは主に, 文章の単語分散表現の系列を入力とし, encoder-decoder 型のネットワークにアテンション機構を取り入れた構成によって出力文を生成する.

自己学習は, 自然言語処理において広く用いられており, 構文解析 [McClosky et al. 2006] や語義曖昧性解消 [Mihalcea 2004] などに利用されている. sequence-to-sequence の研究においても, Dai と Le によって半教師あり学習の手法が提案されている [Dai and Le 2015]. 彼らは, 前段の教師なし学習によって後段の教師あり学習におけるより良い初期パラメータを計算する事前学習手法を提案した. 彼らの手法と異なり, 本論文の提案手法では, 正解付きのデータセットを用いて前段のモデル学習を行うが, その後, 正解を持たないデータセットに対してこのモデルから疑似正解を付与し, これらの正解付き・疑似正解付きの両方のデータセットを利用して学習することで最終的なモデルを獲得する. 前段の教師あり学習によって作成されるモデルと, 後段の自己学習を経たモデルを比較した結果, 後者のモデルが前者のモデルより高い精度

記事タイトル	トピックス見出し
＜天皇陛下＞退位後に「赤坂御用地」に転居　宮内庁検討	陛下 退位後は赤坂に転居案

表 1: 記事タイトルと対応するトピックス見出しの例 *4

を達成することを確認した.

3. 提案手法

本論文の提案手法は以下のような手順による.

1. 教師あり学習 (ベースライン): ベースラインのモデルは, 人間の作成したトピックス見出しと記事タイトルの組から学習される.
2. 疑似見出しの生成: 次に, 記事タイトルのみからなるデータセットに対して, 手順 1 で作成したモデルを用いて疑似トピックス見出しを作成する.
3. 提案モデルの学習: 最後に, 手順 1 のオリジナルデータと, 手順 2 で疑似トピックス見出しが付与されたデータの両方を用いて, 提案モデルの学習を行う.

言い換えると, 提案手法においては, ベースラインのモデルから新しいデータセットを作成することで自己学習を行っている.

4. 実験

4.1 実装と設定

ベースラインのモデルを作成するため, OpenNMT ツールキット [Klein et al. 2017] を利用した. encoder-decoder モデルのネットワークとして, Luong らによって提案された, stacking recurrent neural network に global attention を加えた構成を用いている [Luong et al. 2015].

encoder の入力には 3000 次元の one-hot ベクトルを埋め込んだ分散表現を用い, 250 次元の内部ベクトルを持った 3 層の隠れ層による双方向 LSTM を採用した. decoder においても, 出力した語の再入力に同様の分散表現を用いたが, 3 層の隠れ層の内部ベクトルの次元数は 500 とした. 学習時の最適化手法として Adam [Kingma and Ba 2014] を採用し, そのハイパーパラメータはそれぞれ, $\beta_1 = 0.9$, $\beta_2 = 0.98$, $\varepsilon = 10^{-9}$, $\alpha = 10^{-3}$ とした. 前段の学習と後段の学習はそれぞれ 30 エポックずつ行い, そのミニバッチサイズは 64, dropout 率は 0.3 とした.

本研究では対象とする見出しが非常に短いことから, 分散表現として単語単位ではなく文字単位の入力を用いた. すなわち, システムは記事タイトルを 1 文字ずつ読み込み, その出力として見出しを 1 文字ずつ生成する.

また, 出力時には探索幅 5 によるビームサーチを用いて見出しを生成した.

4.2 比較手法

以下の 3 手法を比較した.

- ベースライン手法: 前述の通り, アテンション機構付きの一般的な encoder-decoder 型モデルをベースラインとして採用した.
- 事前学習手法: 他の半教師あり学習との比較のため, Dai と Le が提案した sequence autoencoder に基づく事前学習手法 [Dai and Le 2015] を比較対象とした. この手法では, 正解見出しなしデータを用いた sequence autoencoder モデル (記事タイトルから記事タイトルへの sequence-to-sequence モデル) の学習を行った後, そのパラメータで初期化したモデルの学習を行う. このとき初期化するパラメータの対象を全てのネットワークパラメータとする場合と, アテンション機構を除く encoder-decoder 部分のみのパラメータを初期化する場合について実験を行った. なお, Dai と Le はこの事前学習手法を感情分析課題で評価している. そのため, 事前学習手法が想定していた, 事例を正負に分類する単純な分類問題と比較して, 本研究課題のほうが複雑であることを考慮に入れる必要がある.
- 提案法: 正解見出しを持つデータと, 疑似正解見出しを付与したデータの双方を学習データとして学習を行った.

4.3 データ

実験用のデータセットとして, 日本語ニュース記事タイトルと, それに対応するトピックス見出しの組を用いた. 表 1 にその例を示す. トピックス見出しにおいては全体の長さをコンパクトにまとめるため, 記事のタイトルに含まれているいくつかの語を省いたり, 言い換えなどが行われている.

クローリングによって, 記事タイトルのみからなるデータセットを準備した. このうち, トピックス見出しと紐付けられた約 10 万組を教師ありデータとし, 紐付けをしなかったものを自己学習用のデータとした. 教師ありデータは, 約 60%を学習データ, 約 20%を開発データ, 約 20%をテストデータとして分割した. 自己学習を経たモデルの精度にデータセットのサイズが与える影響を確認するため, 自己学習用データからそれぞれ 20 万件, 40 万件, 80 万件, 100 万件, 150 万件, 200 万件をサンプリングしたデータセットを作成した.

トピックス見出しは全て 13.5 文字以内で記述されている. 日本語のひらがな, カタカナ, 漢字はそれぞれ 1 文字として数えられ, 英語のアルファベット, 数字および空白文字については 0.5 文字換算として数えられる. すなわち, 編集者は 13 文字の日本語の文字と空白文字 1 つによってトピックス見出しを作成することができ, またアルファベットや数字を用いる場合はそれらの 2 文字を日本語の 1 文字分と換算することができる.

4.4 評価尺度

評価尺度として, 文字ベースの ROUGE-1 指標を用いた [Lin 2004]. これは比較対象のシステムが単語ではなく文字を単位として出力するためである. データセット中の記事タイトルとトピックス見出しは非常に短く, トピックス見出しはしばしば言い換えが用いられている. 単語ベースの ROUGE は言い換え表現を過剰に低く評価するが, 文字ベースで評価すると, 元の単語を構成する文字を抽出したような略語についてはその語を正解に含まれるものとして評価できる. このように, 文字ベースの評価を行うことで, 単語ベースの評価よりもより正確な生成文字列の評価が可能であると考えられる.

また評価において初期値による影響を軽減するため, それぞれの手法に対し, 異なる初期値による 10 回の学習とトピック

*4 https://news.yahoo.co.jp

	ROUGE-1
ベースライン	0.568
事前学習（アテンション機構除く）	0.520
事前学習（全て）	0.503
提案手法（60 万件）	**0.574**

表 2: ROUGE-1 の平均

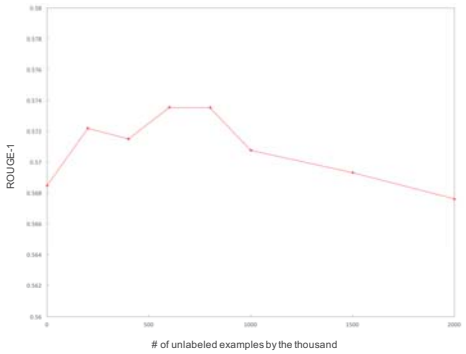


図 1: 正解なしデータのサイズに対する提案手法の ROUGE-1

ス見出しの生成を行い, その評価値の平均をその手法のスコアとして採用した.

5. 結果と考察

表 2 に実験結果を示す. 提案手法のスコアは, 60 万件の自己学習用データセットを用いた場合のモデルを採用した. 提案手法によるモデルは, 自己学習を行わないベースラインモデル, および事前学習を行ったモデルより高い精度を達成した. t 検定により, 提案法と比較手法の間の ROUGE-1 スコアは統計学的に有意であることが示された ($p < 0.05$).

事前学習手法はベースラインよりも低い精度となった. 全てのパラメータを事前学習する手法と比較して, アテンション機構のパラメータを事前学習による初期化の対象から除く手法が良い精度を達成した. このことは, アテンション機構が, 入力された記事タイトルに含まれる情報のうち, どのような情報をトピックス見出しに残すべきかといった, 教師なし学習からは本質的に学習できないパラメータを学習しており, そのため正解のないデータからは望ましい初期値を得られなかったことを示唆している.

図 1 に, 自己学習用のデータセットのサイズに対する提案法の精度の変化を示した. データセットのサイズが 60 万件, および 80 万件のときスコアは 0.574 と最も高い値を記録した. データセットのサイズが小さいとき, もしくは大きすぎるときに精度が低下する現象は, 正解なしデータが多くなりすぎることで, 本来学習すべき対象である正解ありデータよりも大きな影響を持ってしまうことで生じると考えられ, 自己学習ではしばしば確認される. そのため, 自己学習用に疑似正解を付与する際に望ましい出力例のみを採用することができれば, 自己学習による精度向上はより大きくなると考えられる.

表 3 に, 提案法と比較手法による出力文字列の長さ (文字ベース, 半角英数字も 1 文字として数える) を掲載した. 要約率は約 50%で, 機械によって生成された見出しの長さはどれも, 編集者が作成したものと比較して若干短い傾向にあった.

図 4 に, 評価データに対するモデルの出力例をいくつか掲載した. 1 番目の例では, 記事タイトル中の「割引切符」という名詞を, モデルによる出力で「割符」と略語化している. 提案手法においては単語単位ではなく文字単位で処理が行われるため, 複合語が再構成されて出力されることがある. この出力例に対し ROUGE 値は高い値を示すが, 「割引切符」と「割符」は異なるものを指し示すため, この出力例から正しい意味を読み取ることは難しい.

	文字数
本文	595.6
記事タイトル	26.4
トピックス見出し	14.0
ベースライン	13.6
事前学習（アテンション機構除く）	13.3
事前学習（全て）	12.8
提案手法（60 万件）	13.5

表 3: 平均文字数

2 番目の例では, ベースラインモデルは「ロボット」という語を反復して出力し, この見出しで正しい記事内容を説明することは困難である. 一方で, 提案手法の出力では「ソフトバンク」という文字列を「ソフト B」のようにうまく略語化しているように見えるが, 正解トピックス見出し中に「ソフトバンク」に相当する語がなかったため ROUGE 値はベースラインモデルを下回った.

3 番目の例においては, 正解の見出しは記事タイトルの削除操作で生成することができ, 学習モデルはこれを模倣している. Filippova らの先行研究によって, ニューラルネットワークによる文圧縮モデルは, データセット中に存在する正解文字列が全て元文字列の削除操作のみから生成することができる場合に比較的良い結果を見せることが報告されている [Filippova et al. 2015].

4 番目の例のように正解見出しが記事タイトルと全く異なっていると, モデルが生成した見出しがある程度意味をとれるものであっても, 正解見出しと共通する文字を持たないことから ROUGE-1 が低い値をとる場合がある.

最後の例では, 提案手法による出力はベースラインモデルのものよりも望ましい出力を得た. ベースラインモデルは記事の重要な要素とみられる「試験」という語を生成見出しから欠落させたが, 提案法ではこれを残したままトピックス見出しを生成できた.

全般的に, 人間の編集者によって作成されたトピックス見出しは洗練された言い換え表現を含んでおり, これらはしばしば文字単位で置き換えられている. 正解のトピックス見出しが入力文の削除操作のみから生成することができる場合には, ベースラインモデルと提案モデルの双方から比較的良い出力結果を得ることができた.

6. まとめ

本論文では, アテンション機構付き sequence-to-sequence のモデル学習に, 自己学習を追加する学習手法を提案した. 実験により, 自己学習を追加して行うことで学習モデルの精度が有意に向上したことが示された.

5 節で議論したように, 自己学習のために生成された疑似正解見出しの中から品質の高い組のみを選ぶことができれば, より自己学習の効果が高まると考えている. また, 人間の編集者はトピックス見出しを作成する際に記事タイトルだけでなく記事の内容などを考慮に入れていることから, モデルにおいても記事リード文などの情報を考慮することで生成見出しの品質を高めていくことを検討している.

記事タイトル	トピックス見出し	ベースライン	提案手法
JR 東日本の割引切符に若者からため息，高齢者優遇の背景は？	JR のシニア優遇に若者ため息	JR 東の割引切符高齢者の背景 (0.462)	JR 東割符に若者からため息 (0.615)
ソフトバンクがロボット事業に参入，日本のロボット産業どうなる？	日本のロボット産業 未来は?	日本ロボットロボットに参入 (0.462)	ソフト B ロボット事業に参入 (0.385)
＜ボクシング＞亀田ジムが新会長での再出発を検討	亀田ジム 新会長で再出発検討	亀田ジム新会長で再出発検討 (1.000)	亀田ジム新会長で再出発検討 (1.000)
カーボヴェルデ代表が世界ランクで日本を追い抜いた理由	FIFA ランク 無名国がなぜ躍進	カーボヴェルデ代表日本追い抜く (0.000)	カーボヴェルデ代表日本追い抜く (0.000)
ドワンゴの入社試験有料化，その是非をどう考えるべきか	入社試験「有料化」の是非は	ドワンゴ有料化その是非どう (0.462)	ドワンゴの入社試験有料化へ (0.615)

表 4: 出力例 と ROUGE-1 *5

参考文献

[Alfonseca et al. 2013] Alfonseca, E., Pighin, D., and Garrido, G. (2013). Heady: News headline abstraction through event pattern clustering. In *Proceedings of the 51st Annual Meeting of ACL*, pages 1243–1253.

[Ayana et al. 2016] Ayana, Shen, S., Liu, Z., and Sun, M. (2016). Neural headline generation with minimum risk training. *CoRR*, abs/1604.01904.

[Banko et al. 2000] Banko, M., Mittal, V. O., and Witbrock, M. J. (2000). Headline generation based on statistical translation. In *Proceedings of the 38th Annual Meeting on ACL*, pages 318–325.

[Chopra et al. 2016] Chopra, S., Auli, M., and Rush, A. M. (2016). Abstractive sentence summarization with attentive recurrent neural networks. In *Proceedings of the 2016 Conference of NAACL-HLT*, pages 93–98.

[Dai and Le 2015] Dai, A. M. and Le, Q. V. (2015). Semi-supervised sequence learning. In *Advances in Neural Information Processing Systems 28*, pages 3079–3087.

[Filippova et al. 2015] Filippova, K., Alfonseca, E., Colmenares, C. A., Kaiser, L., and Vinyals, O. (2015). Sentence compression by deletion with lstms. In *Proceedings of the 2015 Conference on EMNLP*, pages 360–368.

[Kingma and Ba 2014] Kingma, D. P. and Ba, J. (2014). Adam: A method for stochastic optimization. *CoRR*, abs/1412.6980.

[Klein et al. 2017] Klein, G., Kim, Y., Deng, Y., Senellart, J., and Rush, A. M. (2017). Opennmt: Open-source toolkit for neural machine translation. *CoRR*, abs/1701.02810.

[Knight and Marcu 2002] Knight, K. and Marcu, D. (2002). Summarization beyond sentence extraction: A probabilistic approach to sentence compression. *Artificial Intelligence*, 1(139):91–107.

[Lin 2004] Lin, C.-Y. (2004). Rouge: A package for automatic evaluation of summaries. In *Proceedings of ACL Workshop Text Summarization Branches Out*, pages 74–81.

[Luong et al. 2015] Luong, M.-T., Pham, H., and Manning, C. D. (2015). Effective approaches to attention-based neural machine translation. In *Proceedings of the 2015 Conference on EMNLP*, pages 1412–1421.

[McClosky et al. 2006] McClosky, D., Charniak, E., and Johnson, M. (2006). Effective self-training for parsing. In *Proceedings of the Main Conference on NAACL-HLT*, pages 152–159.

[Mihalcea 2004] Mihalcea, R. (2004). Co-training and self-training for word sense disambiguation. In *Proceedings of the Eighth Conference on CoNLL*, pages 33–40.

[Nenkova and McKeown 2011] Nenkova, A. and McKeown, K. (2011). *Automatic Summarization*. Now Publishers.

[Rush et al. 2015] Rush, A. M., Chopra, S., and Weston, J. (2015). A neural attention model for abstractive sentence summarization. In *Proceedings of the 2015 Conference on EMNLP*, pages 379–389.

[Takase et al. 2016] Takase, S., Suzuki, J., Okazaki, N., Hirao, T., and Masaaki, N. (2016). Neural headline generation on abstract meaning representation. In *Proceedings of the 2016 Conference on EMNLP*, pages 1054–1059.

[Tan et al. 2017] Tan, J., Wan, X., and Xiao, J. (2017). From neural sentence summarization to headline generation: A coarse-to-fine approach. In *Proceedings of IJCAI-17*, pages 4109–4115.

[Tilk and Alumäe 2017] Tilk, O. and Alumäe, T. (2017). Low-resource neural headline generation. *CoRR*, abs/1707.09769.

[Xu et al. 2016] Xu, L., Wang, Z., Ayana, Liu, Z., and Sun, M. (2016). Topic sensitive neural headline generation. *CoRR*, abs/1608.05777.

[Zhou et al. 2017] Zhou, Q., Yang, N., Wei, F., and Zhou, M. (2017). Selective encoding for abstractive sentence summarization. In *Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, pages 1095–1104. Association for Computational Linguistics.

*5 JR 東日本は東日本旅客鉄道株式会社の商標または登録商標です. ソフトバンクの名称は, 日本国およびその他の国におけるソフトバンクグループ株式会社の登録商標または商標です. ドワンゴは株式会社ドワンゴの商標または登録商標です. その他、本論文中に記載されている会社名および商品・サービス名は、各社の商標または登録商標です.

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

画像認識を用いたATMセキュリティ強化

Security Reinforcement for ATM by Using Image Sensing

岸礼子[*1] ファンチョンフィ[*1] 山本一真[*1] 増田誠[*1]
Reiko Kishi Phan Trong Huy Kazuma Yamamoto Makoto Masuda

[*1] 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.

ATM (Automated Teller Machine)-related crimes have been reported as serious problems overseas. One of such crimes is *skimming*: the act of installing skimming device on ATM to illegally copy information of cash cards or passwords. Detecting such illegal acts promptly is important since we can immediately prevent ATM-related crimes by automatically raising alarms and also reduce supervisor's monitoring burden. We have realized an anomaly behavior detection technique which finds not only suspicious devices but also detects actions of installing them. In this article, we discuss our proposed method which combines video feature extraction, ATM status acquisition and recognition. Compared to processing only image information, the proposed method proves to be more effective in recognizing anomaly behaviors from normal behaviors.

1. はじめに

海外では ATM（Automated Teller Machine）利用者のカード情報や暗証番号情報を盗み取るスキミング等の犯罪が深刻な問題となっている。このような犯罪を実行時に検知することは、その場での警報や通報による犯罪抑止や監視員の負担軽減につながるため重要である。しかし近年は犯罪装置の小型化が進み、ATM 外観からは犯罪装置の識別が困難となっている。そこで我々は犯罪装置だけでなくそれを取り付けている行為も検知する技術を実現した。

本稿では、動画像処理による異常行動検知手法に“ATM 状態把握”を組み合わせた ATM 異常行動検知手法を提案する。さらに模擬データを用いて提案手法の有効性を示す。

2. 動画像処理による異常行動検知手法

本章では、一般的な動画像処理による異常行動検知手法を紹介し、ATM へ応用する際の課題を述べる。

2.1 一般的な動画像処理による異常行動検知

動画像処理による異常行動検知手法は一般的に、“動画像特徴抽出”と“識別処理”が用いられる。

[南里 2005]は、動画像特徴に立体高次局所自己相関（CHLAC）を、識別処理には部分空間法を用いている。CHLAC は画素値を 2 値化した連続する 3 フレーム間の局所領域を 251 個のパターンに当てはめる手法である。異常行動が正常行動の中に混ざっても検知可能（加法性）で、かつ、検知性能は画像内の位置に依らない（位置不変性）という利点を持っている。部分空間法では、特徴空間上に正常行動の部分空間を構成し、入力フレームの特徴量とその部分空間との距離を異常度として扱っている。これにより、複数人歩行者の中での転倒動作を異常として検知し、手法の有効性を示している。

[弓場 2012]は、動画像特徴として Space-Time Patch（ST-Patch）、識別には Continuous Rank-Increase Measure（CRIM）を用いている。ST-Patch は、動画像の小領域内の濃度勾配値の統計量から求められる。勾配値は上下左右の画素に加え連続するフレーム間からも求めるため、特徴量は「見え」と「動き」の情報を併せ持っている。CRIM は、ST-Patch から計算できる非定常度の値で、この値が閾値を超えたときに異常とみなしている。ST-Patch と Real AdaBoost と呼ばれる機械学習手法によって人物領域検出を行い、Real AdaBoost の信頼度を用いて人物領域内の人の部分に重み付けを行った CRIM で異常検知を行っている。それによって、エスカレーターでの転倒を対象とした動的な背景下での異常行動検知手法を提案している。

その他にも異常行動検知に用いられる手法には、動画像特徴として、[林 2006]では Optical Flow、[Kobayashi 2012]では STACOG、[弓場 2012]では MHI などがあり、識別処理としては、Linear Discriminant Analysis（LDA）、Support Vector Machine（SVM）、Gaussian Mixture Models（GMM）などがある。

2.2 ATM 異常行動検知での課題

我々は動画像処理による異常行動検知を ATM に対する犯罪の検知に応用する。監視カメラは ATM の上部に設置し、手元の細かい動作がわかるように、操作部を中心に撮影する（図 1）。

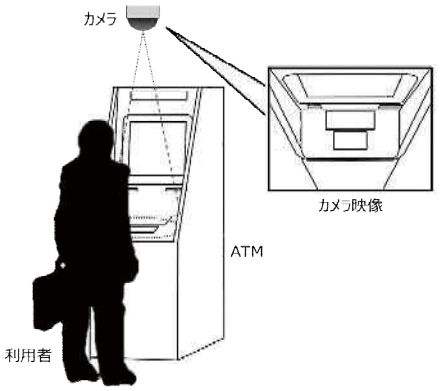


図 1: 撮影イメージ

連絡先: 岸礼子, 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, kishi422@oki.com

「引き出し」「預け入れ」などの ATM に対する通常操作が正常行動となる。正常行動は動作速度に個人差があり、さらに端末上に手を置く・持ち物を持つなど操作以外の動作が含まれる。また、異常行動はカードを挿入口へ差し込むふりをして犯罪装置を設置するなど、正常行動に似せた犯罪行動が起こり得る。このように正常行動と異常行動に多様性があるため動画像処理のみでの識別は十分な精度を期待できない。

3. 提案手法

我々は“ATM 状態把握”を導入し、動画像特徴量抽出と ATM 状態把握および識別処理による異常行動検知手法を提案する。本手法は異常検知辞書を作成する学習フェーズと、異常検知辞書を用いて異常行動を検知する検知フェーズに分かれる。本章では、“ATM 状態把握”の概要、学習フェーズと検知フェーズについてそれぞれ説明する。

3.1 ATM 状態把握

“ATM 状態把握”とは、「無人状態」「暗証番号入力状態」などといった ATM の取引状態(以下、ATM 状態)を把握することである。ATM 状態把握により、起こり得る正常行動を限定できることが大きな利点である。図 2 のように、無人状態から利用者が取引を行って立去るまでには ATM 状態は多様に変化する。例えば「暗証番号入力状態」では暗証番号キーに対する動作が発生するが、それ以外の ATM 状態時に暗証番号キー周辺に動作があれば警戒する必要がある。「近接状態」は取引開始前または終了後のことである。そのため ATM 操作のような複雑な動きは起こらないはずであり、複雑な動作がある場合には警戒する必要がある。このように、ATM 状態把握によって起こり得る動作を絞ることで、異常行動検知の識別性能の向上が可能になる。

ATM 状態は、ATM 自体から通知される内部状態の情報を用いて把握する。

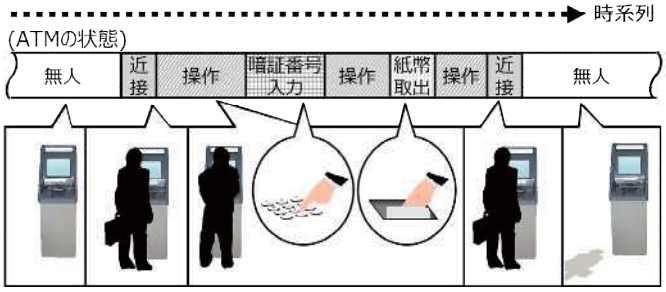


図 2:ATM 状態が変化していく例

3.2 学習フェーズ

学習フェーズでは、正常行動のみを用いて機械学習を行い ATM 状態毎の異常検知辞書を生成する。

図 3 に提案手法の流れを示す。まず、カメラから映像を取得し、フレームごとに正規化画像を生成し、特徴量を抽出する。ATM 状態把握では、入力フレームに対応する ATM 状態を取得しておく。その後、ATM 状態ごとに蓄積しておいた特徴量に対して、機械学習を用いて ATM 状態毎の異常検知辞書を生成する。

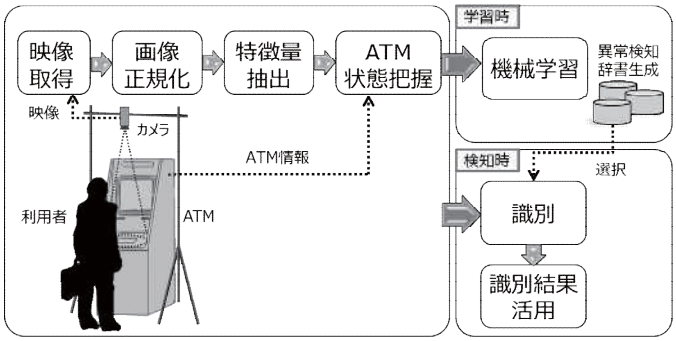


図 3:提案手法の流れ

3.3 検知フェーズ

検知フェーズでは、入力フレーム毎に正常／異常を判定する。

映像取得から ATM 状態把握までは、学習フェーズと共通の処理となる。入力フレームと同じ ATM 状態時の特徴量から生成した異常検知辞書を選択して識別処理を行い、正常／異常を判定する。識別結果活用では、結果が異常だった場合にのみアラーム発報、ATM 画面へのメッセージ表示、監視センターや ATM 管理者への通知・通報などを行う。

4. 評価

提案手法の有効性を確認するための実験を行った。本章では、従来手法(動画像特徴抽出と識別処理)と提案手法(動画像特徴抽出と ATM 状態把握および識別処理)でそれぞれ異常行動検知を行い、結果を比較する。

4.1 処理概要

従来手法と提案手法の間で“ATM 状態把握”に関わる処理以外は共通である。映像をフレームレート 10fps で取得し、画像正規化で 640×480 pixel にリサイズする。動画像特徴には細かい動きに対応できる ST-Patch を使用し、識別処理には一般的に用いられる部分空間法を用いた。入力フレームの特徴量と正常行動の部分空間との距離を異常度として算出し、異常度が閾値を超えた場合に「異常」と判定する。

4.2 評価データ

社内で模擬環境を構築し、実際に ATM に対する動作の映像を取得した。被験者として社員 149 名を集めて撮影し、正常行動データと異常行動データを生成した。正常行動データは、ATM の通常の取引を撮影したものとなる。通常の取引の中には、左手の操作、手を置く動作、紙幣を数える動作など特徴のある動きを意図的に含んでいる。異常行動データは、一般に知られている犯罪事例を元にしてシナリオを作り、犯罪行動を真似た動きを演じることで生成した。学習データと検知データにはそれぞれ以下を用いた。

- 学習データ:
  正常行動　約 800 動作(約 60 万フレーム)
- 検知データ:
  未学習の正常行動　約 240 動作
  異常行動　32 動作

ここでの異常行動は、カード挿入口に犯罪装置を取り付ける行為である。犯罪装置は厚紙などで模式的に製作したもので、カード挿入口を覆う様に取り付けられる。

4.3 評価方法と結果

本稿では、動作単位で評価を行う。各動作の中で一度でも異常と判定されたフレームがあればその動作を「異常」とし、そうでない場合は「正常」とする。評価指標には、Equal Error Rate（EER）を用いる。EER は、正常行動の誤検知率と異常行動の未検知率が等しくなるときのエラー率である。

従来手法は EER が 8.3% となった。正常行動に含まれているカードの入れ直しをする動作が高い異常値となったことが原因として挙げられる。一方、“ATM 状態把握”を導入した提案手法では EER が 0.0% となり、正常行動と異常行動を全て正しく識別できた。従来手法は、多様な正常行動を一つの部分空間にするのに対し、本手法は ATM 状態毎に起こり得る正常行動を学習するため、従来手法で見られた誤検知・未検知が改善されたと考えられる。

表 1：評価結果

	従来手法	提案手法
EER	**8.3 %**	**0.0 %**

5. おわりに

我々は、犯罪装置取付けなどの犯罪行動の検知が可能な異常行動検知技術を実現した。動画像特徴量抽出と ATM 状態把握および識別処理を組み合わせた手法を提案し、動画像処理のみでは識別できなかった正常行動と異常行動に対して結果が改善されることを確認した。本技術は ATM 操作に不慣れな人の戸惑い検知への応用も期待できる。

本評価データは疑似環境データでの評価のため、実環境データでの検証が必要である。

参考文献

[南里 2005] 南里卓也, 大津展之: 複数人動画像からの異常動作検出, 情報処理学会論文誌, vol.45, no.SIG_15, pp.43-50, 2005.

[弓場 2012] 弓場竜, 村井泰裕, 藤吉弘亘: 時空間特徴の統計的学習を用いた異常行動検知, 電子情報通信学会論文誌, vol.J95-D,no.6,pp.1369-1379,2012.

[林 2006] 林健太郎, 羽下哲司, 関真規人, 笹川耕一: 映像監視における人物位置行動の検出技術, 情報処理学会論文誌, vol.47, no.SIG_9, pp.12-19, 2006.

[Kobayashi 2012] Kobayashi, T., Otsu, N., : Motion recognition using local auto-correlation of space–time gradient, Pattern Recognition Letters, vol.33,no.9,pp.1188-1195,2012.

[弓場 2012] 弓場竜, 縣禎輝, 藤吉弘亘: 回帰推定による欠損距離画像の動作特徴量補正法, 電子情報通信学会技術研究報告, 信学技報, 2012.

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

船舶のタンク・ホールド内画像認識に関する研究

Study on Image Recognition in Tank / Hold of Ship

平方 勝　　馬 沖　　谷口 智之
Masaru Hirakata　　Ma Chong　　Tomoyuki Taniguchi

海上・港湾・航空技術研究所
National Institute of Maritime, Port and Aviation Technology

This document describes whether image recognition using Deep Learning can be practical for images taken by unmanned aerial vehicle (drone). There is a movement to try to utilize a drone for inspection inside tank / hold of the ship. Accessibility to the inspection site becomes easy, while on the other hand, a technique to support condition evaluation on the screen is also required to judge through the video taken with the drone. In this research, we examined to verify the recognition rate of structural members in tank / hold in a bright environment. In addition to recognizing in a bright environment, we also examined to verify the recognition rate in a virtual dark environment.

1. はじめに

船舶のタンク/ホールド内の点検に，ドローンを活用しようとする動きがある．点検箇所へのアクセスが容易になる一方，ドローンで撮影した映像を通して現場判断するため，画面上で状態評価を支援する技術が望まれる．

ばら積み貨物船のホールド内は，ハッチを開けると明るく，また，ドローンの飛行にとって障害となる構造部材がない開放的な空間になっている．一方，タンカーのタンク内は，甲板で覆われるため暗い上にドローンの飛行に有用な GPS が効かない．そして，ウェブフレームなど大きな構造部材（ドローンの飛行にとって障害物）がタンク内に多く配置されている．

本研究では，深層学習(Faster R-CNN)を用いた物体検出技術を，第一段階として，ばら積み貨物船のホールド内の構造部材の認識に適用させ，その認識率を検証する．実験は，明るい環境での認識率の検証を行った後，暗い環境を模擬した状態での認識率の検証を行った．

2. 船舶の点検

大型の船舶でアクセスが困難な高所へは，図 1 に示すように，高所作業車を使用して点検を行うことが多い．図 2 に示すように，高所点検箇所にドローンを飛ばして点検する動きがある．



図 1　ばら積み貨物船の点検風景

連絡先：平方勝，海上・港湾・航空技術研究所，〒181-0004 東京都三鷹市新川 6-38-1，0422-41-3690，0422-41-3085，hirakata@nmri.go.jp

図 2 に示すように，船舶のハッチが開いた状態では明るい環境であるが，タンカーのように甲板で覆われているような船舶のタンク内は，図 3 に示すように，暗い環境である．また，タンク内は多くの構造部材が配置されているため，直接の視界から外れることも予想される．

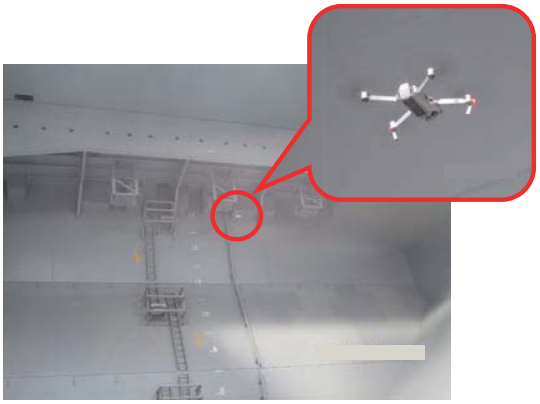


図 2　ドローンの貨物倉内飛行風景



図 3　貨物倉内（ハッチ閉）

3. 画像認識

3.1 Faster R-CNN

深層学習を利用した物体検出に，R-CNN が利用されることが多い[Ross Girshick 2014] ．R-CNN は Selective Search[J.R.

R. Uijlings 2013] で検出した物体候補領域を AlexNet（または VGGNet）に入力して検出する手法である．Selective Search は，色の類似度に着目したセグメンテーション法であり，色の類似度の許容度を超えてグルーピングすることで様々な大きさの候補領域を抽出することができる．Selective Search で検出した物体候補領域を一定サイズにリサイズし，後段の CNN に入力する．物体候補領域の数だけ CNN で認識するため，計算コストが高いといわれる [情報機構 2017] .

畳み込み処理の回数を大幅に削減することで計算コストを改善した Fast R-CNN が報告された．その後，Fast R-CNN をベースとし，Selective Search をやめ，Region Proposal Network で行うことで計算コストを削減した Faster R-CNN が報告された．現在では，Faster R-CNN が物体検出で広く使用される [情報機構 2017]．本研究では，Faster R-CNN による検出を行った．

3.2 データセット

ばら積み貨物船の重点点検箇所周辺の構造部材名を学習・認識させる．ばら積み貨物船の重点点検箇所は，一般的に図 4 に示す 5 箇所といわれている．1 箇所につき，100 画像程度を用意した．画像データを大量に用意するために，画像の中には，同じ対象箇所を別のアングルから撮影したものもある．図 5 で赤枠を記した部材名を学習させた．

学習には，訓練データを 550 画像，検証データを 250 画像用意した．テストデータに 89 画像を用意した．今回用意した画像は，すべて点検者がデジタルカメラで撮影した画像であり，ドローンのカメラによる撮影画像ではない．



図 4 データセット

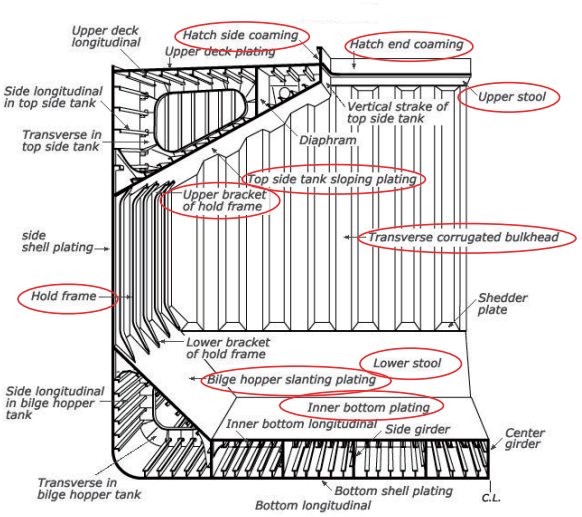


図 5 学習させた部材名

3.3 明るい環境での認識実験

図 6 は，ばら積み貨物船の貨物倉内の画像認識結果及び撮影箇所を示した図面である．表 1 は，認識できた部材名とその認識率である．図 6 で撮影されたすべての部材名が 100%または 100%に近い認識率となっている．訓練データに同様のアングルからの撮影画像が多かったためと考える．

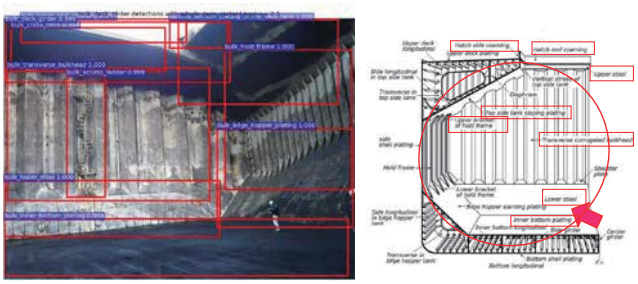


図 6 部材認識(1)

表 1 部材認識(1)の認識率

部材名	認識率
Top side tank sloping plating	100%
Hold frame	100%
Bilge hopper plating	100%
Transverse bulkhead	100%
Lower stool	100%
Access ladder	99.9%
Inner bottom plating	99.9%
Deck girder	99.9%
Hatch side coaming	99.9%
Hatch end coaming	99.4%
Cross deck	99.4%

図 7 も，ばら積み貨物船の貨物倉内の画像認識結果及び撮影箇所を示した図面である．表 2 は，認識できた部材名とその認識率である．表 1 と同様，すべての部材名が 100%または 100%に近い認識率となっている．Inner Bottom Plating は，画像の中で僅かに写っているだけだが，高い認識率で認識できて

いる. Lower Stool の床(エッジ)を認識し, それが, Inner Bottom Plating であると, 構造位置関係も認識できている.

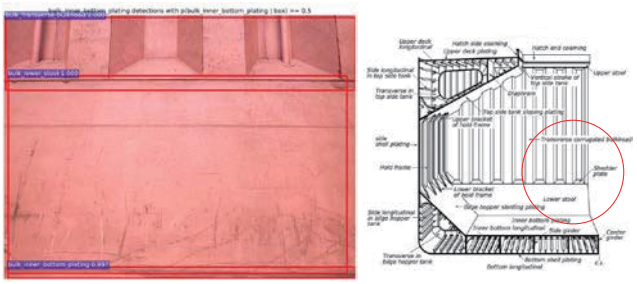


図 7　部材認識(2)

表 2　部材認識(2)の認識率

部材名	認識率
Transverse bulkhead	100%
Lower stool	100%
Inner bottom plating	99.7%

図 6 及び図 7 の認識結果は, 学習で使用した画像ではないが, 同じ船舶の他の画像データを学習させていたことが, 高い認識率につながったものと考え, 別の船舶の同様の箇所について認識させた. 図 8 は, ばら積み貨物船の貨物倉内の認識結果である. 学習で使用した船舶は全て, 船側部に Hold Frame が配置された構造様式であったが, 図 8 の船舶は Hold Frame が配置されていないタイプの船側構造となっている. そのため, Transverse bulkhead が船側を含めて認識された. 船舶の構造様式について多様な学習データを用意して改善していく必要がある. また, Deck girder, Cross deck が画像(図 8)に写っているが, 認識率は 50%を下回っていた. 訓練データを増やして学習を重ねる必要がある. Access Ladder は画像に写っておらず, 認識しなかったことは正しい結果である.



図 8　部材認識(3)

表 3　部材認識(3)の認識率

部材名	認識率
Top side tank sloping plating	98.3%
Transverse bulkhead	95.3% (船側を誤認)
Access ladder	認識せず(正解)
Inner bottom plating	97%
Deck girder	50%未満
Cross deck	50%未満

3.4　暗い環境を模擬した認識実験

ばら積み貨物船のハッチを閉じると, 図 3 に示すようにライトがないと周りを知覚できないほど暗い. ドローンにライトをつけて撮影した画像はない. ライトをつけて飛行したドローンの撮影画像をどの程度認識できるか, ここでは, 図 9 に示すように, オリジナルの画像(明るい環境)から画像処理によって, 暗い環境でライトがあたった模擬的な状態を作り出して, 認識率の検証を行う. Case1, Case2 にしたがって, 明るい範囲を中心位置に集中させ, 全体的に暗い環境を作り出した.



図 9　仮想的な暗い環境創出

図 10 は, 図 6 の画像をオリジナルにして, Case1, Case2 の暗い環境を模擬的に作り出した状態の認識結果である. その状態の認識結果を表 4 に示す. なお, 明るい画像で学習させた状態の重みを使用している. ヒトの知覚のように, Case1, Case2 の順に認識率が低下している. 画面中央の明るい部材の認識率は依然高いものの, 周辺の暗い部材の認識率は低下している. Inner Bottom, Cross Deck の認識率は 50%と低いものの認識できていることは画像判断するヒトにとって有用である. Case2 の認識結果で, Transverse Bulkhead が高い認識率となっていることは, この画像からでは Transverse Bulkhead を見落とす可能性があるため, 判断するヒトに有用な判断材料を提供できると考える. Case2 の静止画像を見ただけでは全体判断が困難である. ヒトは, 静止画像だけでは対象を認知てきなくても, 連続的な動きの中では認知できることもあるため, システムも同様にリアルタイムの連続的な動きから認識できるようにする必要がある.

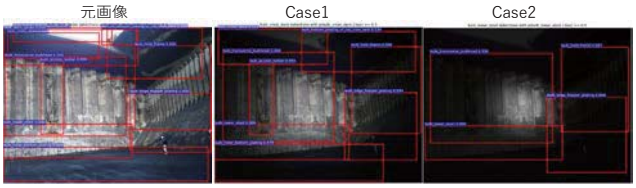


図 10　部材認識の変化(1)

表 4　部材認識の変化(1)での認識率変化

部材名	元画像	Case1	Case2
Top side tank sloping plating	100%	53%	50%未満
Hold frame	100%	99.8%	98.7%
Bilge hopper plating	100%	99.4%	86.8%
Transverse bulkhead	100%	100%	99.8%
Lower stool	100%	98.9%	90%
Access ladder	99.9%	99.3%	50%未満
Inner bottom plating	99.9%	57.9%	50%未満
Deck girder	99.9%	50%未満	50%未満
Hatch side coaming	99.9%	50%未満	50%未満
Hatch end coaming	99.4%	50%未満	50%未満
Cross deck	99.4%	52.4%	50%未満

図 11 は, 図 7 の画像をオリジナルにして, Case1, Case2 の暗い環境を模擬的に作り出した状態の認識結果である. その状態の認識結果を表 5 に示す. Case1,Case2 とも画像に写っていな

い Top side tank sloping plating を誤認している. Case1 では Transverse bulkhead を認識できていることは, この画像からでは Transverse Bulkhead を見落とす可能性があるため, 判断するヒトに有用な判断材料を提供できると考える. Case2 はヒトがみても, この画像のみでは判断が困難である. リアルタイムの連続的な動きから認識できるようにする必要がある. また, 構造部材の位置関係等, 船体構造の知識をベースにヒトは判断することがあるため, このような仕組みを取り入れることによって, 認識率が向上すると思われる.

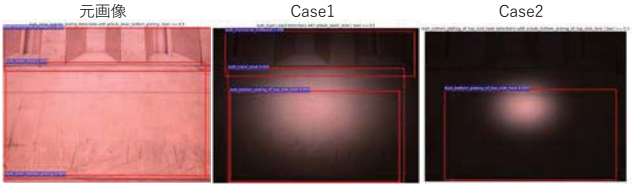


図 11 部材認識の変化(2)

表 5 部材認識の変化(2)での認識率変化

部材名	元画像	Case1	Case2
Top side tank sloping plating	認識せず（正解）	95.3%（誤認）	86.2%（誤認）
Transverse bulkhead	100%	99.6%	50%未満
Lower stool	100%	90.2%	50%未満
Inner bottom plating	99.7%	50%未満	50%未満

4. おわりに

船舶のタンク/ホールド内の点検にドローンを活用する動きがあり, ドローンが撮影した映像から自動評価できる実用的なシステムを構築するための基礎実験を行った. 本研究では, Faster R-CNN を用いて船体構造部材の認識を行った.

データセットは, 明るい環境での画像を用い, 訓練データが 550 画像, 検証データが 250 画像で 15 時間学習した結果を基に, テストデータ 89 画像の検証を行った.

学習した明るい環境での画像では, 認識率は高かった. ただし, 学習した船舶にない構造様式については誤認していたため, 学習データは画像の数に加えて多様な画像を用意する必要がある.

明るい環境で学習した重みを使用して, 暗い環境での認識率を検証した. 暗い環境での画像は, 画像処理によりライトがあたった模擬的な状態を作り出したものである. 明るい環境での画像認識率に比べると, 認識率は低下する. ライトのあたったと想定する明るい(画像中央)の認識率は高いものの, 周辺の暗い部材の認識率は低下し, 認識できなかったケースも見られた. ヒトの視覚認知に似ている. 実際にライトを当てると, ハレーションが起こり, ライトを当てた箇所周辺が真白くなる場合もある. このような問題処理も含めて, ライトを当てた実際の画像を整備し, そのもとで学習を行っていく必要がある.

暗い静止画像だけでは人も判断が困難であることがある. ヒトは, 静止画像だけでは対象を認知できなくても, 連続的な動きの中では認知できることもあるため, システムも同様にリアルタイムの連続的な動きから認識できるようにする必要がある.

今後は, 検査場面で最も重要な損傷を認識できるように学習データを整備して検証を行っていく予定である. 深層学習はブラックボックスであるといわれることが多い. 認識結果の解釈を数多くこなすことで, 認識率の向上につなげる予定である.

参考文献

[Ross Girshick 2014] Ross Girshick, Jeff Donahue, Trevor Darrell, and Jitendra Malik: Rich Feature hierarchies for Accurate Object Detection and Semantic Segmentation, CVPR '14 Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition, pp. 580-587, 2014.

[J.R. R. Uijlings 2013] K. E. A. Van De Sande, T. Gevers and A. W. M. Smeulders: Selective search for object recognition, International Journal of computer vision, vol. 104, no. 2, pp.154-171, 2013.

[情報機構 2017] 機械学習・人工知能業務活用の手引き, 情報機構, 2017

[Shaoqing Ren 2015] Shaoqing Ren, Kaiming He, Ross Girshick, and Jian Sun: Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks, IEEE Trans. Pattern Anal. Mach. Intell. 39(6): 1137-1149, 2017

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

OpenPoseによるバスケットボール投入予測

Prediction of Basketball Free Throw Scoring by OpenPose

中井 眞人 *1 Masato NAKAI
角田 善彦 *1 Yosihiko TSUNODA
孫 財東 *1 Caidong SUN
村越 英樹 *1 Hideki MURAKOSHI
林 久志 *1 Hisashi HAYASHI
網代 剛 *1 Tsuyoshi AZIRO

*1産業技術大学院大学 産業技術研究科
School of Industrial Technology, Advanced Institute of Industrial Technology

We aim for application developments in several fields such as healthcare and robot control. When considering to achieve high quality performance in such applications, it is often necessary to have large amount of accurate and various human posture data. OpenPose of CMU can realize simultaneous posture recognition of multiple people in real time by simple Web camera. We developed two application systems utilizing OpenPose. The first one is a basketball free throw prediction model with human posture data recognized by OpenPose. The second one is a healthcare application which aims to detect brain stroke tendency. In this article, we focus on what we achieved through our first application development. We accomplished to build a high quality motion prediction model with OpenPose data. We consider it opens a way for other research and application developments which are related to human posture and motion.

1. はじめに

我々のチームでは，ヘルスケアやロボット制御分野などを念頭に置き，それら分野での応用開発に取り組んでいる．それらの性能向上を考える場合，精度の高い大量で多様な姿勢データが必要とされる場合が多い．昨年夏に CVPR2017 で発表された米国カーネギーメロン大 (CMU) の OpenPose [Cao 17] [CMU-OP GitHub17] は，簡単な Web カメラを使って図 1 の様にリアルタイムで多人数の姿勢が同時に認識できる．その動画は SNS 等で拡散されかなりの反響を呼んだ．OpenPose の応用研究としてリアルタイムの姿勢データを使ってバスケットボールの投入予測と脳梗塞初期診断判定 (FAST [Takano] [NCVC]) システムを構築した．その結果，投入予測モデルでは先行研究と比較してかなり優位であることが分った．理由としては 2 つあり，従来は全体の姿勢データを時系列で取得するにはモーションキャプチャーの様なセンサーを取り付ける必要がありデータ取得が煩雑であった．今ひとつはデータ取得が煩雑であるためサンプリングが極めて少なく回帰分析等の統計モデルを使った分析ができなかった．一方 OpenPose は Web カメラで動画を撮るだけで容易に多くの姿勢データが取得でき統計モデルを使った分析が可能になった．さらに統計モデルを使った投入予測では有意な精度が得られたので OpenPose が認識するリアルタイムの姿勢データは，統計モデルに耐え得る精度を持つことが判明した．

2. 目的

OpenPose は 2017 年 3 月にステレオ（複眼）カメラによる 3 次元捕捉 [CMU-OP GitHub17] に対応しているが，本研究では導入の容易さや実績を重視して単眼 Web カメラを用いた OpenPose 二次元位置認識環境を構築した（本稿 4.1 参照）．OpenPose の 1 つの特長は，リアルタイムで多人数の姿勢を同時に認識する点である．これを実現するため深層学習を使ったトップダウンの位置認識や PAF（Part Affinity Fields）[Cao 17] による部位の所属認識を採用した独特の工夫をしている．その結果 OpenPose の動画は見た目には精度と汎化性能は驚くべきものがある．しかし一般的に精度と汎化性能はトレードオフの関係があり両立は難しいとされている．そのため OpenPose の性能を確かめるべく OpenPose の姿勢認識データを使った予測モデルを構築して，その予測精度で OpenPose の性能を判断することにした．予測モデルは動画が撮り易く結果が明瞭なバスケットボールフリースローの動作から命中を予測するものとした．手続きとしてはフリースローの動画を OpenPose に通すと我々の環境では，人体姿勢部位検出の引数指定にもよるが 1 秒間に 5 ～ 20 フレーム程度の分解能で姿勢データが出力される．フレームデータを繋いで一旦時系列データとし，そこから特徴量を抽出する．命中予測は特徴量と命中結果とでロジステック回帰で行った．



図 1: OpenPose

3. 先行研究

スポーツ動作の解析は従来はビデオ画像を静止画に分割して姿勢位置を抽出するものが大多数であった [奥山 90] [松原 90]．一方姿勢データを直接取得する方法として体の部位にセンサーやモーションキャプチャーを取り付けて観測した．しかしデータ取得が煩雑なので回帰の様な統計モデルが使えず上

連絡先: 産業技術大学院大学 産業技術研究科 創造技術専攻
b1617mn@aiit.ac.jp b1613yt@aiit.ac.jp

級者と初心者の姿勢の差を論じるのが殆どであった [小郷 92] [安松谷 12]．一方バスケットボール試合ではシュート，ボール奪取等の回数データが試合毎に大量に記録されているので統計モデルを使った勝敗予測モデルが可能だった [斉藤 13]．スポーツ動作の統計モデルとしては隠れマルコフ [Stamp 12] を使った稲邑の姿勢抽象化モデル [稲邑 03] があるが，これは転移学習を目的としている．時系列の予測モデル [北川 93] は一般に定常波と非定常波に分かれ前者は ARIMA モデル，後者はカルマンフィルター [有本 77] が使われる事が多い．しかしこれらのモデルは逐次的に観測された説明変数と目的変数を使う．一方バスケットボールの投入予測は一連の姿勢データから最後に目的変数が得られるので特殊な時系列モデルとなる．この様なモデルとしては LSTM による一連の文章から肯定的か否定的かを予測する感情分析 [Yogatama 17] [Socher 12] や株価の動向から短期的に上昇下降を予測する SCW [Wang 14] がある．しかし何れも大量のデータを必要とする．バスケットの投入予測モデルは特殊な時系列モデルであり，少量のサンプリングであったので，時系列予測ではなく投入前後の姿勢とその差分から特徴量を抽出したロジステック回帰 [Bishop 06] を採用した．

4. OpenPose とは

安価な Web カメラで撮った動画をリアルタイムで多数人数を同時に姿勢認識するモデルで，昨年夏の CVPR2017 でカーネギーメロン大学 (CMU) が開発し学術公開したものである．図 2(左端) の様に 17 の関節点が繋がった 2 次元の姿勢を認識し，その結果をファイルに出力する．図 2(中央，右端) の様に OpenPose は指先と顔も同様に認識する．

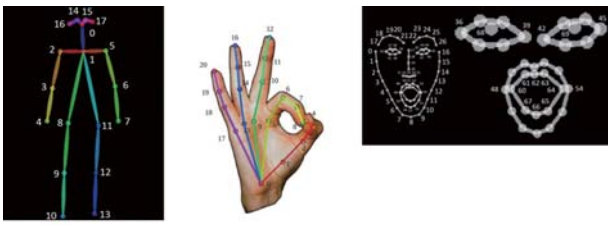


図 2: Analysis Point

4.1 OpenPose の動作方法

本研究では，次のような構成の PC サーバ上で OpenPose を稼働させた．インストールは CMU OpenPose オンラインリポジトリ [CMU-OP GitHub17] の “Installation, Reinstallation and Uninstallation” から，特に以下のハードウェアやソフトウェアに関して推奨の仕様（CPU コア数やメモリ容量）やバージョンを満たしていることを確認して行う．

【ハードウェア】

- CPU: AMD Ryzen 7 1800X (コア数 8)
- メインメモリ 16GB
- GPU: NVidia GeForce GTX 1080 ti (GPU メモリ: 11GB)

【ソフトウェア】

- OS: Ubuntu 14.04 LTS
- CUDA バージョン: 8.0
- cuDNN バージョン: 5.1 for CUDA8.0

4.2 OpenPose 出力データ

本稿 2 章に記した通り，本研究での OpenPose は 2 次元の位置認識なので姿勢，指先，顔の位置データは何れも x 値，y 値，信頼度の 3 値で表現される．OpenPose は隠れた位置の部位まで推測するので 0〜1 の信頼度がある．また多人数の姿勢を同時に認識できるので，1 フレームのファイルには左側の人物から人数分出力される．OpenPose は図 2 左端の人体姿勢 17 点の捕捉を基本とし，加えて図 2 中央および右端のように指先や顔のデータ出力は引数で指定できる．姿勢データは 1 フレーム毎に基本 17 点，指先，顔の同期をとって別ファイルに出力される．出力データ分解能は，計算環境の性能や出力部位の引数指定により変わるが，我々の環境では 1 秒間に 5〜20 フレーム程度であった．

5. バスケット投入予測の手法

5.1 OpenPose の姿勢データ

本研究では OpenPose の姿勢データのみ使用した（図 2 左端 17 関節点データ）．51 人のバスケットボールフリースロー動作の動画を撮り，OpenPose で解析した姿勢認識データをダウンロードした．

5.2 時系列への変換

ダウンロードしたフレームファイル群を読み込み 17 点の関節を時系列に変換した．

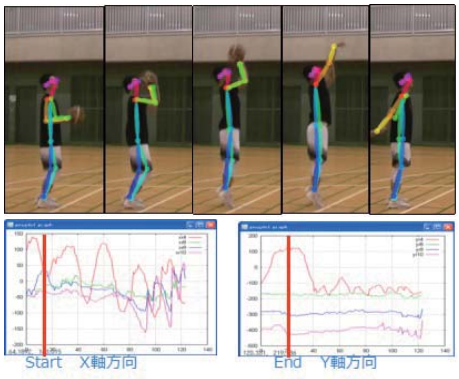


図 3: Time Series

51 人の全員は膝を曲げてから投入していたので，投入開始は膝を最大に屈折した時点とし，投入終了は手が最高点に達する時点とし，約 3 〜 5 秒間の時系列に揃えた．また各関節点は首関節からの相対距離とした．

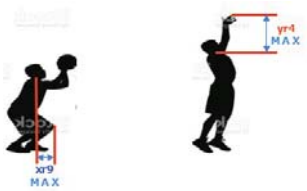


図 4: Start and Last Figure

5.3 ロジステック回帰モデルの採用

ボールが籠に入ったか入らなかったかの 2 値の教師データなので，ロジステック回帰モデルを採用した．2 値判定モデルでは定評のある Xgboost [Chen 16] も検討したが，分析結果の

出力は命中に寄与する特徴量が不明瞭なので採用しなかった．また非線形の 2 値判定モデルの SVM[Platt 99] があるが，これは判定確率を計算しないので採用しなかった．

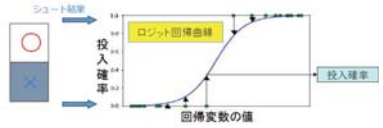


図 5: Logistic Regression

5.4 特徴量の作成

ロジステック回帰モデルに投入する特徴量を 17 点の関節点の投入開始時の値，投入終了時の値，その差分とその速度とした．22 の特徴量を投入したが，有意な特徴量として図 7 に示すものが残った．

6. 実験結果

6.1 精度

51 人を命中予測の高い順に並べて，命中した実績の累計の図を作成すると図 6 のパレート図が得られた．これで示された精度 AR は 41 %で有効な判別モデルが構築できていることが示された．(AR は完全モデルと無反応モデルで囲まれた凸部分の割合)

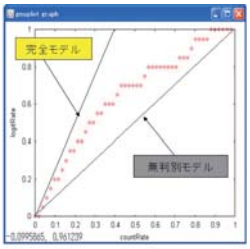


図 6: AR Accurate

6.2 有意な特徴量の検証

投入された特徴量で有意なものが正しくモデルを説明できているか検討した．図 7 は回帰の符号より，命中予測が高くなる特徴量の方向である．これによると開始時は腕を前から後ろへ一旦引いて反動を付けて投擲するオーバスローと投球時には膝の伸張と腕の振り上げによりボールに力を伝達している事が判明した．これにより特徴量の解釈でもこのモデルの有効性を確認した．

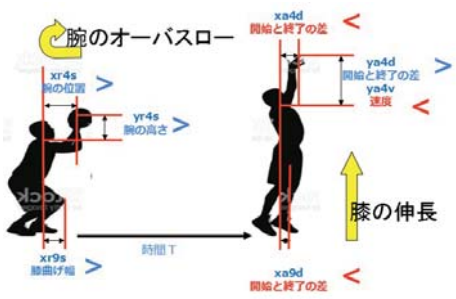


図 7: Feature Direction for Maximum Preciction

6.3 診断と矯正

投入予測モデルはレベル診断システムに使えることが判明した．OpenPose はリアルタイムで姿勢を認識するので図 8 に示す様に被験者の投入姿勢から直ちに投入予測を計算してレベル診断ができる．



図 8: Diagnosis System

また図 9 に示す様に有意な特徴量について初心者と上級者とを比較するとかなりの相違があることが判明した．この様に有意な特徴量を比較することで投入姿勢を矯正できることも分った．

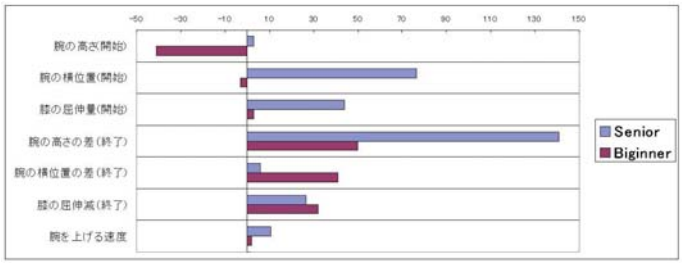


図 9: Diagnosis by Comparison

7. まとめと今後

一連の動作から投げられたボールの命中を予測する難しいモデルで期待された精度が得られたので，OpenPose のリアルタイムの姿勢認識精度は極めて高いと判断した．OpenPose は容易に姿勢データを得られることから，様々な場面で大量で高精度の姿勢データを取得することができる．図 10 の様に運転手や自転車の人も同時に観測でき，自動運転等の危険回避モデルに応用できると考えられる．



図 10: Prediction for Auto Driving

また競技での姿勢データが得られることで，図 11 の様に敵対的に学習するロボット [Fu 17] の初期学習としての逆強化学習 [Wulfmeier 14] に適用が考えられる．

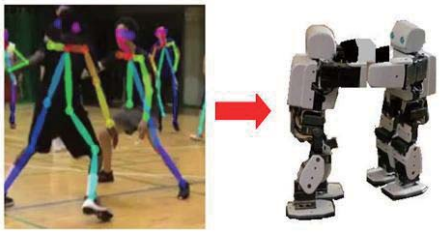


図 11: Inverse Reinforcement Learning

本稿研究で得られた OpenPose 姿勢データ解析の知見を活用し，FAST [Takano] [NCVC] と呼ばれる一般人が行う脳梗塞兆候判定を情報デバイスが検出・実行するシステムの試作も行った．この試作では図 12 の様に OpenPose の指先と顔の認識も使うことで正しく判定できることが分かった．この取り組みにより，OpenPose 技術のヘルスケア分野への応用可能性の一端を開いた．この詳細については別の機会に報告する予定である．

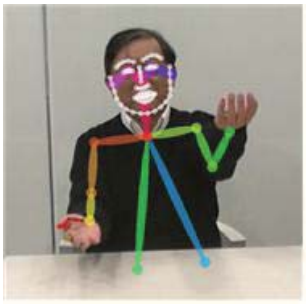


図 12: FAST

謝辞

東京都立産業技術高等専門学校のバスケットボール部にはフリースローの動画撮影に協力頂き感謝申し上げます．

参考文献

[Cao 17] Zhe Cao, Tomas Simon, Shih-En Wei , Yaser Sheikh:Realtime Multi-Person 2D Pose Estimation using Part Affinity Fields, CVPR2017

[CMU-OP GitHub17] CMU-Perceptual-Computing-Lab openpose,https://github.com/CMU-Perceptual-Computing-Lab/openpose

[Takano] Junji Takano:t-PA - a 'Magic Bullet' For Treating Stroke,https://www.pyroenergen.com/articles13/ischemic-stroke-detection.htm

[NCVC] 国立研究開発法人国立循環器病研究センター: [103] 脳梗塞が起こったら - FAST を覚えよう, http://www.ncvc.go.jp/cvdinfo/pamphlet/brain/pamph103.html

[奥山 90] 奥山秀雄:コンピューター動作分析システム（APAS） を用いたバスケットボールのシュート分析 (1990), 日本体育学会第 41 回大会

[松原 90] 松原孝 猪木原孝二 川上雅之 [他]:バスケットボールゲームのシュートについて (1990), 岡山理科大学紀要

[小郷 92] 小郷克敏　錦井利臣　小澤雄二　中川保敬:運続動作時における主運動の視覚情報獲得時期 (1992), 日本体育学会大会号

[安松谷 12] 安松谷 亮宏 曽我真人 瀧寛和:バスケットボールにおけるシュートフォームの学習支援環境の構築 (2012), 情報処理学会シンポジウム論文集

[斉藤 13] 斉藤百合子 倉石平:バスケットボール競技におけるゲーム分析の指標に関する事例研究 (2013), 早稲田大学修士論文

[Stamp 12] Mark Stamp:A Revealing Introduction to Hidden Markov Models(2012)

[稲邑 03] 谷江博昭 稲邑哲也 中村仁彦:統計的情報量を用いた原始シンボル空間の構成とそれに基づく原始シンボル系列の記号化 (2003), 第 21 回ロボット学会学術講演会

[北川 93] 北川源四郎:時系列解析プログラミング—FORTRAN77 (1993), 岩波コンピュータサイエンス

[有本 77] 有本卓:カルマン・フィルター (1977), 産業図書システム・サイエンス・シリーズ

[Socher 12] Richard Socher, Brody Huval, Christopher D. Manning, Andrew Y. Ng:Semantic Compositionality through Recursive Matrix-Vector Spaces, EMNLP2012

[Yogatama 17] Dani Yogatama, Phil Blunsom, Chris Dyer, Edward Grefenstette, Wang Ling:Lerning to Compose Wards into Sentences with Reinforcement Learning, ICLR2017

[Wang 14] Jialei Wang, Peilin Zhao, Steven C.H.:Exact Soft Confidence-Weighted Learning, ICML2014

[Bishop 06] Christopher M. Bishop:Pattern Recognition and Machine Learning, Springer(2006)

[Chen 16] Tianqi Chen, Carlos Guestrin, Christopher:XGBoost: A Scalable Tree Boosting System, Arixv2016

[Platt 99] John C. Platt:Fast Training of Support Vector Machines using Sequential Minimal Optimization(1999)

[Fu 17] Justin Fu, Katie Luo, Sergey Levine:Lerning Robust Rewards with Adversarial Inverse Reinforcement Learning, Arxiv2017

[Wulfmeier 14] Markus Wulfmeier, Peter Ondru´ ska , Ingmar Posner :Maximum Entropy Deep Inverse Reinforcement Learning, NIPS2014

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

場の雰囲気を考慮したBGM推薦システム構築の試み

BGM Recommendation System Considering the Atmosphere

佐藤 季久恵 *1 Kikue Sato　坂井 栞 *1 Shiori Sakai　高屋 英知 *2 Eichi Takaya　山内 和樹 *3 Kazuki Yamauchi　大矢 隼士 *3 Hayato Oya　栗原 聡 *2 Satoshi Kurihara

*1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

*2慶應義塾大学 大学院理工学研究科
Graduate School of Science and Technology, Keio University

*3株式会社レコチョク
RecoChoku Co.,Ltd.

Japanese sometimes leave the decision of things to the atmosphere, it is very important to design the atmosphere of the place in various situations. BGM has an emotion inducing effect and an image inducing effect, which makes it possible to change the atmosphere of the space. In this paper, we proposed a BGM recommendation system reflecting the atmosphere in the shop by combining images and environmental sounds and constructing a data set using shop labels. As a result of recommendation by our system, higher ratings than baseline were obtained for three index.

1. はじめに

場の雰囲気は，人と人との間に流れる「空気」や視覚情報，聴覚情報などが複雑に絡み合うことにより形成される．これを人為的にデザインすることを考えたとき，特に視覚情報と聴覚情報をコントロールすることが重要である．家具や調度品，壁紙など，BGM には感情誘導効果やイメージ誘導効果があるとされており [1]，場の雰囲気を小さい労力で変容させることができる．現にレストランなどでは，それらの効果を利用するべく，楽曲配信サービスを導入しているところが多い．しかし，時間帯による店内の見え方や客層の変化により，店舗側はその都度雰囲気に合った BGM を提供することが求められる．時々刻々と変化する店内の状況に合わせて BGM 配信サービスが対応したり，人手による選曲を行うことは困難であることから，本研究では，店舗の雰囲気に適した BGM を推薦するシステムの構築を行う．本稿では，あらかじめ撮影された店舗内動画と，異なる環境音を組み合わせて印象評価を行い，類似度に基づいた楽曲推薦を試みる．

2. 関連研究

画像や楽曲といったコンテンツに対しユーザがタグ付けを行うことは，ソーシャルタギングと呼ばれ，これを利用した推薦や検索システムに関する研究は数多く存在する．梶ら [2] は，歌詞とアノテーションを利用し，視聴時のユーザの状況に合わせたプレイリストを作成するために楽曲とユーザを特徴量空間へマップする手法を採用している．特徴量には歌詞，楽曲情景，視聴状況を用いており，それらの特徴量空間にユーザをマップすることで，楽曲間，ユーザと楽曲間，ユーザ間の類似度計算を可能にしている．楽曲情景のラベルは登場人物（一人，私），いつ（朝，過去，春），状況（恋愛中，反社会），心理状況（悲しい，怒り）の 4 項目を用いている．歌詞と楽曲情景については，それまで視聴した好きな曲の特徴量平均をそれぞれの特徴量空間にそのユーザの嗜好としてマップすること

連絡先: 佐藤季久恵，電気通信大学大学院情報理工学研究科情報学専攻，東京都調布市調布ヶ丘 1-5-1，ksato@ni.is.uec.ac.jp

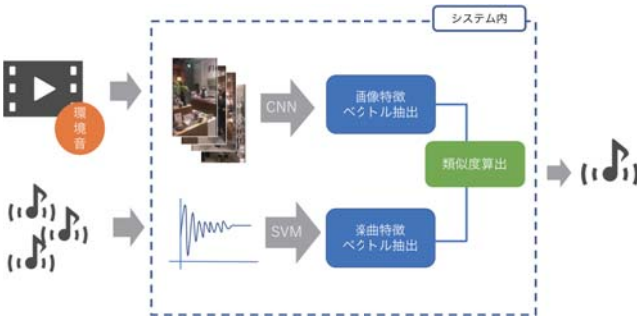


図 1: システムの概要図

で．推薦を行っている．Kaminskas ら [3] の研究ではユーザが関心のある場所（place of interest, POI）に即した楽曲推薦のシステムを構築している．楽曲と POI に双方同様の感情語を用いたタグをつけ，それらをベクトルとして扱い，類似度から適した楽曲を推薦している．タグには 9 項目の感情タグと 13 項目の物理的タグ（色や気温など）を用いている．

3. 本研究のアプローチ

本研究では，店舗での利用を想定し，場の雰囲気に合った BGM の推薦システムを提案する．

3.1 システムの概要

本研究における場の雰囲気を反映した BGM 推薦の流れを図 1 に示す．

まず，店舗内動画像を提案システムに入力し，Convolutional Neural Network（CNN）によってラベルを予測する．そして，推薦の候補となる楽曲群から特徴量としてメル周波数ケプストラム係数（MFCC）を求め，それを入力とした Support Vector Machine（SVM）を用いてラベルを予測する．それぞれの楽曲と店舗内動画において予測されたラベルの類似度を算出し，類似度が高いものを店舗に適した楽曲として推薦する．

3.2 環境音の利用

先行研究の多くは，場所の画像に対してラベル付けがなされている．画像データの取得やラベル付けは容易である一方，推薦システムにおいては視覚情報しか考慮されない点で不十分である．そこで本研究では，動画を印象評価に用い，その中でも環境音に着目する．

環境音は，我々が普段生活する中で無意識に耳にし，そこがどのような場所であるのかを判断するための材料にもなりうる．また，環境音が存在することにより，場所の見え方も変化する傾向があるとされている [4]．本研究では BGM を独立した音として扱うのではなく，環境音を含めて場をデザインすることを考慮し，環境音を含めた印象評価を行う．

3.3 店舗ラベルの導入

感情語や印象語を用いて画像や楽曲にラベル付けを行い，それに基づいた楽曲推薦を行うことは，先行研究でも試みられている．ラベルを用いることで，画像や楽曲がユーザーへ与える心理的影響を考慮することができ，個人の嗜好や状況に即した楽曲などを推薦することが可能である．しかし，個人の経験や感情に依存する感情語や印象語ラベルを使用することは不特定多数への適応を目的とした BGM 推薦には不向きである．

そこで本研究では，画像を見て想起される「情景」として，スターバックスや東急ハンズといった具体的な店舗名を用いてラベル付けを行う．チェーン店は全体を通してコンセプトを持っており，店舗内装などを統一しているところが多い．そのため，店を利用した人の間では同一のイメージを共有することが可能である．また，これまでは複数の感情語や印象語を用いることで店舗内を表現していたが，具体的な店名を用いることで一つのラベルで表現することが可能になる．

4. データセット

4.1 ラベルの選定

先述した店舗ラベルの候補を選定するにあたり，聞き取り調査を行った．

回答者は学生 4 人，社会人 2 名で，店舗イメージが確立している店舗名を列記してもらった．集計後，店の種類に偏りが出ないよう，USEN のコンシェルジュサービス [5] を参考に記載されている項目で補った．ラベル内容は表 1 に示す．これらのラベルを，後述する店舗内動画データセットの作成と楽曲評価に用いた．

4.2 店舗内動画データセットの作成

店舗内の雰囲気を評価するための店舗内動画を収集した．撮影は目線の高さで店舗内を 180 度撮影とし．時間は 10 秒から 15 秒ほどで行った．画像サイズは 1920 × 1080，フレーム数は 30fps とした．撮影イメージを図 2 に示す．ライトやアプリなどで明度や彩度の調整はしないものとした．

収集された店舗内動画から環境音を切り離し，異なる環境音を付け加えることで仮想店舗内動画を作成した．環境音はカフェ店内，子供が多いイベント会場内，ショッピングモール内，オフィス内，街中の 5 種類を使用した．

4.2.1 店舗内動画評価

作成した 740 本の仮想店舗内動画に対し，3 名の作業者に印象評価を行ってもらった．具体的には，作成した仮想店舗内動画を視聴してもらい，動画がどのような状況に当てはまるか，表 1 のラベルから選択してもらった．

表 1: ラベル一覧

情景	
スターバックス	ダイソー
ルノアール	東急ハンズ
コメダ珈琲	無印良品
バー	ニトリ
居酒屋	大塚家具
割烹・料亭	紀伊國屋書店
ラーメン屋	TSUTAYA
沖縄料理店	高島屋
イタリア料理店	PARCO
西友	イオンモール
成城石井	シェラトンホテル
カルディ	オフィス
アパレル（高級店）	企業ロビー（大企業）
アパレル（フォーマル）	企業ロビー（中小企業）
アパレル（カジュアル）	国際空港
ドラッグストア	地方空港
francfranc	
日差し	
あり	なし
時間帯	
朝（-10 時台）	昼（11 時台-14 時台）
夕方（15 時台-17 時台）	夜（18 時台-）
都市度合い	
都会	郊外
田舎	

4.3 楽曲評価

仮想店舗内動画と同様に，多数の楽曲に対して，それらがどのような状況下で BGM として流れているかを基準に，3 名の作業者に評価を行ってもらった．楽曲は「 J-POP」,「アニメ」,「キッズ・ファミリー」,「歌謡曲・演歌」,「邦楽ヒップホップ・R & B・レゲエ」,「邦楽ロック」,「洋楽ヒップホップ・R & B・レゲエ」,「洋楽ポップス」,「洋楽ロック」,「洋楽総合」の計 10 個のジャンルから 100 曲ずつを用意し，ラベルは表 1 から選択してもらった．

5. 予測器の構築と推薦方法

前節で作成したデータセットを用い，店舗内動画および楽曲に対する予測ラベルを出力するための予測器をそれぞれ構築した．

店舗内動画から予測ラベルを出力する予測器には，CNN を用いた．ネットワーク構造は AlexNet[6] と同様とし，ラベル付けのなされた仮想店舗内動画 740 本を学習データに用いた．なお，各動画は 1 本あたり 10 枚の連続画像とみなしているため，データセットは計 7400 枚のラベル付き画像となる．また，全 5 種類の環境音と画像との紐付けは，環境音タグにあたる値を CNN アーキテクチャにおける全結合層のユニットに追加することによって行っている（図 3）．

楽曲から予測ラベルを出力する予測器には，SVM を用いた．その際の入力には，各楽曲から算出した MFCC を用いている．

識別器から得られる結果は，各ラベルにおける値である．動画と楽曲のラベルの類似度を計算し，値が大きい 3 曲を推薦する．本研究ではユークリッド距離，コサイン類似度，ピアソ



図 2: 店舗内動画イメージ図

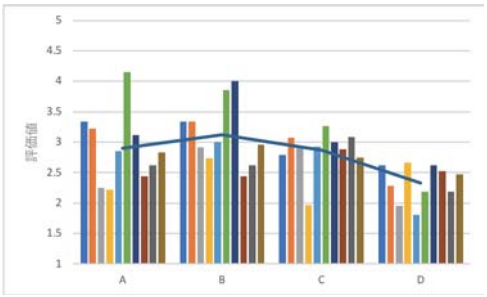


図 4: 楽曲推薦結果

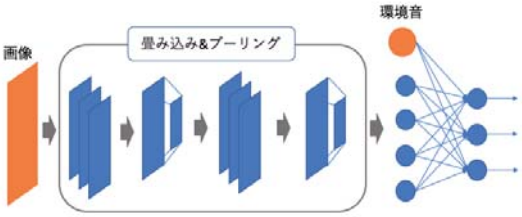


図 3: 店舗識別用 CNN のアーキテクチャ

ン相関係数を用いて求める．

6. 評価実験

提案システムの評価は，曲付きの動画を視聴した評価者に対するアンケートによって行った．評価者は本学学生から募集し，1 本の動画に対し 8 名または 9 名が 5 段階で評価を行った．

提案システムを用いて計 10 本の動画に対する楽曲をそれぞれ 3 曲推薦し，評価した結果を図 4 に示す．A，B，C はそれぞれコサイン類似度，ピアソン相関係数，ユークリッド距離にもとづいて推薦を行った結果であり，D はランダムに推薦を行った結果である．

類似度指標ごとの平均値は 2.99，3.12，2.89 の値で，標準偏差は 0.59，0.46，0.32 であった．また，図 4 からも分かるように A と B においては一部突出して評価が高いものが存在しており，D と比べると平均的にはいずれのグループも評価値が高いことが分かる．

しかし，評価者から感想を聞いたところ，「場所が歌詞と合っていない」「歌詞が気になってしまう」などの意見が得られた．

7. 考察

どの類似度計算においても，定量的にはランダム推薦に勝るものの，定性的には最適な BGM 推薦ができたと結論付けることはできなかった．原因の一つとしてデータの少なさとラベルの多さが学習に影響を与えたと考えられる．また十分なラベル付けがされていないという問題もあった．本研究ではデータセット作成時に動画や楽曲に対してラベル付けをしてもらったが，複数のラベルがつけられたものと，そうでないものの差が激しかった．楽曲に対するタグ付けは 1 曲に対し最低 2 人で行っていたことでラベル付与の偏りが生まれ，推薦に影響が出たのではないかと考えている．

加えて評価実験において同じ楽曲であるにもかかわらず，グループが異なるだけで点数が異なるものが多く存在した．前の曲との関係性が原因と考えられるが，確証を得るためにも人為的に様々な曲と組み合わせ，評価を行う必要がある．

8. おわりに

本稿では，画像と環境音を組み合わせ，店舗ラベルを用いたデータセットを構築することにより，店舗内での雰囲気を反映した BGM 推薦システムを提案した．3 種類の類似度指標を用いて動画に対し楽曲を推薦した結果，いずれの類似度指標においても，ランダムで推薦された曲よりも平均的に高い評価が得られた．一方で，定性的にはあまり高い評価は得られなかった．

今後の課題としては，データセットの拡充や，楽曲間の相性を考慮したシステムの改良などが挙げられる．

参考文献

[1] Daniel Västfjäll. Emotion induction through music: A review of the musical mood induction procedure. *Musicae Scientiae*, Vol. 5, No. 1_suppl, pp. 173–211, 2001.

[2] 梶克彦, 平田圭二, 長尾確. 状況と嗜好に関するアノテーションに基づくオンライン楽曲推薦システム. 情報処理学会研究報告音楽情報科学（MUS）, Vol. 2004, 127（2004-MUS-058）, pp. 33–38, 2004.

[3] Marius Kaminskas and Francesco Ricci. Location-adapted music recommendation using tags. In *International Conference on User Modeling, Adaptation, and Personalization*, pp. 183–194. Springer, 2011.

[4] R Murray Schafer. *The soundscape: Our sonic environment and the tuning of the world*. Simon and Schuster, 1993.

[5] music.usen.com コンシェルジュ, http://music.usen.com（閲覧日：2017 年 12 月 5 日）.

[6] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E Hinton. Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems*, pp. 1097–1105, 2012.

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

運動データからの楽曲作成

Music Generation from Motion Data

鈴木 隼太*1 渡邉 彰吾*2 六沢 一昭*1
Junta Suzuki Syogo Watanabe Kazuaki Rokusawa

*1千葉工業大学 情報科学部 情報工学科
Department of Computer Science, Chiba Institute of Technology

*2千葉工業大学大学院 情報科学研究科 情報科学専攻
Graduate School of Information and Computer Science, Chiba Institute of Technology

This paper describes an experimental sonification system which generates music from motion data measured by an acceleration sensor. The system generates rhythms, chords, tunes and harmony reflecting the observed movement, aiming for comfortable music.

1. はじめに

本稿は, 加速度センサーにより測定した運動データから楽曲を作成する可聴化実験システムについて述べる. 運動状況を反映し, 聴いて楽しめる楽曲を作成することが本システムの目標である.

運動情報の可聴化の研究には運動学習支援を目的としたものが多い. 動作情報を聴覚情報へ変換して伝達することにより, スポーツなどの動作学習やリハビリなどの動作支援に役立てることが考えられている. [高野 2016], [松原 2012], [宝里 2011] はその例であると言えよう. 本研究は, それらとは異なり, 楽しめる楽曲の作成が第一の目的である.

2. 自然な楽曲

自然な楽曲を作成するために着目したコードと規則を以下に示す.

表 1: ダイアトニックコード (ハ長調)

コード	C	Dm	Em	F	G	Am	$Bm^{\flat 5}$
機能	T	S	T	S	D	T	D

2.1 ダイアトニックコード (Diatonic Chord)

ダイアトニックコードのみを用いる. ハ長調のダイアトニックコードを表 1 に示す. 表中の T, D, S はコードの機能を示すもので, 以下の特徴がある.

T (Tonic; トニック) 安定感のあるコードである. 楽曲のはじめと終わりによく使われる.

D (Dominant; ドミナント) 不安定な響きを持つコードである. トニックへ動いて落ち着こうとする.

S (Subdominant; サブドミナント) やや不安定な響きを持つコードである.

連絡先: 六沢 一昭, 千葉工業大学 情報科学部 情報工学科, 275-0016 千葉県習志野市津田沼 2-17-1, rokusawa.kazuaki@it-chiba.ac.jp

2.2 コード進行

安定したコード進行には以下の 3 つのパターンがある.

- T → S → T
- T → S → D → T
- T → D → T

T, S からは T, S, D のどれへも進行するが, D からは T へのみ進行する.

$$
\begin{aligned}
C &\rightarrow Dm, Em, F, G, Am, Bm^{\flat 5} \\
Dm &\rightarrow G \\
Em &\rightarrow C, F, Am \\
F &\rightarrow C, Dm, G \\
G &\rightarrow C, Am \\
Am &\rightarrow Dm, F, G \\
Bm^{\flat 5} &\rightarrow C, Am
\end{aligned}
$$

図 1: コード進行 (ハ長調)

ハ長調における自然で安定したコード進行を図 1 に示す. このコード進行に基づいて楽曲のコード進行を決定する.

3. 運動データから楽曲へ

3.1 楽曲作成の流れ

運動データ

運動データは, 加速度センサーにより測定したデータである. 上下/左右/前後の 3 方向それぞれの加速度測定値からなる.

区間と小節

運動データを適当な数ごとに区切る. 例えば 50 個ごとに区切る. 区切りによって生まれた (運動データの) ひとつの区間を (楽曲の) ひとつの小節に対応させて楽曲を作成する.

楽曲作成

まず, 運動データを解析し各区間 (小節) のコードを決定する. そして, コードをもとに, 運動データも考慮して, メロディを生成する. 同様に運動データからリズムとハーモニーも生成する. 各小節のメロディを構成する音は, コードの構成音のみからとする. この「まずコードを決め, コードの構成音からメロディを決定する」方式は [杉原 2011][渡邉 2017] で用いたものである.

表 2: レベル値の例

測定値の絶対値	レベル値
0.0000 以上 0.1428 未満	0
0.1428 以上 0.2856 未満	1
0.2856 以上 0.4284 未満	2
0.4284 以上 0.5712 未満	3
0.5712 以上 0.7140 未満	4
0.7140 以上 0.8568 未満	5
0.8568 以上	6

3.2 レベル値と運動

各区間に対し, その区間内の測定値の絶対値の最大値のレベルを求め, それをその区間のレベルとする. 測定値の絶対値とレベルの対応例を表 2 *1 に示す. 測定値の絶対値が大きくなるほどレベルの値も大きくなる.

レベル値は運動の変化の大きさを表わす. 大きいレベル値は, 加速度の大きいことを示し, 運動が激しいことを意味する. 一方, 小さいレベル値は穏やかな運動を示し, レベル値ゼロは, 運動に変化が (ほぼ) ないことを意味する.

3.3 リズム/コード/メロディ/ハーモニーの決定

3.3.1 基本的な考え

運動が激しいほど楽曲のリズムも激しくするのが適当であろう. 上下/左右/前後方向のうち, 運動の激しさを直接反映するのは上下方向の測定値であると考え, 上下方向の測定値からリズムを決定することにした.

リズム以外の楽曲の要素であるコード及びメロディ, ハーモニーは, 主に上下方向以外 (左右及び前後方向) の測定値から決定する. これらは, リズムと異なり, 前の小節とのつながりが重要である. 例えばある小節のコードを決める時は, 前の小節のコードも考慮する必要がある. 対応する区間の測定値のみからコードを決定したのでは, 2.2 で述べた自然で安定したコード進行を実現することができない.

前述したように, レベル値は運動の変化の大きさを表わす. このことから, 基本的に, レベル値が大きいほど楽曲の変化を大きくし, 小さいほど変化は小さくする. そしてレベル値ゼロの場合は楽曲は変化させない.

3.3.2 リズムの決定

各区間の上下方向のレベル値から, 対応する小節のリズムを表 3 に基づき決定する. レベル値が大きいほど (運動が激しいほど), 激しいリズムが (音の数の多い小節が) 生成される.

3.3.3 コードの決定

ある小節のコードと, その小節に対応する区間の左右方向のレベル値から, 次の小節のコードを表 4 に基づき決定する.

例えば, ある小節のコードが F で, その小節に対応する区間の左右方向のレベル値が 4 の場合, 次の小節のコードは Dm となる. C と 3 ならば次のコードは F となる.

表 4 は図 1 のコード進行を実現しており, 自然で安定したコード進行が実現される.

3.3.4 メロディの決定

ある小節のコードとリズム (音符の数) と, 対応する区間の前後方向の測定値から, その小節のメロディ (を構成する音) を決定する.

*1 3.3.3 のコードの決定における, 左右方向の測定値とレベル値の対応を示す.

表 3: 上下方向のレベル値と対応するリズム

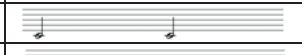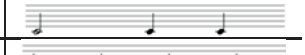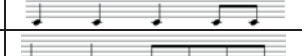
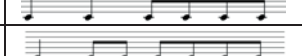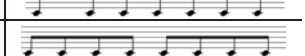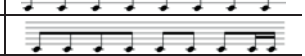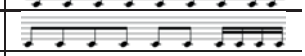
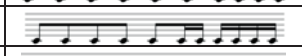
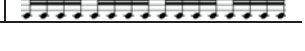
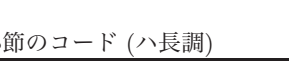
レベル値	音符数	リズム
0	1	
1	2	
2	3	
3	4	
4	5	
5	6	
6	7	
7	8	
8	9	
9	10	
10	11	
11	12	
12	13	
13	14	
14	15	
15	16	

表 4: 次の小節のコード (ハ長調)

レベル値	C	Dm	Em	F	G	Am	$Bm^{\flat 5}$
0	C	Dm	Em	F	G	Am	$Bm^{\flat 5}$
1	Dm	G	C	C	C	Dm	C
2	Em	G	C	C	C	Dm	C
3	F	G	Am	Dm	C	F	C
4	G	G	Am	Dm	Am	F	Am
5	Am	G	F	G	Am	G	Am
6	$Bm^{\flat 5}$	G	F	G	Am	G	Am

まず, リズムが示す音符数で前後方向の測定値を等分する. 等分によって生まれた各部分は, リズムによって決まった各音に対応する. 例えば, ある小節のリズムが表 3 のレベル値 6 のものならば, 音符数は 7 なので, 対応する区間の測定値を 7 等分する. 等分によって生まれた 7 つの各部分は 7 つの各音に対応する.

次に, 各部分の測定値の絶対値の最大値のレベル値を求め, そのレベル値と対応する小節のコードから表 5 と図 2 に基づき, メロディの構成音を決定する. 例えば, コードが Am である小節に対応する区間の, ある部分のレベル値が 5 の場合, その部分に対応する音は E5 となり, コードが G でレベル値が 1 ならば音は B3 となる.

3.3.5 ハーモニー (伴奏パターン) の決定

各区間の前後方向のレベル値から, 対応する小節の伴奏パターンを表 6 に基づき決定する. レベル値が大きいほど複雑な伴奏パターンが生成される.

4. 楽曲作成例

図 3 は, JR 京葉線新習志野駅から千葉工業大学新習志野キャンパスまで歩いた時に測定された運動データである. 図の横軸は歩行開始後の経過時間 (単位: 秒) を示す. 測定は毎秒 10 回

表 5: メロディ構成音

レベル値	C	Dm	Em	F	G	Am	$Bm^{\flat 5}$
0	C4	D4	E4	F3	G3	A3	B3
1	E4	F4	G4	A3	B3	C4	D4
2	G4	A4	B4	C4	D4	E4	F4
3	C5	D5	E5	F4	G4	A4	B4
4	E5	F5	G5	A4	B4	C5	D5
5	G5	A5	B5	C5	D5	E5	F5
6	C6	D6	E6	F5	G5	A5	B5
7	E6	F6	G6	A5	B5	C6	D6
8	G6	A6	B6	C6	D6	E6	F6
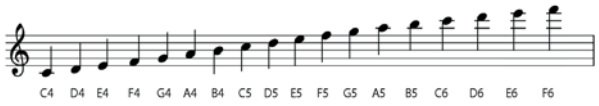


図 2: 構成音

であり, 運動データ 10 個で 1 秒経過となる. 運動時間 (測定時間) はおよそ 480 秒であり, 一方向あたりの運動データはおよそ 4800 個である. このデータからハ長調の楽曲を作成した.

運動データを 200 個ごとに区切って区間を生成した. 24 個の区間が生まれ, 24 個の小節からなる楽曲が作成された. 運動データ 200 個は 20 秒に対応するので, 運動 20 秒ごとに ひとつの小節が作られたわけである.

各小節の左右方向のレベル値とコード, 及び, 上下方向のレベル値と音符数を表 7 に示す. また, 7 小節目の前後方向の測定値とレベル値, 構成音を表 8 に示す. そして, 作成された楽曲を図 4 に示す.

最初の小節のコードは, ハ長調の楽曲のため, C である. 2 番目の小節は, 最初の小節のコード C と左右方向のレベル値 0 から C, 3 番目は, C と 2 から Em である (表 7)

表 7 より 7 小節目のコードは G で音符数は 10 である. 区間を 10 等分して生まれた各部分の, 前後方向の測定値の絶対値の最大値と, その値から定まるレベル値, そして, コードとレベル値及び表 5 から決まる構成音が表 8 に示されている.

図 3 の運動の内容であるが, 歩行だけでなく, 走行や停止といった動きも含んでいる.

走行部分は, 歩行開始後およそ 60 秒からの 30 ～ 40 秒間である. 運動データの対応する部分は 3 方向とも測定値 (の絶対値) が大きい. 作成された楽曲では, 走行部分は 4, 5 番目の小節が対応する. 二つの小節とも音符数が多く (11 個と 15 個), メロディの構成音が高い. リズムとメロディに走行が表われていると言えよう.

停止は 2 回ある. 初回の停止は, 停止時間が短く, 運動データにも楽曲にも明確には表われていない. 2 回目の停止は, 歩行開始後およそ 240 秒後からのおよそ 40 秒間である. 運動データの対応する部分は 3 方向とも測定値はゼロに近い. 作成された楽曲の対応する二つの小節 (13, 14 番目の小節) は, 二分音符二つの小節と, 全音符の小節である. 停止が明確に表われていると言えよう.

5. まとめ

加速度センサーにより測定した運動データから楽曲を作成する実験システムについて述べた. 目標の, 運動状況を反映し

表 6: 前後方向のレベル値と対応する伴奏パターン

レベル値	伴奏パターン
0	
1	
2	
3	
4	
5	
6	
7	
8	
9	

聴いて楽しめる楽曲を作成することはほぼ実現できたと思われる.

参考文献

[高野 2016] 高野 衛, 安藤 大地, 笠原 信一: 動作情報を用いた可聴化における変換手法の考察 – パフォーマンス実演による検証 –, 先端芸術音楽創作学会 会報, Vol.8, No.3, pp.1–4 (2016).

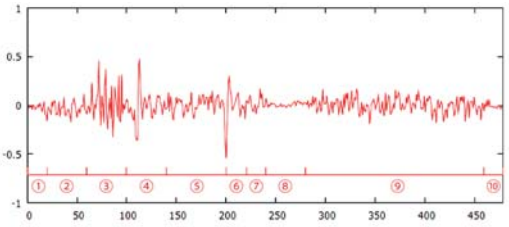
[松原 2012] 松原 正樹 他: 身体動作の連動性理解にむけた筋活動可聴化, 日本音響学会講演論文集, 2-10-2, pp.919–922 (2012).

[宝里 2011] 宝里 直幸, 有田 浩之, 阪口 豊: 身体運動の可聴化: その概念と運動学習支援への応用, 情報処理学会 インタラクション 2011, 3CR3-1 (2011).

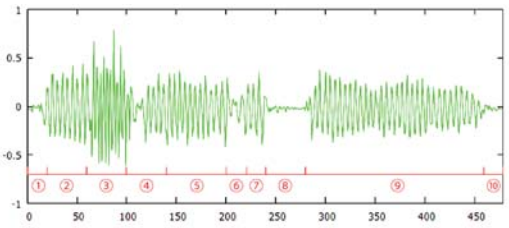
[杉原 2011] 杉原 大和, 六沢 一昭: プログラムからの楽曲生成の試み, 第 5 回エンターテイメントと認知科学シンポジウム (2011).

[渡邉 2017] 渡邉 彰吾, 六沢 一昭: プログラムからの楽曲作成, 情報処理学会 研究報告音楽情報科学, Vol.2017-MUS-115, No.25 (2017).

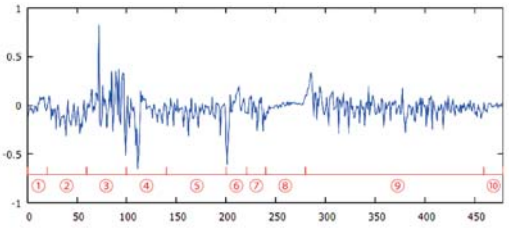
[島岡 1964] 島岡 譲 他: 和声 理論と実習, 音楽之友社 (1964).



(a) 上下方向



(b) 左右方向



(c) 前後方向

横軸の単位: 秒, 測定値 10 個/秒
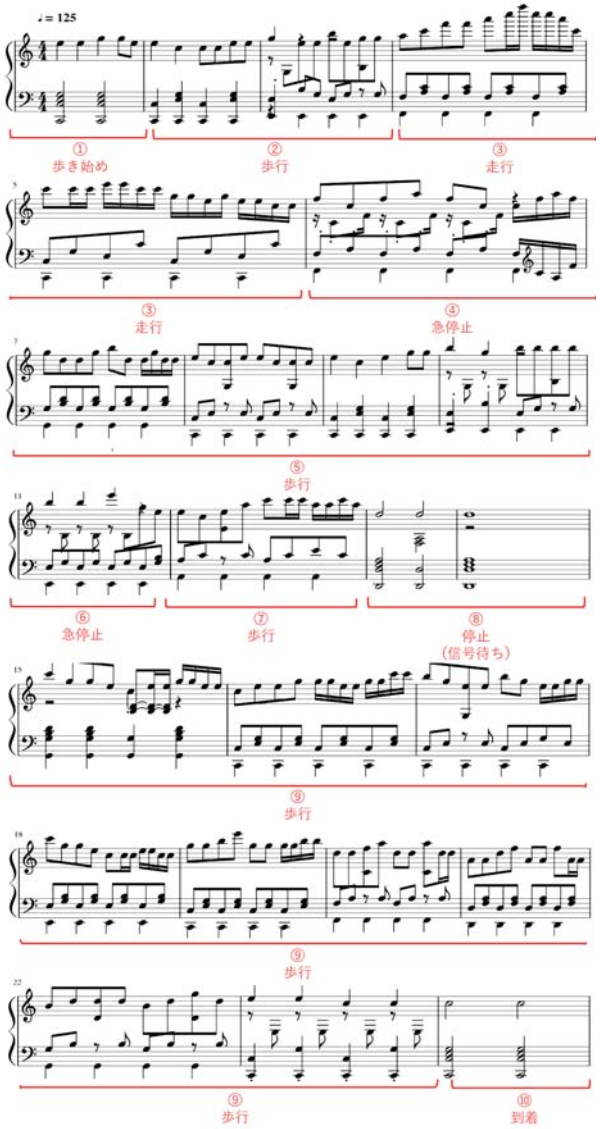
図 3: 運動データ

表 7: 各小節のレベル値とコード, 音符数

小節	左右	コード	上下	音符数
1	0	C	4	5
2	2	C	5	6
3	5	Em	6	7
4	2	F	10	11
5	3	C	14	15
6	5	F	9	10
7	2	G	9	10
8	0	C	7	8
9	2	C	4	5
10	0	Em	5	6
11	3	Em	4	5
12	2	Am	10	11
13	0	Dm	1	2
14	1	Dm	0	1
15	1	G	10	11
16	0	C	11	12
17	2	C	9	10
18	2	Em	10	11
19	3	C	9	10
20	3	F	8	9
21	2	Dm	8	9
22	1	G	7	8
23	0	C	3	4
24	0	C	1	2

表 8: 7 小節目の前後方向の測定値とレベル値, 構成音

区間	測定値	レベル値	構成音
1	0.391	3	G4
2	0.224	2	D4
3	0.235	2	D4
4	0.333	3	G4
5	0.505	4	B4
6	0.301	2	D4
7	0.254	2	D4
8	0.367	3	G4
9	0.224	2	D4
10	0.284	2	D4



運動データ 200 個/区間, 運動 20 秒/小節

図 4: 作成された楽曲

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

グラフカーネルフィルタをもちいた楽曲の画一な印象の獲得

Acquisition of uniform impression of music using graph kernel filter

錠 尚史 *1
Hisashi IKARI

*1株式会社ソケッツ
Sockets Co., Ltd.

The impression of a song varies from person to person. The sensitivity that depends on this individual is greatly different among individuals and it is difficult to quantify. In addition, because sensitivity changes with time, fixed point observation is also necessary, and it takes much time. In this case, focusing on the Graph laplacian which has the property of Fourier transform among the Deep learning attracting attention in recent years, we will clarify the time shortening by computer experiment and the frequency feature which affects the sensitivity of music.

1. はじめに

楽曲の印象は人により様々である．この個人に依存する感性は個人差があり，楽曲の印象の研究は心理学実験 [Hevner, 1936] を始めとする統計数理による検定に基づく研究が主立つ．この際，統計をもちいるために必要なサンプルの数は多い程，楽曲の印象の真の分布に近づく [Clopper and Pearson, 1934]．しかしながら，大規模の心理学実験には時間と人員を要し，また，感性は時間経過に伴い変化するために，時間変化を考慮した定点観測も必要であり，多くの時間を要する．

近年，深層学習の一般物体の認識の精度が注目を浴びている [Krizhevsky, Sutskever and Hinton, 2012]．深層学習は脳の計算モデルに基づいており，その深層学習の畳み込みは視覚の受容野の特性を示している [David Marr, 1982]．この畳み込みは SS 理論 [S. Suzuki, 1994] に端を発し，感性は受容野の反応と個人の経験に基づいた意味付けにより意識される感覚と前提される．

本件においても同様に深層学習の畳み込みを受容野とし，個人の経験に基づいた意味付けをニューラルネットワーク [Cochocki and Unbehauen, 1993] として分離，個人の経験に基づいた意味づけに至る前の楽曲の印象を画一な楽曲の印象と前提する．この構成に感性を表すラベルを付与し，深層学習の学習過程より受容野の特徴を求め，画一な楽曲の印象とし，かつ深層学習をもちいた計算機実験により実験の時間の短縮を行う．

2. 楽曲の感性の特徴モデル

2.1 楽曲の特徴量

楽曲は波形で表される．また，楽曲の印象は音色に起因すると前提する [Hevner, 1937]．ゆえに楽曲の特徴量をスペクトログラムとする．ただし，楽曲の特徴量を鮮鋭とするために，マルコフクラスタをもちいて端点を得るようスペクトログラムの要素の値を先鋭化する．この際，マルコフクラスタのパラメータ a を 3.0，e を 2.0 とおく．なお，楽曲の教師信号は 1,090 の楽曲からなり，ラベルには感性を表す 90 種の語彙が付与される．この語彙は賑やか，穏やか，爽やかを始めとする情感を表す語彙からなる *1．本稿ではこれを感性語彙と呼ぶ．

連絡先: 錠 尚史，株式会社ソケッツ，ikari@sockets.co.jp

*1 商用データのために非公開である，必要の際は連絡先まで連絡されたし

2.2 楽曲のグラフ表現

フーリエ級数は正規直交基底関数の正弦波関数の多項式として表せられる．ゆえにラプラス固有関数 $f(w)$ をもちいて，次数行列 D と隣接行列 A からなるラプラシアン行列 L の固有ベクトルより，フーリエ変換に等しい結果を得られる．

$$f(w) = \langle f, e^{jwt} \rangle = \int_R f(t)\, e^{-jwt}\, dt \tag{1}$$

$$e^{-jwt} = \frac{\partial^2}{\partial t^2}\, e^{-jwt} = w^2\, e^{-jwt} \tag{2}$$

$$w^2 = (2\pi\xi)^2 \tag{3}$$

楽曲の特徴量は，スペクトログラムの要素をグラフの頂点，隣接行列 A で任意の近傍の頂点同士を結合した構成をとる．次数行列 D の辺の重みはこれらスペクトログラムの要素の値の相関を重みとする．すなわち楽曲全てのスペクトログラムの要素の相関行列となる．なお，λ は固有値，μ_λ は固有ベクトルを表す．以上より，楽曲の特徴量は，スペクトログラムの要素について，任意の近傍の頂点間の値の振動として表される．

$$L = D - A = U\Lambda U^T \tag{4}$$

$$U = [\mu_{\lambda_0}, ..., \mu_{\lambda_{N-1}}] \tag{5}$$

$$\Lambda = diag(\mu_0, ..., \mu_{N-1}) \tag{6}$$

2.3 楽曲の畳み込み

楽曲の特徴量の畳み込みは，[Defferrard, Bresson and Vandergheynst, 2016] らの 128 要素の 2 乗からなるグラフカーネルフィルタ H を 20 次まで展開して畳み込む．グラフカーネルフィルタ H は楽曲の特徴量について逆フーリエ変換 U とフーリエ変換 U^T との積からなる多項式 $Udiag(H(\lambda_H))U^T f_{in}$ の H であり，次数は振動の大きさを表す．この際に求められる f_{out} が目的とする楽曲の感性の特徴である．

$$P_{\lambda_i} = \sum_{\lambda=\lambda_i} \mu_\lambda \mu_\lambda^T \tag{7}$$

$$P_{\lambda_i} P_{\lambda_j} = \delta(\lambda_i - \lambda_j) P_{\lambda_i} \tag{8}$$

$$f_{out} = H f_{in} \tag{9}$$

$$= \Big(\sum_{\lambda_i \in \sigma(L)} H(\lambda_i) P_{\lambda_i} \Big) f_{in} \tag{10}$$

$$= Udiag(H(\lambda_H))U^T f_{in} \tag{11}$$

2.4 楽曲の感性の個人差を表すニューラルネットワーク

フーリエ級数は級数が収束する前提の元，微分可能である．ゆえにグラフカーネルフィルタは，ラベルと楽曲の特徴量より誤差逆伝搬法をはじめとする学習過程で求められる．この際，グラフカーネルフィルタの荷重は，90 種の感性語彙が付与されたラベルと，グラフ表現された楽曲の特徴量を教師信号とし，グラフカーネルフィルタを入力層，1 層の中間層を持つニューラルネットワークを出力層とした構成より誤差逆伝搬法をもちいて求められる．上記の f_{out} と 1 層の中間層を持つニューラルネットワークにおける荷重とは異なり，この荷重は個人の感性の差を表す役割を持つ．

3. 楽曲の感性の特徴

3.1 楽曲の識別の精度

楽曲の感性の特徴モデルをもちいて，1,090 の楽曲，ならびに 90 種の感性語彙を付与したデータセットについて，深層学習の学習過程よりグラフカーネルフィルタを求め，さらに楽曲の特徴量とグラフカーネルフィルタより，全ての感性語彙を満たす楽曲の感性の特徴を求めた．その楽曲の特徴量の識別の精度は 96%に達した．この精度について学習回数の変動を加えた [表 1] を以下に記す．この際，汎化性能については 1,090 の楽曲の内の 10%をアトランダムに訓練データとした．

表 1: 楽曲の識別の精度

Epochs	訓練正答率	汎化正答率
1	0.0073	0.1431
40	0.8284	0.8110
80	0.9532	0.9394
100	0.9633	0.9514

3.2 楽曲の感性の特徴の俯瞰

得られた楽曲の感性の特徴について，全体の俯瞰を得るために，全ての楽曲の感性の特徴をグラフカーネルフィルタごとに重ね合わせた [図 1] を作成した．グラフカーネルフィルタはフーリエ級数展開の多項式に等しく，4 次項までで楽曲の感性の特徴がほぼ表されている．

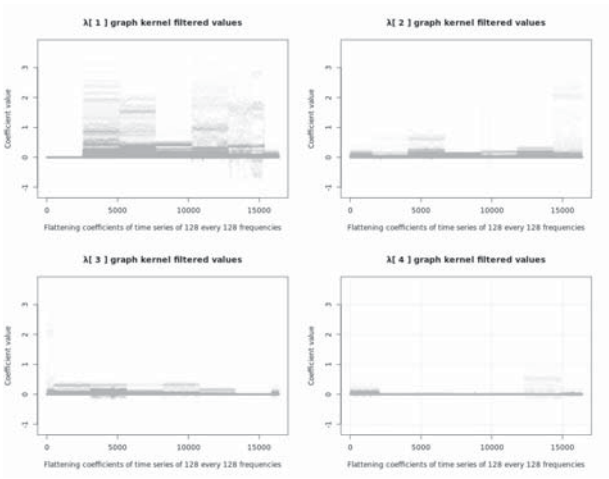


図 1: 楽曲の感性の特徴（全体）

[図 1] の横軸は楽曲の特徴量とグラフカーネルフィルタの積をとり，128 要素の 2 乗を 128 要素ごとに 1 次元に平坦化した軸である．これは左より高周波成分，右に進むにつれて低周波成分であることを示す．縦軸は楽曲の感性の特徴，すなわちグラフカーネルフィルタの係数を表す．この係数は値が高いほど振動が多い．楽曲の特徴量が与えられた際，受容野相当のグラフカーネルフィルタから得られる係数，すなわち楽曲の感性の特徴は，横軸の階数を 6 とした際に高周波帯，低周波帯，中周波帯のそれぞれ 2 種の反応よりなる．これは聴覚の基底膜の反応と同じ傾向を示している [Pickles, 1995].

3.3 特徴の次元圧縮による俯瞰

楽曲の感性の特徴は，グラフカーネルフィルタの係数であるため，グラフカーネルフィルタの 128 要素の 2 乗，それを 20 次持つ．すなわち 327,680 要素で表される．ゆえに楽曲の感性の特徴を固有値分解し，固有ベクトルより傾向を得る．得られた固有ベクトルは，おおよそ 3 種の方向に集約される [図 2].



図 2: 特徴の次元圧縮による俯瞰

3.4 感性語彙と楽曲の感性の特徴

感性語彙は，活性と非活性を表す軸，快と不快を表す軸の直交上で表される [Russell, 1980]．ゆえにそれらの軸に当該する語彙を活性について賑やか，非活性について穏やか，快について爽やかと前提する．不快は不快に相当する感性語彙がないために割愛した．ここで感性語彙に紐づく楽曲の例を挙げる，賑やかは真夏の Sounds good![AKB48] 他，穏やかは Too Much Rain[Paul McCartney] 他，爽やかは Love Is Stronger Than Pride[Sade] 他である．これらの楽曲の感性の特徴は，賑やかでは，1 次と 2 次に注目すれば高周波帯と中周波帯に高い値が分布し [図 3]，穏やかでは，1 次に注目すれば低周波帯に高い値が分布 [図 4]，爽やかでは，1 次に注目すれば高周波帯に高い値が分布する [図 5].

ここで感性語彙の直交軸から離れた感性語彙について，楽曲の感性の特徴を求める．非活性と快の中間に位置付けられる感性語彙は，愛しいと前提する．楽曲の例は If You Leave Me Now Maps[Chicago] となる．得られた楽曲の感性の特徴は，1 次と 2 次に注目すれば低周波帯と高周波帯に高い値が分布する [図 6]．感性語彙の軸の非活性，すなわち穏やかには低周波帯に高い値が分布し，快，すなわち爽やかには高周波帯に高い値が分布している．ゆえに愛しいは感性語彙の直交軸の和からなると考えられる．また，これらの感性語彙の直交軸の周波帯の傾向は，[3.3 特徴の次元圧縮による俯瞰] の 3 種の方向を示していると考えられる．

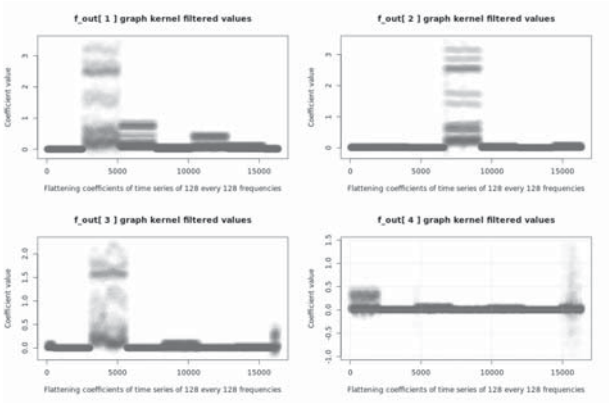


図 3: 楽曲の感性の特徴（賑やか）

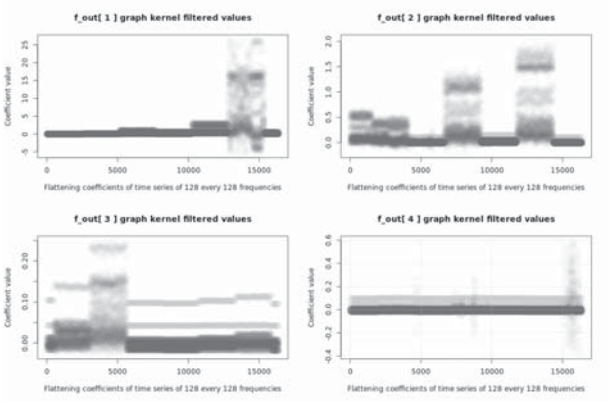


図 4: 楽曲の感性の特徴（穏やか）

3.5　楽曲の感性の特徴と感性語彙の類似性

楽曲の感性の特徴は感性語彙に紐づく．また，楽曲の感性の特徴は数列として表される．ゆえに楽曲の感性の特徴より幾何表現が可能である．以下に恋愛に関する感性語彙が付与された楽曲の集まりの例を記す [図 7]．恋愛を表す感性語彙を持つ楽曲の感性の特徴は，類似した数列となり，近い位置関係が求められている．また，同様に勇気づけに関する感性語彙が付与された楽曲の感性の特徴も類似した数列となり [図 8]，楽曲の感性の特徴は，感性語彙に基づいた類似性を得ていると言える．

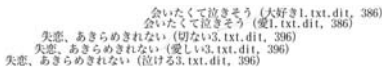


図 7: 恋愛を表す感性語彙を持つ楽曲の位置関係

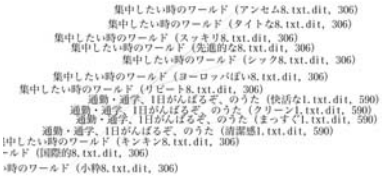


図 8: 勇気づけを表す感性語彙を持つ楽曲の位置関係

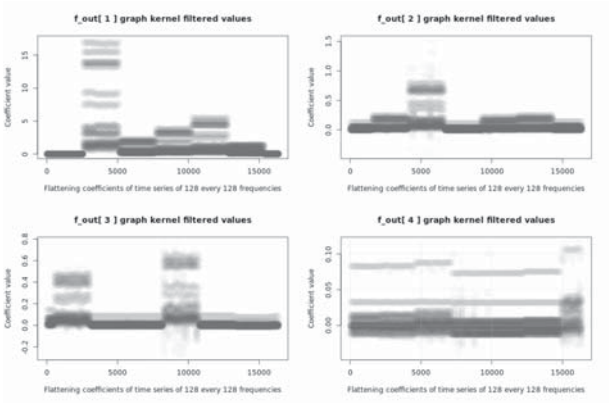


図 5: 楽曲の感性の特徴（爽やか）

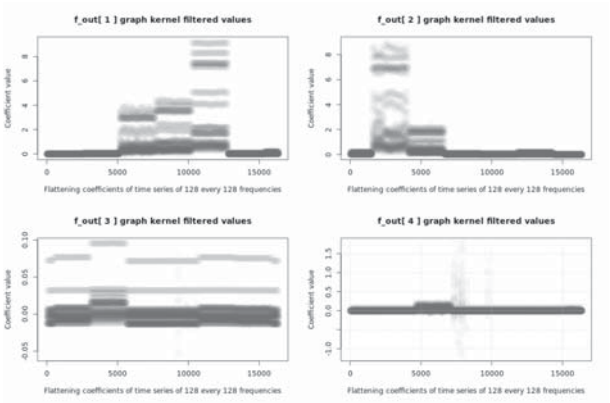


図 6: 楽曲の感性の特徴（愛しい）

3.6　楽曲の感性の特徴同士の類似性

楽曲の感性の特徴は，深層学習の学習過程をもちいて求められる．ゆえに楽曲の特徴量より感性語彙の識別が可能である．識別は深層学習に基づくため，識別の結果，得られる楽曲の特徴量の分類の値は，その分類の荷重を表す．本項では，この分類の荷重の値と楽曲の感性の特徴の類似性より，求められる類似楽曲の例を示す．ここでは感性語彙より特徴が顕著な賑やかの真夏の Sounds good![AKB48]，穏やかの Too Much Rain[Paul McCartney]，爽やかの Love Is Stronger Than Pride[Sade]，愛しいの Lady Marmalade[Christina Aguilera] を例にもちいる．それぞれ，賑やかでは summer tail[KEYTALK]，穏やかでは Heaven On The Ground[Jos James]，爽やかでは The Lady Wants To Know[Michael Franks]，愛しいでは Want U Back[Cher Lloyd] が求められた．これら類似楽曲の特徴を，賑やかの類似を [図 9] に，穏やかの類似を [図 10] に，爽やかの類似を [図 11] に記す．

4.　まとめ

楽曲の特徴量より，グラフカーネルフィルタと深層学習の学習過程をもちいて，楽曲の感性の特徴を求めた．この楽曲の感性の特徴に基づく識別の精度は 96%に達した．得られた楽曲の感性の特徴を固有値分解した際，その特徴は，おおよそ 3 種の方向に集約される固有ベクトルからなり，おおよその楽曲の感性の特徴の傾向が示された．また，楽曲の感性の特徴は，

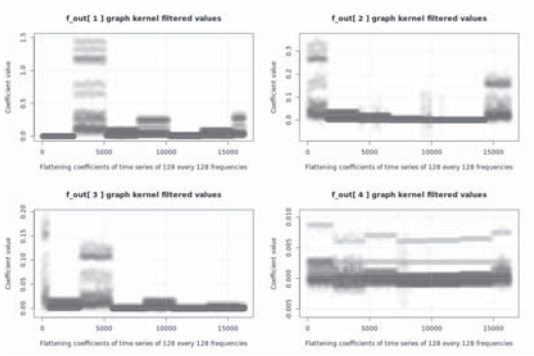


図 9: 楽曲の感性の特徴（賑やかの類似）

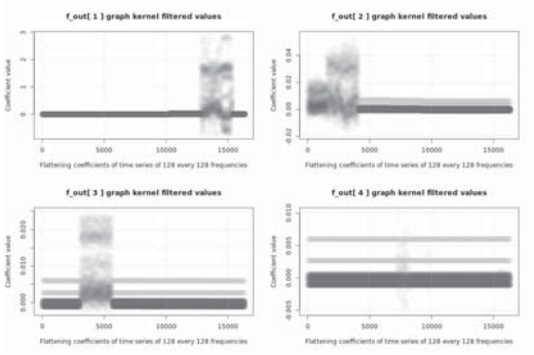


図 10: 楽曲の感性の特徴（穏やかの類似）

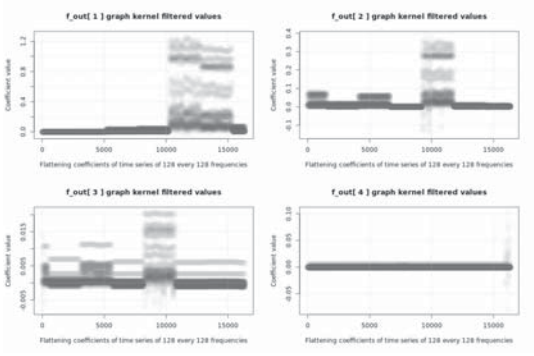


図 11: 楽曲の感性の特徴（爽やかの類似）

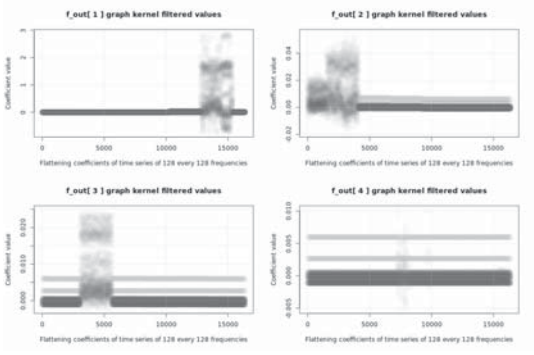


図 12: 楽曲の感性の特徴（愛しいの類似）

賑やかな感性語彙が与えられた際には高周波成分と中周波成分が高く，穏やかな感性語彙が与えられた際には低周波成分が高く，爽やかな感性語彙が与えられた際には高周波成分が高く，感性語彙とそれに紐づく楽曲の感性の特徴の関係が認められ，3 種の方向に集約される固有ベクトルとの関連が示唆された．加えて，感性語彙と楽曲の感性の特徴の関係，楽曲の感性の特徴同士においてそれぞれ類似性が示された．上記より，得られた楽曲の感性の特徴を充当と結論する．

ただし，今回もちいた楽曲の数は 1,090 であり少数であることをふまえ，今後はより大規模な楽曲の感性の特徴を求め，より微細な特徴の獲得を可能とすること，楽曲の感性の特徴と感性語彙に関係が見られることより，その関係を正準相関と仮定し，深層学習の学習過程をもちいた，楽曲の感性の特徴のさらなる追求を今後の課題とする．

5. 謝辞

本件を進めるにあたり，日常の議論を通じての多くの知識や示唆を頂いた株式会社ソケッツの皆様に感謝します．協力していただいた皆様へ心から感謝の気持ちと御礼を申し上げたく，謝辞にかえさせていただきます．

参考文献

[1] Hevner, K. (1935b). Expression in music: A discussion of experimental studies and theories. Psychological Review, 42, 186-204.

[2] C.J.Clopper, E.S.Pearson, (1934). Theuseofconfidence-orfiducial limits illustrated in the case of the binomial, Biometrika 26 404416.

[3] Krizhevsky, A., Sutskever, I. and Hinton, G. (2012). ImageNet classification with deep convolutional neural networks. In Proc. Advances in Neural Information Processing Systems 25 10901098.

[4] Marr, D. And Hildrech, E. (1980). Theory of edge detection. Proc. R. Soc. Long. B, 207:187-217.

[5] 鈴木昇一. (1994). パターンのエントロピーモデル，電子情報通信学会論文誌 (D-II)，vol.J77-D-II, no.10, pp.2220-2238.

[6] A.Cochocki, Rolf Unbehauen. (1993). Neural Networks for Optimization and Signal Processing 1st. John Wiley and Sons, Inc.

[7] Hevner, K. (1937). The affective value of pitch and tempo in music. American Journal of Psychology, 49, 621-630.

[8] Michal Defferrard, Xavier Bresson, Pierre Vandergheynst. (2016). Convolutional Neural Networks on Graphs with Fast Localized Spectral Filtering. Advances in Neural Information Processing Systems 29.

[9] J.O.Pickles, 谷口郁雄監訳. (1995). 聴覚生理学, 二瓶社.

[10] J.A.Russell. (1980). A circumplex model of affect. Journal of Personality and Social Psychology, Vol. 36, pp. 1161 1178.

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

機器の振動データの非負値行列因子分解による特徴抽出と異常検知

Feature Extraction and Anomaly Detection by Non-negative Matrix Factorization of Vibration Data of Machine

関根 理敏 *1　小林 一樹 *1　伊加田 恵志 *1
Masatoshi Sekine　Kazuki Kobayashi　Satoshi Ikada

*1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, in the field of manufacturing industry, there is an increasing need for anomaly detection by collection and analysis of sensor data for predictive maintenance of factory equipment and industrial product. In the conventional method, for example, attention is focused on the power of a specific frequency band related to the anomaly of the equipment, and anomaly detection is performed by comparing the magnitude of the power. However, when there are many or wide frequency bands involved in anomaly, they may not be clearly specified. Therefore, we propose a method for anomaly detection using non-negative matrix factorization which is an unsupervised learning algorithm. Even if the frequency band of the vibration data is not clearly specified, our proposed method can automatically extract the features of vibration data and detect anomaly of machines accurately.

1. はじめに

近年，主に製造業の分野において，工場設備や工業製品の機器の予防保全に向けたセンサデータの収集・分析による異常検知のニーズが高まっている [METI 17]．そこでは機器の状態監視において，ネットワーク化された振動センサ，音響センサ等を配置し，それらのセンサデータをリアルタイムに収集・分析し，観測対象の故障の兆候を自動的に把握する．これによりメンテナンスのタイミング等を最適化でき，機器のダウンタイム発生による稼働率低下を抑制することが可能となる．

機器の異常検知において，従来手法では一例として，機器の正常・異常に関連する特定の周波数帯のパワーに着目し，そのパワーの大小を比較することによって異常検知を行っている．しかしながら，正常・異常に関与する周波数帯が複数ある場合や，広域にまたがる場合，また検知対象に個体差がある場合等では，周波数帯を明確に特定し，パワーの大小から異常検知を行うのが困難な場合がある．

そこで本稿では，教師なし学習アルゴリズムである非負値行列因子分解 (Non-negative Matrix Factorization (以下，NMF))[Lee 99] を利用し，学習段階と判別段階で NMF の基底行列を共通化することで，係数行列を特徴量とした異常検知手法を提案する．機器を利用した異常検知の性能評価を行った結果，振動データの自動特徴抽出によって，異常部位の動作区間における異常検知が可能であることが分かった．

2. 異常検知手法

2.1 学習段階におけるパワースペクトルからの NMF による特徴抽出と学習モデルの構築

図 1 に本手法における学習段階の動作を示す．学習データとして，正常状態のみ利用する場合と，正常・異常の両方の状態を利用する場合があるが，以下は前者の場合について説明する．まず正常状態における振動データからそれぞれ平均値を引き，高速フーリエ変換（Fast Fourier Transform (FFT)）を行うことにより，パワースペクトルを求める．以下の式 (1) で

連絡先: 関根理敏，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，sekine566@oki.com

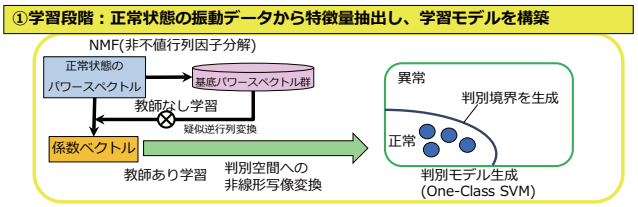


図 1: 学習段階

示すように，正常状態のパワースペクトル $\boldsymbol{Y}_l$ に NMF を適用し，係数行列 $\boldsymbol{W}_l$ と基底行列 $\boldsymbol{H}_l$ に分解する．

$$\boldsymbol{Y}_l \simeq \boldsymbol{W}_l \boldsymbol{H}_l \tag{1}$$

ここで係数行列 $\boldsymbol{W}_l$ の各成分は，対応する基底行列 $\boldsymbol{H}_l$ の各ベクトル成分の，正常状態のパワースペクトル $\boldsymbol{Y}_l$ における含有情報を示し，パワースペクトルの特徴を表す．本稿では，このように係数行列を特徴量として学習モデルを構築する．この場合，構築した学習モデルにより判別を行うには，学習段階における基底行列 $\boldsymbol{H}_l$ を共通の基底行列として判別段階でも利用する必要がある．そこで正常状態のパワースペクトル $\boldsymbol{Y}_l$ に基底行列 $\boldsymbol{H}_l$ の逆行列をかけて係数行列を求める．しかしながら，基底行列 $\boldsymbol{H}_l$ は一般に逆行列を持たない．そこで，ムーア・ペンローズの擬似逆行列 $\boldsymbol{H}_l{}^+$ を求め，学習段階においても判別段階においてもこの疑似逆行列 $\boldsymbol{H}_l{}^+$ により係数行列を抽出する．よって，学習時においては以下の式 (2) を用いて係数行列 $\boldsymbol{W}_{lf}$ を求め，この係数行列を One-Class SVM に入力しモデルを構築する．

$$\boldsymbol{W}_{lf} = \boldsymbol{Y}_l \boldsymbol{H}_l{}^+ \tag{2}$$

ここで係数行列 $\boldsymbol{W}_{lf}$ は $||\boldsymbol{Y}_l - \boldsymbol{W}_{lf}\boldsymbol{H}_l||^2$ を最小にする最小二乗解となる．

2.2 判別段階における分類スコアの算出と正常・異常判別

図 2 に本手法における判別段階の動作を示す．判別対象のパワースペクトル $\boldsymbol{Y}_t$ に対して学習段階と同様に，以下の式 (3)

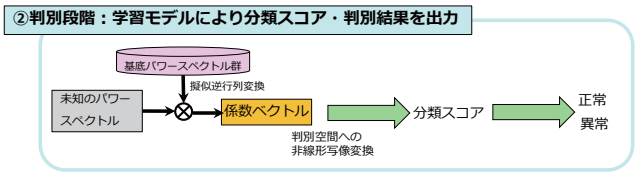


図 2: 判別段階

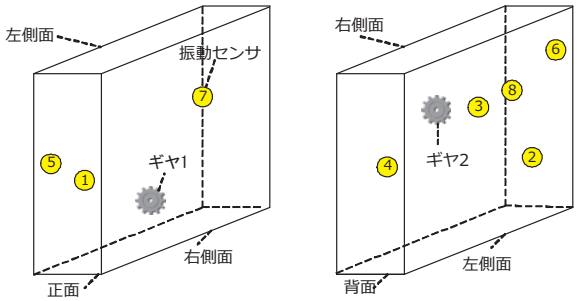


図 3: 振動センサ 8 箇所とギヤ 2 箇所の設置位置

で示すように基底行列の擬似逆行列 $\boldsymbol{H}_l{}^+$ をかけることで係数行列 $\boldsymbol{W}_{tf}$ を求める．

$$\boldsymbol{W}_{tf} = \boldsymbol{Y}_t \boldsymbol{H}_l{}^+ \tag{3}$$

学習モデルは係数行列 $\boldsymbol{W}_{tf}$ の各ベクトルごとに分類スコアを算出し，異常度の推定及び判別を行う．なお，分類スコアは判定境界までの符号付き距離であり，異常度が高いほど値が小さくなる．

3. 性能評価

本手法の評価を行うため，複数のモータ及び機械式の可動部を有する機器の正常・異常時の異常度推定による判別を行った．機器はシーケンス動作 30 秒間を 1 サンプルとして正常・異常各 10 サンプル分の振動データを取得した．機器の異常を，歯の欠け（ギヤ 1），回転の偏心（ギヤ 2）があるギヤにそれぞれ交換することにより発生させた．また検知周波数範囲が 10Hz から 15kHz までの同機種の振動センサを図 3 のように 8 箇所配置した．サンプリング周波数は 100kHz とした．

図 4 に 1 シーケンス動作 30 秒間の，図 3 における振動センサ 1 で取得した信号及びスペクトログラムを示す．スペクトログラムはウィンドウ幅 0.1 秒，シフト幅 0.05 秒とした．また図 5 に 1 シーケンス動作におけるギヤ 1，2 の動作期間を示す．動作期間はシーケンス動作全期間における NMF の係数の時系列の振幅の立ち上がり時点，立ち下がり時点から求めた．

スペクトログラムにおける 0.1 秒間のパワースペクトルごとに正常 5 サンプルで One-Class SVM で学習を行った．残りの正常データ 5 サンプル及び異常データを判別データとして交差検定（分割数 2）を行った．また，ギヤ 1, ギヤ 2 の動作が重複しない動作期間を評価対象とし，ギヤ 1 は 2.8 秒間，ギヤ 2 は 0.75 秒間における 0.05 秒毎の分類スコア値の平均値を閾値判別した．閾値は判別正解率が最も高くなる値に設定した．

表 1，表 2 にそれぞれギヤ 1, ギヤ 2 の判別結果を示す．実験の結果，ギヤ 1 については図 3 における振動センサ 2 または 8，ギヤ 2 については振動センサ 2 のデータをそれぞれ用いることで，最も精度よく正常・異常判別できることが分かった．

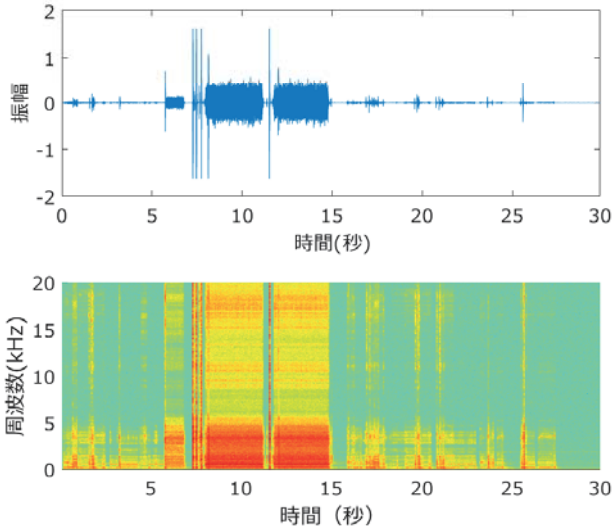


図 4: 1 シーケンス動作における信号（上）とスペクトログラム（下）

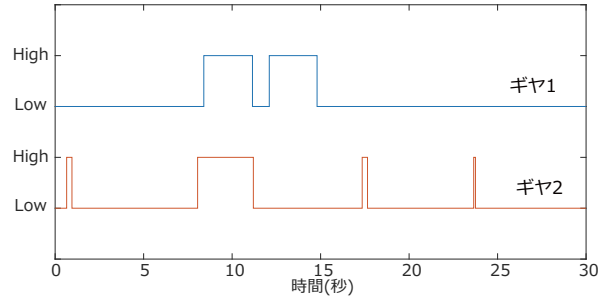


図 5: 1 シーケンス動作におけるギヤの動作区間 (High の区間)

4. おわりに

本稿では機器の異常検知において，NMF で振動データの特徴を抽出し，機械学習により機器の異常検知を行う手法について示した．機器を対象とした正常・異常状態の振動データを利用した評価の結果，ギヤの動作区間において，異常時においては正常時と比べて異常度が増加し，異常検知が可能であることが分かった．今後は機器の劣化経緯を観測した振動データを利用した異常の予兆検知を行う予定である．また正常状態において，複数の動作モードが存在する場合における効率的かつ高精度な異常検知手法の検討を行う予定である．

参考文献

[METI 17] 経済産業省，2017 年版ものづくり白書.

[Lee 99] D.D. Lee and H.S.Seung,„“Learning the part of objects by non-negative matrix factorization,” Nature, vol.401,no,pp.788-791,Oct.1999.

表 1: ギヤ 1 の判別正解率 (%)

真＼判別	正常	異常
正常	100	0
異常	0	100

表 2: ギヤ 2 の判別正解率 (%)

真＼判別	正常	異常
正常	100	0
異常	5	95

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

1d CNN-LSTM による調節弁内部の異常検知

Anomaly Detection in Control Valves by 1d CNN-LSTM

茂木 貴弘[*1] 中澤 友哉[*1] 田原 鉄也[*1]
Takahiro Motegi Yuya Nakazawa Tetsuya Tabaru

[*1] アズビル株式会社
Azbil Corporation

This paper proposes an anomaly detection system for time series data by using 1d CNN-LSTM networks, which is a combination of one dimensional convolutional neural network (1d CNN) and long short time memory (LSTM). The CNN processes a time series data from a sensor and its output is passed to LSTM. After training of the networks, the CNN grows into an appropriate filter to emphasize features of the time series in frequency domain, and the LSTM becomes a good feature extractor. The extractor works fine even under noisy conditions. It generates a feature vector and the vector is utilized to diagnose anomalies. We applied the proposed system to vibration sensor data obtained from a control valve. The system detected anomalies due to cavitation, which is one of the most serious phenomenon of control valves, with 99.5% accuracy. The result shows availability of our proposed method.

1. はじめに

本稿では、時系列一次元信号の分類タスクによる異常検知アプリケーションとして、振動センサデータを分析した事例について報告する。

石油・化学業界をはじめ各種プラントにおいては、流量等を制御する操作端として調節弁が用いられており、調節弁内部で発生する異常の一つとして、キャビテーションと呼ばれる現象がある。キャビテーションとは、流体が弁を通過する際に、流体圧力がその流体の飽和蒸気圧以下に下がり再度圧力回復する過程で、流体中に気泡が発生、消滅する一連の現象である[azbil 13]。キャビテーションによる衝撃圧は数百気圧にも達し、弁内部を損傷させるため、放置し続ければ流体漏洩などの事故につながる可能性もある。そのため、プラントの予防保全の観点からキャビテーションを検出することは重要である。

そこで、キャビテーションを自動で検出することを目的に、調節弁本体の外部に振動センサを取り付けて信号を取得し、振動信号を分析する手法を検討した。振動信号の例を図 1 に示す。

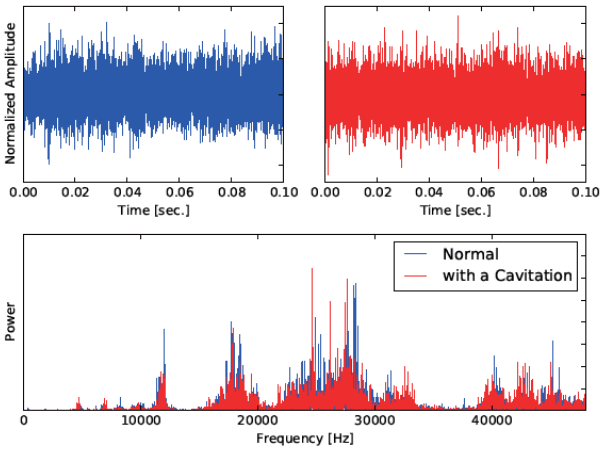


図 1 分類対象の一次元信号

図 1 の青線はキャビテーション無しの波形であり、流体による振動がノイズとして計測されている。図 1 の赤線はキャビテーション有りの波形であり、流体による振動に加えて、非定常にキャビテーションによる振動が混在している。図 1 で比較してわかるように、信号対雑音比は小さく、一般には判別することは難しい。

よって、振動信号からキャビテーション有無を自動で分類する手法として、CNN (Convolutional Neural Network) [LeCun 98] と LSTM (Long Short Term Memory) [Hochreister 97] に着目した。本稿では、これらを組み合わせ、教師あり学習により、キャビテーションの特徴量を自動で抽出し分類するタスクを試みた。

2. 1d CNN-LSTM による異常分類方法

2.1 1d CNN

一般に、CNN は画像データ等の多次元データを対象に利用されており、画像の局所的な特徴量を学習できることが知られている。先行研究では、一次元信号をスペクトログラム等の二次元データへ変換し、一次元信号を画像として CNN で分類タスクをする試みも行われている [Lostanlen 16]。しかし、ニューラルネットワークへ信号を入力する度にスペクトログラムへ変換する計算コスト、本来一次元である信号をわざわざ CNN で二次元分析する計算コストが必要となり、計算能力の低い現場機器へ学習済みモデルを搭載し運用する用途には適さないという課題がある。また、一次元信号をスペクトログラムへ変換する過程で位相情報が損なわれるため、分類精度へ影響が出る可能性もある。

そこで、一次元信号を二次元化することなく入力できる 1d CNN に着目した [Collobert 16]。1d CNN の畳み込み層は入力信号と同じく一次元の畳み込みフィルタを用いて時間方向へストライドさせる演算となるが、基本的に通常の CNN と同様に実装できる。1d CNN では、分類対象の信号の特徴的な周波数帯域を強調するような畳み込みフィルタを学習により獲得できる。

また、通常の CNN では次元削減のためにプーリングを用いることが定石であるが、1d CNN の場合はプーリングによるダウンサンプリングでエイリアシングが発生し、高周波成分が損なわれることが懸念されるため、本稿では用いないこととした。

連絡先： 茂木貴弘, アズビル株式会社 技術開発本部,
神奈川県藤沢市川名 1-12-2, t.motegi.zg@azbil.com

2.2 LSTM

CNN は、局所的な周波数帯域での特徴量学習に適した手法である一方、白色雑音等の広帯域な雑音が混在する分類タスクは苦手と考えられる [三村 17]。図 1 に示すように、分類対象の信号の周波数帯域は広帯域で重複しており、流体による振動に比べてキャビテーションによる振動は小さいことから、1d CNN のみにより分類タスクを高精度で実現することは難しいと考えられる。そこで、LSTM に着目した。LSTM は、過去のタイムステップの信号値を長期間保持できる特性があるため、白色雑音等の広帯域な雑音への耐性が期待できる。

2.3 1d CNN-LSTM

上記考え方に基づき、図 2 のニューラルネットワーク(評価モデル I)を設計した。ネットワークの詳細設計は表 1 に示す。

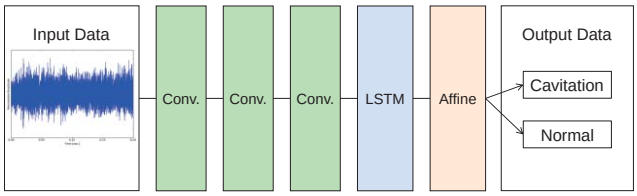


図 2 ニューラルネットワーク構造

表 1 ニューラルネットワークの詳細条件

レイヤーの設定	
入力層	サイズ：(10000, 1)
畳み込み層①	フィルタ：(100, 1)×1 ストライド：2 バッチ正則化あり
畳み込み層②	同上
畳み込み層③	同上
LSTM 層	ドロップアウト率：0.1
全結合層	活性化関数：シグモイド
出力層	サイズ：(2, 1)

3. キャビテーション検出実験

3.1 データセット

流量実験設備に組み付けられた調節弁本体外部に振動センサを設置し、流体条件を変化させたときの振動をサンプリング周波数 96 kHz で収録した。実験時に透明流路を用いてキャビテーション有無を目視確認し、ラベル付けした。ラベル付けされた収録データは、信号長 10,000 サンプルで区切り、データセットとした。また信号の振幅のばらつきが学習に影響しないように、データセットの振幅は実効値で正規化した。キャビテーションあり 1,200 セット、キャビテーションなし 1,600 セットからなるデータセットから、検証データとして各 100 セットをランダムに選択し、残りを訓練データとした。

3.2 学習条件

学習を効率的に進めるために、バッチ数 200 のミニバッチ学習を行った。損失関数はソフトマックス交差エントロピとし、最適化アルゴリズム RMSprop としてネットワークの更新を行った。

評価モデル I との比較として、1d CNN のみの評価モデル II、LSTM のみの評価モデル III についても検証を行った。評価モデル II、III のレイヤーの設定は、表 1 の畳み込み層、LSTM 層と同様とした。

4. 実験結果

学習回数と分類精度の関係を図 3 に示す。評価モデル II は、学習が収束せず、検証データでの最高分類精度は 90%であった。本稿で着目した評価モデル I は、検証データでの最高分類精度は 99.5%で収束しており、極めて高い分類精度が確認された。一方で、評価モデル III は過学習状態となっており、汎用的な特徴量を学習できていない。その理由については今後も引き続き考察が必要であるが、本実験結果より、1d CNN と LSTM を組み合わせることで時系列一次元信号をより高精度で分類できることがわかった。

5. まとめ

本稿では、教師あり学習により時系列一次元信号から特徴量を自動で抽出できる 1d CNN-LSTM を用いて、キャビテーションを検出した事例を報告した。

実験結果より、評価モデル I は 99.5%という極めて高い分類精度を確認できた。よって、本手法が調節弁内部の異常を早期に検知し、予防保全に貢献できる可能性が示された。

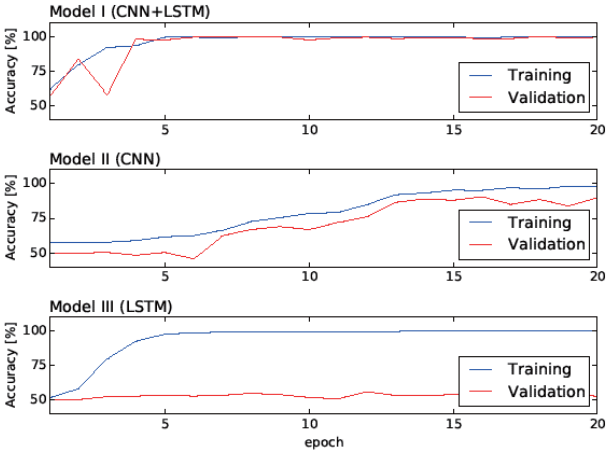


図 3 実験結果

参考文献

[azbil 13] アズビル株式会社編：調節弁のキャビテーションについて，調節弁用計装資料, ID1-8000-4600, アズビル株式会社 (2013)

[LeCun 98] Y. LeCun: Gradient-based learning applied to document recognition, Proceedings of the IEEE, Vol.86, pp. 2278-2324 (1998)

[Hochreister 97] S. Hochreiter: Long short-term memory, Neural computation, Vol. 9, pp. 1735-1780 (1997)

[Lostanlen 16] V. Lostanlen and C.-E. Cella：Deep Convolutional Networks on the Pitch Spiral for Musical Instrument Recognition, Proceedings of the ISMIR2016 (2016)

[Collobert 16] R. Collobert, C. Puhrsch, and G. Synnaeve: Wav2Letter: an End-to-End ConvNet-based Speech Recognition System, arXiv:1609.03193 (2016)

[三村 17] 三村正人: 深層学習に基づくフロントエンド特徴量強調と頑健な音声認識，日本音響学会誌，73 巻 1 号，pp.47-54 (2017)

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

認知症ケア高度化のための協調学習環境を活用した認知症の見立てコーパスの構築

Constructing Diagnosis Corpus Using Collaborative Learning Environment for Improving Dementia Care

神谷 直輝 *1 Naoki Kamiya　上野 秀樹 *2, 3, 4 Hideki Ueno　吉沢 拓実 *1 Takumi Yoshizawa　石川 翔吾 *1 Shogo Ishikawa
今田 兼太 *1 Kenta Imada　西山 明也斗 *1 Hayato Nishiyama　桐山 伸也 *1, 4 Shinya Kiriyama　玉井 顯 *1 Akira Tamai　竹林 洋一 *1, 4 Yoichi Takebayashi

*1 静岡大学 Shizuoka University　*2 千葉大学医学部附属病院 Chiba University Hospital　*3 敦賀温泉病院 Tsuruga Onsen Hospital
*4 みんなの認知症情報学会 The Society of Citizen Informatics for Human Cognitive Disorder

This paper describes construction of diagnosis corpus using collaborative learning environment for improving dementia care. Analyzing causes of reversible dementia are essential to improve dementia care, and which are interpreted diversely. We developed the diagnosis corpus using the collaborative learning environment to construct diagnostic knowledge by accumulating interpretations. Our corpus enable us to analyze learning effect and improve knowledge of dementia diagnosis.

1. はじめに

認知症の「状態」を引き起こす認知機能低下の原因は 70 種以上も存在する. その中には治療可能な医学的疾患も多く存在することが知られており, 医療の関与が欠かせない. 脳機能の低下を引き起こしている原因を分析することを本稿では認知症の「見立て」と呼ぶ. 医師の見立ての知識を学ぶことで, 医師が必要とする情報を理解することができ, 適切な情報提供によって認知症ケアの質が改善することが期待できる. また, 見立てのノウハウを学ぶことで支援対象者に対する理解が深まり, 自信を持って支援に当たることができるようになり, 支援の質が改善することが期待される.

筆者らは多職種で見立て知が学べる学習環境を構築してきた[橋詰 2017]. 家族や介護従事者, 看護師, 医師が認知症のケースを軸に多面的に議論することで, 気づきが増え, 実践的な見立ての理解が促される. 本稿では, 学習者の意見や気づきを収集し, 協調学習で生み出される見立て知として蓄積・利用を促すための見立てコーパスの構築について述べる.

2. 認知症の見立て知の協調学習

認知症とは, “一度正常に発達した認知機能が後天的な脳の障害によって持続的に低下し, 日常生活や社会生活に支障をきたすようになった状態”である[日本神経学会 2010]. 特に治療可能な認知症(Reversible Dementia[Chari 2015] / Treatable Dementia[Mahler 1987])への対応が重要である. 治療可能な認知症とは, 脳細胞は死滅しておらず, 脳機能を低下させる原因を治療で取り除くことで脳機能の回復が可能な認知症である. この治療可能な認知症に気づくポイントには, 歩行や排泄, ふらつき, 食欲, 睡眠の状況など日々の暮らしで観察できる項目が多くある. 身近にいる支援者がいち早く気づけるようにするためには, 医師の見立ての知識の理解が欠かせない. そして, 実生活で見立てを行い, 支援の質を改善することが必要である.

実践的な学びにつなげる手法には, 医学や経営学, 法学の分野で有用なケースメソッドがあり[Barnes L.B. 1984], 筆者らはその手法を発展させた協調学習会を開催してきた. 認知症のケース検討を主軸とした「①個人での見立て, ②グループでの見立て, ③総合討論」という流れを設計した. 多様な学習者が各自の立場・経験をもとに考え, 多角的に議論することで見立ての理解が促される. 個々の学習者の知の獲得を支援する取り組みはあるが[Nelson B. 2012], 学習者と教師の議論や気づきなど学びのプロセスを蓄積することで, 見立て知の深化につながると期待される.

3. 協調学習環境に基づく見立てコーパスの設計

継続的な見立て知の構築と発展に向けて, 見立てコーパスを機軸とした協調学習環境を構築した(図 1). 見立てコーパスには, 専門家の知識を付与した病院のケースデータが蓄積されており, そのデータをもとに専門家と研究者が協調学習会で用いる検討ケース, 及び検討ケースに対する質問レポートを作成する. それらを用いた協調学習会を設計・開催し, その結果を見立て知として本コーパスに蓄積する. この協調学習環境によって家族や介護従事者, 専門家の知識・経験が織り交ざった新しい知が形成され, 見立て知を深化成長できると考える.

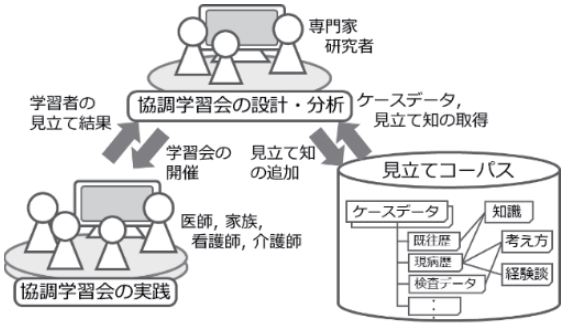


図 1 見立て知の協調学習環境

連絡先：神谷直輝, 静岡大学, 静岡県浜松市中区城北 3-5-1, 053-478-148, kamy@kirilab.net

協調学習会を効果的に学ぶ場にするために，質問レポートをタブレット型端末上で提示するツールを開発した．学習者の見立てた結果や意見を入力ログとして 5 秒毎にデータベースに送信する．連続的な入力内容の遷移を収集することによって「②グループ」での見立てや「③総合討論」での議論を通した個人の考え方や思考プロセス等の学びを表出化につなげる．また，ツールを用いた遠隔参加も可能である．議論に参加できる学習者が増えることで様々な観点の知を収集することができるようになる．このように収集された入力データを専門家や研究者が分析し，新たな知として見立てコーパスに蓄積する．

見立てコーパスには精神科医 2 名とのケースカンファレンスに基づいた病院の外来患者のケース 22 事例が蓄積されている．見立てでは数十項目以上の医療情報や詳細な生活情報等が認知症の人ごとに適切に用いられる．そこで，見立てに不可欠な情報を選定するため，外来患者のケースを用いたケースカンファレンスを開催し，医師に見立ててもらい，患者情報中の必要な項目を抽出した(表 **1**)．Web 会議ツール上で患者情報を医師に提示し，見立てのプロセスで着目する情報と理由，関連する知識等の解説を収集した．その結果をもとに患者情報を登録するための基本的な構造を設計した．医師 2 名に本コーパスの構造と入力済みデータを確認してもらった所，治療可能な認知症の検討に不要な項目は無いとの意見を得た．

表 1 治療可能な認知症の検討に用いる項目の一部

記載欄・検査名	項目
家族歴	家族構成，家族の状況
既往歴	聞き取り内容，HT，DM，輸血
本人歴	教育歴，職歴，家庭内状況，対人関係，趣味等
現病歴	聞き取り内容，身体状況(血圧，飲酒，排泄等)
服薬情報	一般名・含量・用法
認知機能評価	BFB，MMSE，HDS-R，行動観察方式 AOS, ADL
CT, MRI	医師の所見

4. コーパスに基づく学習効果の分析と見立て知の表現

見立てコーパスに継続的に知を蓄積・深化させるために，本コーパスを機軸とした協調学習環境を福井県敦賀市，若狭地区，藤沢市にて構築し，介護従事者を中心とした協調学習会を開催した．

収集した学習者の意見は，本コーパスの構造として予め蓄積された医師の見立て方との違いや，コーパスの構造で表現できない学習者の意見・考え方を見つけることができる．その例として，1 つの検討ケースに対し 10 名の学習者が治療可能な認知症を判別する際に参照した情報と，詳しく見立てるために必要だと指摘した情報の傾向を図 **2**に示す．特にエピソード(現病歴)の参照が多く，認知機能障害や生活障害を読み取る学習者が多かったことが分かる．とりわけ参照が少なかった項目には，現在の能力を以前と比べて理解するための職業歴や学歴，脳機能低下の原因を探るために不可欠な薬物歴への参照が少なく，それらの情報の活用した学習者は一部だったと分かる．しかし，その一部の学習者が生活支援や医学的な知識を用いた意見・見立てを他の参加者と共有することで，新たな意見や見立て知につながると考えられる．

協調学習会で得た意見や考え方を収集し，本コーパスの構造に応用する (図 3)．学習者の専門的知識や経験にもとづく意見を活用することで，ケースの情報から治療可能な認知症の可能性を検討できるようになる．このように協調学習会で得た知を蓄積することで，ひとつの事例の見立てを深めることや，見立て知を表現するコーパスの構造の改良・洗練につながることが期待される．

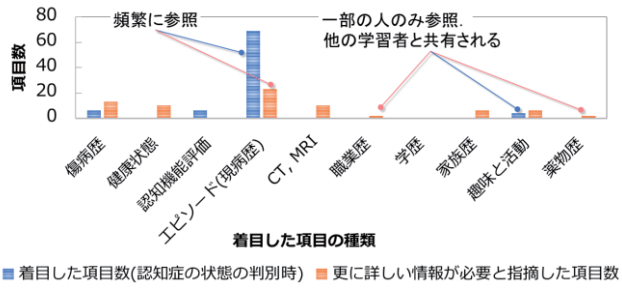


図 2 学習者が見立てに用いた情報の傾向

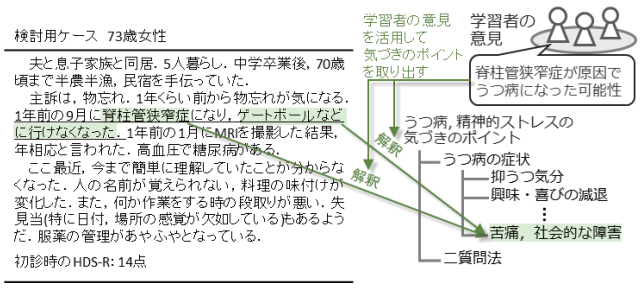


図 3 学習者の意見・考え方の活用例

5. おわりに

本稿では，見立てコーパスを機軸とした協調学習環境に基づく協調学習会を開催し，学習者の意見や考え方を活用することで見立てコーパスを構築・改良できることを示した．さらに，構築した本コーパスによる見立て知の学びの評価に加えて，学びが見立て知の深化につながる可能性が示された．今後も継続的に見立てコーパスを発展させ，見立て知を学ぶことでケアの質が向上するか検証する．

参考文献

[橋詰 2017] 橋詰裕樹 他：協調学習環境を活用した認知症の見立て知の学びと実践，第 31 回人工知能学会全国大会，1I2-NFC-02a-2in2 (2017).

[日本神経学会 2010] 日本神経学会監修：認知症疾患治療ガイドライン 2010, 医学書院 (2010).

[Chari 2015] Chari D, et.al., Reversible dementia in elderly: Really uncommon?, J. Geriatr Ment Health, 2:30-7 2015.

[Mahler 1987] Mahler ME, et. al., Treatable Dementias, Western Journal of Medicine, 146(6):705-712 (1987).

[Barnes L.B. 1984] Teaching and the Casemethod, third edition, Harvard Business School Press (1984).

[Nelson B. 2012] Baloian N., et.al., “Ubiquitous Mobile Knowledge Construction in Collaborative Learning Environments.” Sensors (Basel, Switzerland) 12.6 (2012).

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

個性に基づくケアのための認知症ケア協調学習環境の構築と実践

Construction and Practice of Collaborative Learning Environment for Personality-focused Care in Dementia Care

小俣 敦士 *1 Atsushi Omata
松井 佑樹 *1 Yuki Matsui
石川 翔吾 *1 Shogo Ishikawa
宗形 初枝 *2 Hatsue Munakata
中野目 あゆみ *2 Ayumi Nakanome
香山 壮太 *2 Sota Kayama
伊東 美緒 *3 Mio Ito
坂根 裕 *4 Yutaka Sakane
本田 美和子 *5 Miwako Honda
原 寿夫 *2 Hisao Hara
桐山 伸也 *1*6 Shinya Kiriyama
竹林 洋一 *1*4*6 Yoichi Takebayashi

*1静岡大学 Shizuoka University
*2郡山市医療介護病院 Koriyama Medical Care Hospital
*3東京都健康長寿医療センター研究所 Tokyo Metropolitan Institute of Gerontology
*4株式会社エクサウィザーズ ExaWizards Inc.
*5東京医療センター Tokyo Medical Center
*6みんなの認知症情報学会 The Society of Citizen Informatics for Human Cognitive Disorder

We describe the construction and practice of collaborative learning environment to develop the dementia care skills focusing on elderlies personality. In our learning environment, the policy of care for people with dementia is considered based on their personality and desire. And our learning environment helps to learn collaboratively dementia care throughout the organization by using video. We have conducted a collaborative learning for dementia care in the care fields. The results suggest that the collaborative learning environment is useful for learners.

1. はじめに

認知症高齢者は多様な個性をもち，自分らしく生活したいと願っているが，認知機能の低下に伴う将来の不安や自己喪失感によって行動・心理症状が現れやすい状態にある．この行動・心理症状には，抑うつ，徘徊，暴力なども含まれ，多くの医療介護現場を疲弊させている．一方で，ケアの達人は，身体的なスキルに加えて，相手の個性や願いを適切に理解することで，良好な関係を築くことができている．認知症の人本人の個性や願いを，ケアに関わる全ての人が共有してケアを実践できれば，より良い関係性を築くことができるとともにケアの高度化につながる．

本稿では，認知症高齢者の個性やゴール (願い) といった個性情報に基づいたケアの実践と高度化のための協調学習環境を提案し，有効性について検討する．

2. 構造化映像を用いた協調学習環境

閉鎖的であるケア現場では，どのようにケアを実践したのかを言語で表現することは難しいため，映像を用いてケアの振り返りを支援することで，学びを促進させることが可能である．筆者らは，認知症ケアの現場において組織全体で認知症ケアを学び，高度化するための協調学習環境の構築を進めてきた [宗形 17]．本学習環境では，認知症ケア現場で撮影されるケア映像を基に学習を進める (**図 1**).

- 実践：ケアを実践している様子をビデオ撮影 (図中 2)
- 指導：ケア動画に指導データを付与 (図中 3)
- 学習：指導付きケア動画を視聴し学ぶ (図中 4, 5)

連絡先: 小俣敦士，静岡大学創造科学技術大学院，静岡県浜松市中区城北 3-5-1，omata@kirilab.net

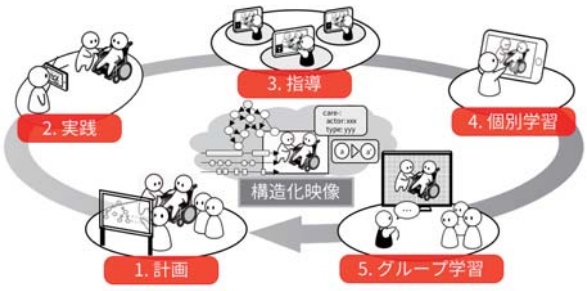


図 1: ケア映像を用いた学びの高度化と知の構造化サイクル

学習者は，ケアのどこに注目すべきか，どのようなことを考えるべきかをといった状況判断能力を養うことや，具体的なスキルを客観的に指摘・アドバイスを受けることができ，スキル向上に効果的である．そして，学びのプロセスを通して取得される多様なデータをケア動画と関連づけることにより，構造化映像としてデータ化することが可能である [小俣 17].

本稿では，上述したスキル習得を支援する枠組みを発展させ，ケア実践の前に，ケア対象者の個性やゴールを検討し，ケアの方針を決めるための計画の場を設計する (**図 1 の 1**).

3. 個性情報に基づくケアの目標設定

私たちは異なる能力や，価値観，社会的な役割を持ち，状況や目的に応じて複数のモデルを切り替えている [Minsky 09]. 認知症の人に関しても，ケアを受ける際の身体的状況や，気分といった心的状況，そしてケアスタッフとの関係性など社会的な側面も影響し，様々なモデル (個性) を切り替えていると考えられる．そのため，各スタッフが日頃ケアを行う中で得たその人に関する知識を，組織やチームで共有し，その人についての理解を深めることがより良いケアを実現する上で役立つ．

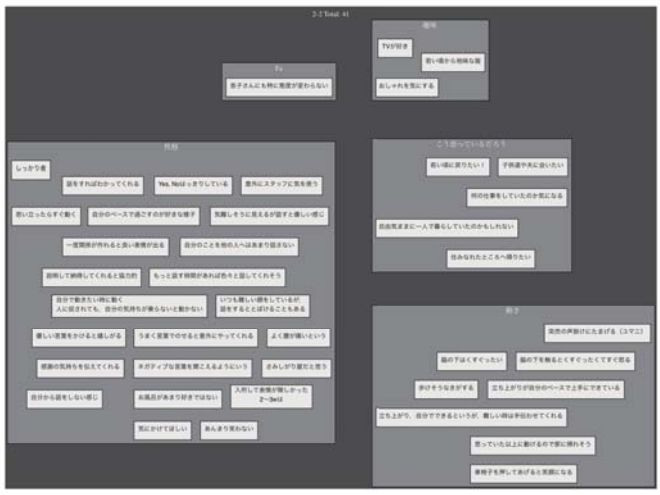


図 2: 個性情報の検討結果の例

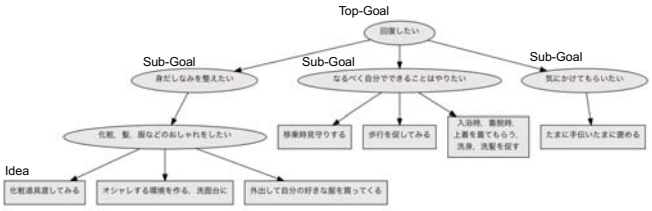


図 3: ゴールと実現可能なケアの検討結果の例

そして，その人がどのようなことを望んでいて，どのような状態を目指すのか，各スタッフが共通の目標を持ちチームとして関わることが重要である．このような観点から，以下のような手続きでグループワークを行いケアの方針を検討する．なお，一名の認知症高齢者の方についてグループワークを実施した際の結果も同時に示す (**図 2**, **図 3**).

1. ブレインストーミング形式で個性，その人らしさ，特徴など個性情報を自由に挙げる (**図 2**)
2. 個性情報をもとに，その人の望んでいること，やりたいことをゴールで表現する (**図 3**)
3. 各ゴールに対して，実現可能なケアを検討する (**図 3**)
4. 実際に実践・撮影するケアを決定する

個性グループワークを実施する際には，可能な限り認知症の人本人や家族も同席してもらい，意見を聞きながら実施するような場を作るようにする．目標をゴールで表現すると複数のゴールの関係性を表現することができ，認知症ケアにおいてはなぜそのケアを行うのかといった行動意図を表現できる．そして，目標を設定したのち，ケアを実践・撮影し，その映像を用いて組織全体で学びを進める．このように，学びをケアを実践する人で閉じるのではなく，同じ場を共有するスタッフ，外部の専門家，認知症の人本人や家族などを巻き込んで，学びを深めることが可能な協調学習環境を持続的に発展させていく．

4. 協調学習環境による学びの効果

福島県の郡山市医療介護病院で協調学習環境の枠組みに基づいて学習を実施した結果について示す．本病院では約 80 人のケアスタッフが所属しており，6〜10 名のグループで学習を進めた．学習前後にケアを実践し，学びの効果を分析した結果を一つの事例を用いて示す．

表 1: 事例情報

ケア対象者	90 代女性
個性情報	みんなと一緒にいるのが好き 社交的な人 お世話をすることが得意 犬を飼っていた 周りの様子をよく観察している 挨拶をすると笑顔で挨拶してくれる 手を握る力が強い 梅酒が好き 息子さんのことは遠くからでもわかる 息子さんととても良い関係　　など
ケアの目標	立って歩く 普段は経管栄養だが口からの食事を楽しむ
実施したケア	おやつの時間にデザートを食べる

まず，学習で対象となった事例の情報を**表 1** に示す。個性グループワークの結果，ケア対象者の方は社交的で，息子さんとの関係が良好であることがわかった．そして，現在の身体機能を伸ばし回復を目指すために,「立って歩く」というゴールと，現在 3 食経管栄養であり，口からの食事を他の人と一緒に楽しめるようになるために,「口からの食事を楽しむ」という目標を設定した．協調学習では「おやつの時間にデザートを食べる」ケアを実践している映像を用いて学習を進めた．約三ヶ月間をかけて，ケア映像に対して指導データを付与し，生成された指導付きケア動画をもとに学習を進め，学習後にも同様のケアを実践した．なお，ケアの実践に対する指導はグループに所属する全スタッフが行い，映像学習についても全スタッフで行った．このように，映像という客観データを用いて，個人の実践経験から組織の学びを深めていく．

学習前後のケアを，スクリプト [Schank 77] という手続き的知識や出来事を表現するための知識表現を用いて比較した結果を**図 4** に示す．筆者らは，認知症ケアにおける様々な状況・場面を，人工知能のモデルを用いて表現するための構造設計を進めており，本稿ではその構造に則ってケアを表現している．ケア映像における，ケアスタッフの行為とケアを受けている認知症高齢者の状態・行為が可視化されており，左から右に向かってケアの流れが表現されている．ケアスタッフの行為に関しては，より抽象的な構造として，認知症ケア技法ユマニチュード [本田 14] の「５つのステップ」を示している．ユマニチュードでは，介入の際の出会いから別れまでのプロセスがモデル化されており，この「５つのステップ」の手順を踏むことで認知症の人との人間関係が形成できると言われている．

- 出会いの準備：相手に自分が来たことを認識してもらうプロセス
- ケアの準備　：関係性を作りケアの合意を得るプロセス
- 知覚の連結　：実際に心地よいケアを行うプロセス
- 感情の固定　：良い時間を過ごせたことを確認するプロセス
- 再会の約束　：次回のケアに繋げるプロセス

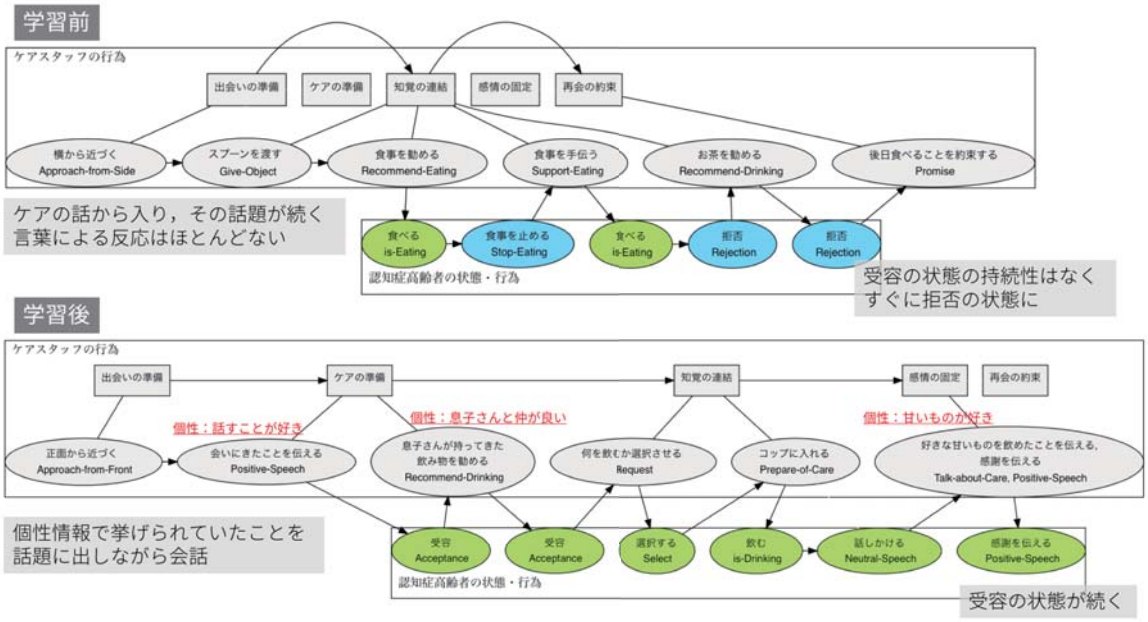


図 4: 学習前後のケアスクリプトの変化

学習前のケアでは，出会ってからスプーンが渡され，その状態のまま食事が促されており，認知症の人は拒否の状態で終わっていることが確認できる．また，ユマニチュードのスキルの観点においても，「ケアの準備」や「感情の固定」が実施されておらず，相手に合意を得ないままケアが実施されていることがわかる．一方で，学習後のケアでは，出会いから会話しながらケアを行い，認知症の人は受容の状態が続いていることが確認できる．また，ユマニチュードのスキルの観点でも，「再会の約束」はないものの，手順を踏んでケアが進行している．個性の観点では，社交的な側面や息子さんとの関係が良いことなど個性情報で挙げられていた内容を話題に出しながら人間関係を構築し，相手からの発話などの自発的な行動を引き出していることが確認できる．この学習前後では，個性グループワークと，実際のケア映像に対して，グループスタッフからの指導が行われた．学習前の映像に対して得られたグループスタッフからのコメントを以下に示す．

- 突然おやつの声掛けになっている
- 視線が合っていない
- いきなりケアの話をしているので，相手のところに行ったらケアの準備として相手との関係性を作ることが大切
- 食べてもらうのではなくてポジティブな人間関係を築くことに目的を立てた方がよりスムーズなケアに結びつく
- 拒否されているので，これ以上やると強制ケアになってしまうので，また次の機会にするとしたのは良い
- まずアイコンタクトをとって，こちらを認識してもらって，そこから関係性が生まれるのでまずは目玉を捉える
- 少し抑揚をつけて，相手に感情が届くように「おいしいねー」とか「いっぱい食べてくれると嬉しいなー」とか，やや大げさな感じで抑揚をつけてポジティブな言葉を選ぶと喜んで食べてくれる可能性があります．

このように，他のスタッフからコメントから，ケアの具体的な改善点やケアの考え方の共有が行われ，ケアスキル向上につながっていることが示された．また，個性に基づき協調的に学習することで，ケアの目標やそのケアを行う意図を共有し，個性に基づくケア実践に繋がることが示唆された．

5. おわりに

本稿では，認知症高齢者の個性に基づくケアのための認知症ケア協調学習環境について述べた．個性やゴールに基づき協調的に学ぶことが，ケアを受ける相手の理解を深めるとともに，ケアを行う際の目標やその意図をチーム全体で共有でき，多様な個性を持った認知症の人に合わせたケア実践につながることが示唆された．今後は，本稿で述べた個性情報やゴールの構造化を進め，協調学習環境の発展と学習効果の評価を進める．

参考文献

[宗形 17] 宗形初枝, 他: 第 31 回人工知能学会全国大会, (2017).

[小俣 17] 小俣敦士, 他: 認知症ケアの内省を促す構造化映像を用いた協調学習環境, 第 8 回高齢社会デザイン研究会, (2017).

[Minsky 09] Minsky, M. 著, 竹林訳:ミンスキー博士の脳の探検-常識・感情・自己とは-, 共立出版, (2009).

[Schank 77] Schank, R. C., et al.: Scripts, plans, goals, and understanding: An inquiry into human knowledge structures., Psychology Press, (1977).

[本田 14] 本田美和子, 他: ユマニチュード入門, 医学書院, (2014).

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

感情思考モデルに基づくマルチモーダル認知症ケア知の共創

Co-production of care knowledge for people with dementia based on an emotion thinking models

石川 翔吾 *1 Shogo Ishikawa　佐々木 勇輝 *1 Yuki Sasaki　桐山 伸也 *1 Shinya Kiriyama　本田 美和子 *2 Miwako Honda　Yves Gineste*3 Yves Gineste
竹林 洋一 *1 Yoichi Takebayashi

*1静岡大学 Shizuoka University　*2東京医療センター Tokyo Medical center　*3Institute Gineste Marescotti Institute Gineste Marescotti

This paper describes a methodology of co-production of care knowledge for people with dementia based on emotion thinking models. Our goal is to construct the AI platform to explain complicated thinking processes in caring. Emotion thinking models are designed to represent knowledge of care experts. The models have multiple representations: “goal”, “trans-frame” and “resourcefulness” on the basis of Minsky’s theory. The result suggests that the representation of thinking process in dementia care leads to encouraging construction of care knowledge.

1. はじめに

筆者らはケアと認知症の人の関係を明らかにする Evidence Based Care (EBC) の実現に向けて認知症の人の情動理解基盤技術の開発を進めている [竹林 15]．ケア従事者のケアスキル，及び認知症の人の情動的行動に着目し，表層的な行動の特徴表現や認知症ケアの評価を行ってきた [石川 15]．認知症ケアは，認知症当事者の身体的，心的状態の評価，変動性への対応，そして認知症当事者の生活の質を高めるためのケアの目的等を考慮した複雑な思考プロセスの結果である．一方でこのような思考プロセスを説明可能なものとして表現する手段が少ないという課題がある．

そこで本稿では，行動評価の仕組みを発展させ，認知症ケアにおける思考プロセスを客観化するための感情思考モデルを構築し，多様な熟達者の意見を集約することで認知症ケア知の構築につながることを示す．

2. マルチモーダル認知症ケアの表現

2.1 認知症ケアにおける感情思考モデルの設計

介護現場では,「優しい」ケア,「尊厳のある」ケアというスーツケースワード（多義的な意味を一つの単語に詰め込むこと）[Minsky 09] で指導されることが多い．筆者らは,「優しさ」や「尊厳」を技術と哲学として具体的に習得可能なものにしたマルチモーダルコミュニケーション技法の ユマニチュード® に着目して,「見る」「話す」「触れる」等の優しさに関するスキルの評価を進めてきた [石川 15]．

一方で，熟達したケア従事者は，本人の尊厳を考慮することを具体的に，１）認知症の人の状態をセンシングし，２）ケアの目標達成のためのプランをその場その場で組み換えながら，臨機応変にスキルを活用している．このような認知症ケアにおける思考プロセスを [本田 17, 石川 15] に基づき，以下の三つの観点から表現することとした．

- 感情的状態：環境要因に対して脆弱な認知症の人が感情的思考を利用しやすい特性から感情的状態としてポジティブ，ネガティブ，ニュートラルな状態を規定する．
- 行動意図：対象の心的・身体的状態を踏まえたゴール設定．
- 知識利用：時系列のケアプロセスのなかでどのように知識を利用したのかを表現する．

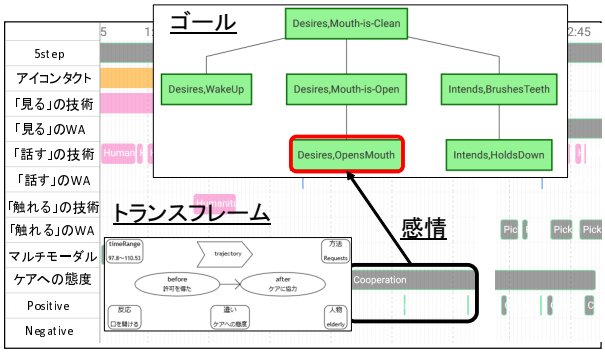


図 1: 口腔ケア場面におけるケアの思考プロセスの表現

本稿では，これらの観点を統合するものを感情思考モデルと呼ぶ．ケア従事者の視点から認知症の人の心の状態を表現することとし，これらのさまざまな思考をマルチモーダルに同時に処理している系として扱う．また，心の状態についての表現系は表 1 の構造を持つ．

2.2 Semantic Primitive の設計と心的状態の表現

[石川 15] で設計した行動レイヤの記述と思考レイヤの記述を接続するための構造として Semantic Primitives を設計した．Semantic Primitives は行為を表現する Action，状態を表現する State，変化を表現する Transition の 3 種類から構成される．一例を表 2 に示す．本 Primitive は思考レイヤを記述するための基本タームとなる．

図 1 では感情思考モデルに基づき口腔ケア場面における思考プロセスを表現している．この場面では，認知症の人がポジティブな状態の時，口腔内を清潔にするというゴールを達成するために，ケアの協力が得られた場面を示している．これらの思考プロセスを表現するために，行動レベルの記述，ルー

連絡先: 石川翔吾，静岡大学，静岡県浜松市中区城北 3-5-1，053-478-1488，ishikawa-s@inf.shizuoka.ac.jp

表 1: 心の状態の表現の一例

Category	構造	意味
感情的状態	Positive :actor :object :action	ACTOR が何に対して positive な ACTION を表現したか
行動意図	Desires :actor :prop	ACTOR は PROP が実現することを望む
	Intends :actor :prop	ACTOR は ACTION を取る計画を持っている
知識利用	Trans-frame :actor :before :after :goal :gap :prop	ACTOR は前後の変化でどの FRAME を利用したのか

表 2: 口腔ケアにおける Semantic Primitives の例

Category	Type	フレーム構造
Action	Look	Looks at Oral :actor :object
	Speech	Requests :actor :object
	Touch	Grasps :actor :object
	Action	is-walking :actor
State	Physical	Mouse-is-Opening :person
		Eyes-are-Closing :person
	Environment	Bed-is-Reclining
Transition	Mental-trans	ToPositive :person
		ToNegative :person
	Physical-trans	LocationChange :person
	Abstract-trans	Attitude :person

ルベースの Semantic primitive の生成，思考プロセスの記述，記述結果の検索・可視化を支援するツールを設計し，認知症ケア知の共創を実現する．

3. 感情思考モデルに基づく認知症ケア知の共創

設計した感情思考モデルに基づき認知症ケア知の共創について検証した．特別養護老人ホームを利用する 2 名の認知症の人（アルツハイマー型認知症）に対してケアを実施した．ビギナーレベルのスタッフ，ユマニチュードインストラクターの映像事例 2 事例を評価対象とした．ユマニチュードインストラクター 6 名が個別に映像事例を視聴し，提示されたベースデータに対して追加・修正点として意見が集約された．

図 2 はビギナーレベルのスタッフの口腔ケア映像に対して，ゴールの観点から意見を集約した結果である．口腔ケアをする際に口を開けることを促す行為に対し，合図をして，押さえて，催促し，指示するという意図があったことがサブゴールとして追加された．また，「口腔ケアをしやすくしたい」というゴールが表現されていたが，同じ人に対するケアの類似事例を参照しながら映像を視聴することで，全てのインストラクターがこのゴールの表現は適切ではないという結果が得られた．

図 3 はインストラクターによる移乗ケア映像に対して，どのように考えていたのかを集約した結果である．感情の状態がネガティブからポジティブに遷移した中で，高齢者の身体的状態をセンシングしながらケアの中で elderly frame の slot を修正している．また，インストラクターは立つ力を確認するために，事故を予防して膝を支え，一連の流れで自然に歩く行為に移れるように促し，万一の場合にすぐに座れるようにケアしているという意見がゴールに集約された．

このように，変化，状態，意図という観点から構築した感情

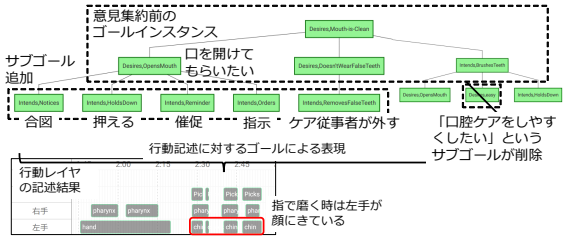


図 2: ケア熟達者の意見集約による初学者の行動意図の表現

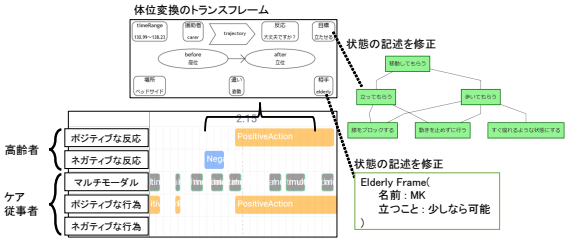


図 3: ケア熟達者の意見集約による熟達者のケアプロセスの表現

思考モデルによって，熟達者の意見が集約され，認知症ケア知の共創につながることが示された．

4. おわりに

本稿では，感情思考モデルを機軸とした共創システムによって，ドメインエキスパートの意見が集約され，認知症ケア知の再構造化が促進されることを示した．今後も思考の表現を深化させるために Interior grounding[Minsky 09] を進め，一見単純にみえる現象が複雑であることを示すための情動理解基盤技術の開発を進める．

参考文献

[本田 17] 本田，他：ユマニチュードの Evidence-Based Care の実現に向けたマルチモーダルコミュニケーションの評価，第 31 回人工知能学会全国大会，1I3-NFC-02b-2in1 (2017).

[石川 15] 石川，竹林: エビデンスを生み出す認知症情報学－情動理解基盤技術とコミュニケーション支援－，人工知能学会誌，32(1), pp.103-110 (2017).

[Minsky 09] Minsky, M. 著, 竹林訳：ミンスキー博士の脳の探検－常識・感情・自己とは－, 共立出版, 東京 (2009).

[竹林 15] 竹林：認知症の人の暮らしをアシストする人工知能技術，人工知能学会誌, 29(5), pp.515-523 (2014).

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

骨格検出とベッド位置検出の組合せによる患者の端座位推定に関する初期検討

Patient's sitting position estimation using skeleton information and bed position detection

井上　円[*1,2]
Madoka Inoue

田口　亮[*2]
Ryo Taguchi

梅崎　太造[*2,3]
Taizo Umezaki

[*1] アイホン株式会社
AIPHONE CO., LTD.

[*2] 名古屋工業大学
Nagoya Institute of Technology

[*3] 東京大学
The University of Tokyo

The work of a nurse in charge of nursing of a hospitalized patient is a task that leads to a serious accident with a single mistake or overlook, so nurses are exposed to high stress. In particular, the three items of medication, tube connection, and fall are factors that lead to serious accidents and are considered to be a major load factor of nursing work. In order to reduce the burden of nursing work, we estimated the sitting posture, which is the initial posture of the patient's lifting motion, using the camera image. In this study, as an initial study of the study, we estimated the patient's sitting position by combining the detection result of the skeleton position of the patient, the detection result of the bed position and the integrated processing of them. As a result of the evaluation, the end sitting position was identified with an accuracy of 98.6 [%].

1. はじめに

入院患者の看護を担当する看護師の業務は，ひとつのミスや見逃しが重大な事故に繋がる業務であり，看護師は高いストレスに晒されている．とりわけ，注射・予薬，チューブ接続，転倒転落の 3 項目は重大な事故に繋がる要因であり，看護業務の大きな負荷要因とされている．

これまで我々は，看護業務の負荷を低減する為に，画像センシング技術を用いて，事故原因の主要 3 項目の一つである転倒転落に対する未然防止を検討してきた．その中で，転倒事故は就寝中の患者がトイレに行く過程で多発するという理解を得た．そこ本研究は，事故防止の手段として，患者の離床動作における特定の姿勢である端座位を推定する．なお，用語の定義として，患者の就寝姿勢を臥位（がい）とし，患者が足を地面に着けてベッド端に座る姿勢を端座位（たんざい）とする．

本稿で用いる情報は全て病室に設置した単眼カメラデバイスから得られた可視画像の情報とする．近年デプスセンサが普及しており，空間内の情報を捕捉する有効な手段とされている．その様な背景において，我々がカメラデバイスを用いる理由は二つある．理由の一つは，入院患者は音や光に過敏に反応する為，デプスセンサを導入する事で内蔵の近赤外光が患者のストレス源となる事を避ける為である．もう一つの理由は，導入コストである．ステレオカメラを用いた場合，デプスセンサと等価の空間情報を捕捉する事が出来るが，製品にカメラモジュールを 2 個搭載する必要があり製品単価が上昇する．国内の大規模病院は 500 床を超える為，デバイス単価の上昇はシステム全体のコストに影響する．計算処理を工夫し単眼カメラで所望の機能を実現する事で，システム全体のコストダウンに寄与する．

本項では，研究の初期検討として，患者の骨格位置の検出結果と，ベッド位置の検出結果を組み合わせ，患者の端座位を推定する．

連絡先：井上　円，アイホン株式会社　技術本部　技術開発部　第二開発課，〒456-8666 名古屋市熱田区神野町 2-18，madoka_inoue@aiphone.co.jp

2. 提案手法

2.1 骨格検出

骨格検出には，Cao らの二次元画像の姿勢推定手法[Cao 2017]を用いる．深層学習の各チャネルで部位毎の検出を行い，部位の関連度を算出する．更に各部位と部位の関連度に基づいて，部位同士をつなぎ合わせる事で骨格を抽出する．

2.2 ベッド位置検出

可視画像からベッド位置を検出する代表的な手法は，線分をヒューリスティックに組み合わせる手法[Kittipanya-Ngam 2012] [岡田 2015] や画像特徴と機械学習を組み合わせた手法 [井上 2018] が存在する．ただし，ヒューリスティックな手法は，製品の長期供給を考慮した場合に，製品の設計変更が生じた際にパラメータの再検討が必要となるリスクを含む．従って，本稿では



Fig. 1. Bed shapes of input images

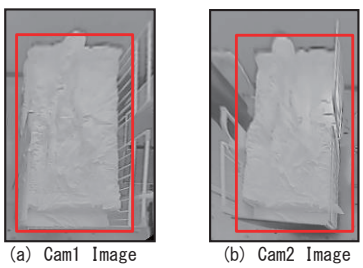


Fig. 2. Bed shapes of IMP images

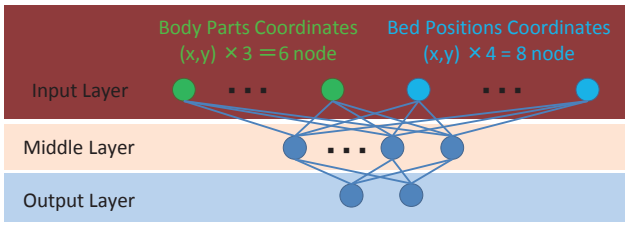


Fig. 3. Overview of network

画像特徴と機械学習による手法を用いる.

提案手法は, 入力画像をベッドサイズ程度の着目領域で走査する. 着目領域毎の処理は, 領域内の輝度情報を用いて HOG 特徴を抽出し, SVM 識別器を用いて HOG 特徴に対する尤度判定を行う. 尤度判定の結果が事前に設定した閾値以上であれば着目領域をベッドと判定し, 着目領域の位置からベッド座標を算出する. ただし, 画像に記録されるベッド形状は, 透視投影変換の原理上, 図 1 に示す様にカメラとベッドの位置関係に応じて様々な四角形となる. この様にカメラ位置に応じて形状のばらつきが生じるベッド画像を HOG 特徴で抽出した場合, 画像特徴の出力値が発散する為にベッドを正しく検出する事が出来ない. そこで, 特徴抽出の前処理として入力画像に逆射影変換 [Kim 2002] 処理を施す. 予め入力画像に対してレンズ歪を補正する処理を行い, 歪補整後の画像に対して視点変換を用いて視点を室内の鉛直上方向に置き換える鳥瞰図を生成して用いる事で, 設置エリア内のどの位置に取り付けられたカメラを使用しても, 図 2 に示す様な長方形のベッド形状を得る.

2.3 端座位推定

初期検討として, 3 層ニューラルネットワークを用いて端座位の推定を行う. 入力値は, 骨格の検出結果座標と, ベッド位置の検出結果の座標情報用いる. Cao らの骨格推定では部位情報として体の 18 点の座標が得られるが, 本手法では座位の推定に必要な首・右骨盤・左骨盤の 3 点の座標情報を用いる. また, ベッド位置はベッド検出処理により得られたベッド隅 4 点の座標を入力とする. 出力層はノード数 2 の 2 クラス分類問題として解く. ネットワークの概略を図 3 に示す.

3. 実験

3.1 実験データ

病院環境を模擬したシミュレーション環境を構築し, ベッド頭部壁面の 8 か所に設置したカメラを用いて, 実験協力者 5 名の臥位から端坐位に遷移し, 室外に退出する一連の動作を 5[fps]で 3888 データ収集した. 本実験では, 撮影データから端坐位シーンの静止画を 7832 枚, 端坐位以外の姿勢を 7900 枚使用する. なお, 実験協力者に対しては実験の目的やデータの用途, 作業の内容, ならびに個人情報の取り扱いについて十分な説明を行い, 同意書を取り交わした.

3.2 端座位の推定精度評価

学習データに対して, 骨格とベッド位置の検出を行う. 一例として骨格とベッド位置の検出結果サンプルを図 4 に示す. 次に, 各々の結果座標を取得し, 両者の座標を画像毎に統合した実験用入力座標データを作成する. 続いて, 学習課程として実験用入力座標データの 90[%]を用いてネットワークのパラメータを学習する. 最後に, 得られたネットワークパラメータについて, 実験用入力座標データの残り 10[%]で推論を行い, 識別精度を調べる.

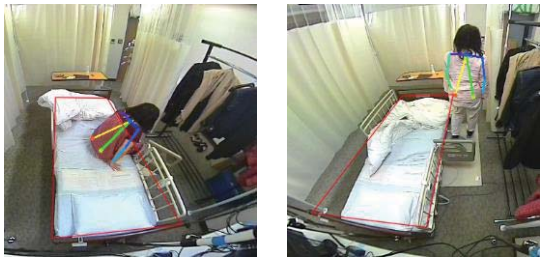


Fig. 4. Results of Pose and Bed Detection

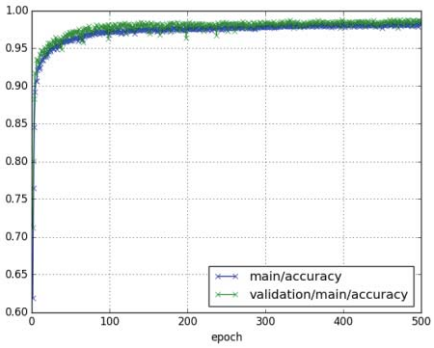


Fig. 5. Learning Curve

なお実験条件として各層のノード数は, 入力層を 14, 中間層を 10, 出力層を2と設定した. 学習繰り返し回数は 500 とした.

3.3 実験結果

評価データに対して 98.6[%]の精度で端坐位とその他の動作を正しく識別した. 実験の学習曲線を図 5 に占めす.

4. まとめ

安価なデバイスを用いた看護業務の負荷低減策として, カメラ映像と機械学習を組み合わせて患者の端座位を識別する手法を提案した. 骨格とベッド位置の検出結果に統合処理を加える事で, 患者の端座位とその他の動作を 98.6[%]の精度で識別した. 今後, 更なる精度向上と, 一連の処理を統合したアルゴリズムを検討したい.

参考文献

[Cao 2017] Cao, Z., Simon, T., Wei, S. E., & Sheikh, Y.: Realtime multi-person 2d pose estimation using part affinity fields, In *IEEE Conference on Computer Vision and Pattern Recognition*, 2017.

[Kittipanya-Ngam 2012] Kittipanya-Ngam, P., Guat, O. S., and Lung, E. H.: Bed detection for monitoring system in hospital wards, In *IEEE Proc.34th Annual Conf. Engineering in Medicine and Biology Society*, 2012.

[岡田 2015] 岡田康貴, 村下君高: 医療現場での運用に即したベッド領域認識技術の開発, 精密工学会誌 Vol.81 No. 12, 2015.

[井上 2018] 井上 円, 安井 俊之, 田口 亮, 梅崎 太造: 患者みまもりの自働化に向けたベッド位置の検出, 電気論文 C Vol.138 No.6, 2018.

[Kim 2002] Kim, D. K., Jang, B. T., & Hwang, C. J.: A planar perspective image matching using point correspondences and rectangle-to-quadrilateral mapping, In *Image Analysis and Interpretation, 2002. Proceedings. Fifth IEEE Southwest Symposium on*, 2002.

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

Accurate drowsiness estimation via eye-related movements: a neural-network-based investigation

Mingfei Sun*1 Masanori Tsujikawa*2 Yoshifumi Onishi*2 Xiaojuan Ma*1
Atsushi Nishino*3 Satoshi Hashimoto*3

*1 Department of Computer Science & Engineering, Hong Kong University of Science and Technology
*2 Data Science Research Laboratories, NEC Corporation
*3 Technology and Innovation Center, DAIKIN Industries, LTD

Many studies reported eye-related movements, e.g., eye blink and eyelid drooping, are highly indicative symptoms of drowsiness. However, few has investigated the computational efficacy for drowsiness estimation accounted by these movements. This paper thus analyzes two typical movements: eyelid movements $X_{el}(t)$ and eyeball movements $X_{eb}(t)$, and investigates different neural-network modelings: CNN-Net and CNN-LSTM-Net. Experimental results show that using joint movements can achieve better performances than eyelid movements for short time drowsiness estimation while using eyeball movements alone perform worse even than the baseline (PERCLOS method). In addition, the CNN-Net is more effective for accurate drowsiness level estimation than the CNN-LSTM-Net.

1. INTRODUCTION

Drowsiness has been studied for years in fatigue risk management and vigilance monitoring. Psychological studies have demonstrated that the drowsiness can significantly impair productivity and deteriorate the quality of work outcomes. For example, drowsy driving, usually caused by sleep loss, night or long-time working [Dinges and Grace, 1998], is reported as one of the main causes of serious accidents [Akbar et al., 2017, Reddy et al., 2017]. On the another hand, if drowsiness can be effectively estimated, the aforementioned side effects might be significantly mitigated or avoided. Studies showed that accurate driver drowsiness estimation can help prevent potential accidents caused by driving fatigue [Dinges and Grace, 1998]. Also, research on Massive Open Online Courses (MOOC) demonstrated that the learning outcomes can be greatly improved by taking measures based on students' estimated level of drowsiness [Kim et al., 2017].

Eye-related movements, e.g., eyelid movements and eyeball movements, are reported to be important and useful for accurate drowsiness estimation by previous studies [Zhu et al., 2014, Wierwille et al., 1994, Dinges and Grace, 1998]. However, few has tried to further differentiate the role played by different types of eye movements. Basically, there are two types of eye-related movements: eyelid movement $X_{el}(t)$ and eyeball movement $X_{eb}(t)$. Technical investigation of these two types of eye movements is non-trivial since it requires accurate extractions of eyelid movements and eyeball movements. Furthermore, although many neural-network-based temporal modelings, e.g., CNN and LSTM, are proposed for modeling these eye-related movements, an insightful comparison is still in need.

Contact: Mingfei Sun, CSE Department at HKUST, Hong Kong, (+852) 5224 9330, mingfei.sun@ust.hk

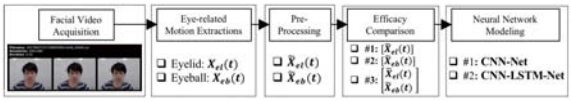


Figure 1: The proposed investigation pipeline

In this paper, we conduct a systematic analysis of two types of eye-related movements for drowsiness estimation. The contributions of this paper are as follows. First, we analyze the computational efficacy of eyelid movements and eyeball movements for drowsiness estimation. Second, we propose and compare two neural networks for modeling temporal correlations of eye-related movements. Third, we conduct multiple experiments and present insightful interpretations as well as discussions for experimental results. Empirical evaluation shows that the proposed neural network models are effective, and the combined eye-related movements are more effective than eyelid movements for short time drowsiness estimation, while eyeball movements alone fail to deliver good results. In addition, as drowsiness period extends, CNN-Net performs increasingly better than CNN-LSTM-Net for drowsiness level prediction.

2. METHOD

The overview of our proposed method is shown in Fig. 1.

2.1 Facial Video Acquisition

The facial video data were collected from 29 subjects with their informed consent in a local laboratory and then labeled with 3 professional annotators. First, 29 subjects were asked to finish a specific math task while seated in front of a display with a web camera placed on top. The facial videos ($640 * 480$, 30fps) were captured by a web camera when subjects were performing the task, which finally adds up to $205,600$s ($\sim$ 57h). Then, 3 professional annotators rated every 10 seconds (without overlapping) of facial videos with

3Pin1-49

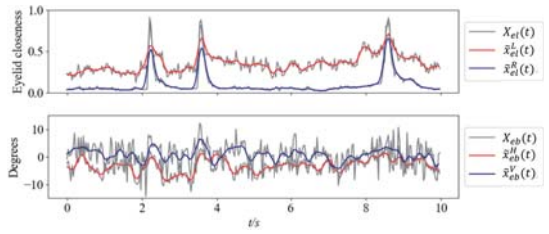


Figure 2: Filtering & down-sampling of eyelid (top) and eyeball (bottom) movements

5 drowsiness levels according [Zilberg et al., 2007]. The averaged label values is used as the ground truth.

2.2 Motion Extraction & Pre-processing

Eye-related motion extraction: The eyelid movements $X_{el}(t)$ and eyeball movements $X_{eb}(t)$ are extracted by an accurate facial analysis tool developed by NEC corporation. Specifically, $X_{el}(t) = \left[x_{el}^{L}(t), x_{el}^{R}(t)\right]$ where $x_{el}^{L}(t)$ and $x_{el}^{R}(t) \in [0, 1]$ represent left and right eyelid closenesses with 0 denoting fully open and 1 fully closed. Meanwhile,$X_{eb}(t) = \left[x_{eb}^{H}(t), x_{eb}^{V}(t)\right]$ where $x_{eb}^{H}(t)$ and $x_{eb}^{V}(t) \in [-30, 30]$ denote vertical and horizontal degrees of eyeball movements.

Pre-processing: The Hamming filter (window size 11) is applied separately to $X_{el}(t)$ and $X_{eb}(t)$ to remove high frequency noises, as shown in Fig. 2 where $X'_{el}(t) = \left[x'^{L}_{el}(t), x'^{R}_{el}(t)\right]$, $X'_{eb}(t) = \left[x'^{L}_{eb}(t), x'^{R}_{eb}(t)\right]$ and $x'(t) = H\big(x(t)\big)$. The filtered $X'_{el}(t)$ and $X'_{eb}(t)$ are then down-sampled to 15 points per second, i.e., $X'_{el_d}(t) = X'_{el}(t)$ and $X'_{eb_d}(t_d) = X'_{eb}(t)$, in order to remove redundancies. In addition, according to the Rectified Linear Unit (ReLU) used in neural networks, the input data are further shifted and scaled to be non-negative based on the degree ranges, i.e., $\tilde{x}_{eb}(t) = \left[x'_{eb_d}(t) + 30\right]/60$, while $x'^{L}_{el_d}(t)$ are kept $x'^{R}_{el_d}(t)$ the same, $\tilde{x}_{el}(t) = x'_{el_d}(t)$.

2.3 Efficacy Comparison & Neural Network Modeling

To compare the efficacy of different eye-related movements for drowsiness estimation, we apply a same neural network model, i.e., CNN-LSTM-Net as shown in Fig 3(a), to three different combinations of eyelid and eyeball movements: $\left[\tilde{X}_{el}(t)\right]$, $\left[\tilde{X}_{eb}(t)\right]$ and $\left[\tilde{X}_{el}(t), \tilde{X}_{eb}(t)\right]$. Then three combinations of eye-related movements are input as features, i.e., $\left[\tilde{X}_{el}(t)\right]$, $\left[\tilde{X}_{eb}(t)\right]$ and $\left[\tilde{X}_{el}(t), \tilde{X}_{eb}(t)\right]$. For joint movement feature $\left[\tilde{X}_{el}(t), \tilde{X}_{eb}(t)\right]$, the $\tilde{X}_{el}(t)$ and $\tilde{X}_{eb}(t)$ are processed separately by CNN part before being concatenated into LSTM part.

Another neural network structure, i.e., CNN-Net as shown in Fig 3(b), can also be applied to estimate drowsiness from eye-related movements [Zhu et al., 2014]. Different from CNN-LSTM-Net, CNN-Net structure only exploits convolution layers without LSTM layers. In the proposed CNN-Net, we use a similar CNN structure as that in CNN-LSTM-Net. Instead of the LSTM layer, we adopt a global pooling layer to compare every sequence segment to obtain the max value, which are then fully connected to output the drowsiness labels.

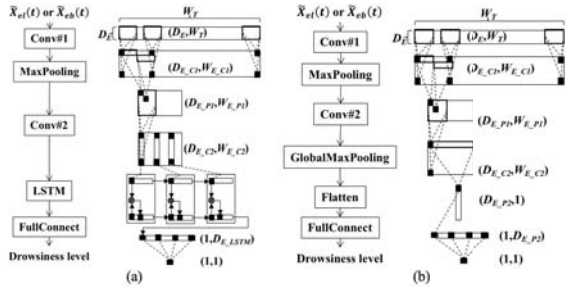


Figure 3: (a) CNN-LSTM-Net; (b) CNN-Net

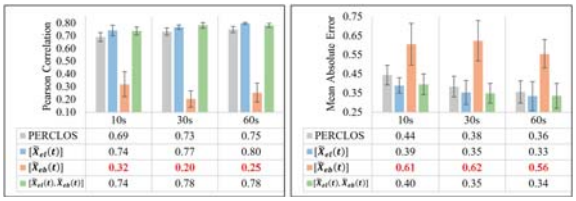


Figure 4: Modeling eyelid movements and eyeball movements by CNN-LSTM-Net along different time periods

3. EXPERIMENT RESULTS

The experiments are conducted on the facial video dataset with two common regression performance metrics: Pearson Correlation coefficient and Mean Absolute Error (MAE). Specifically, the evaluation dataset is randomly divided into five groups based on participants to remove the subject-dependences, and the cross validation adopts leave-one-group-out strategy with the PERCLOS method [Dinges and Grace, 1998] as the baseline. The training is conducted on the Nvidia 1080 (8GB memory) graphic card (batch size 128, epoch 100), and an early stop checker was also set to reduce the training time accordingly. The Adam optimizer ($lr = 0.001$) was used with learning rate decaying to 0.0001 and 0.00001 after 20 and 50 epochs respectively.

3.1 Efficacy comparison

The importance is compared between $\left[\tilde{X}_{el}(t)\right]$, $\left[\tilde{X}_{eb}(t)\right]$ and $\left[\tilde{X}_{el}(t), \tilde{X}_{eb}(t)\right]$. From Fig. 4, it is notable that using $\left[\tilde{X}_{eb}(t)\right]$ to estimate drowsiness fails to deliver good results, worse even than the baseline (PERCLOS) performances: the Pearson Correlation values < 0.4 indicates the estimated drowsiness levels and the ground truth labels are weakly correlated; the Mean Absolute Error(MAE) values are all around 0.6, which are almost two times of the MAEs achieved by PERCLOS method. In the meanwhile, $\left[\tilde{X}_{el}(t)\right]$ and $\left[\tilde{X}_{el}(t), \tilde{X}_{eb}(t)\right]$ both perform almost equally better than the PERCLOS. As a summary, the eyeball movements alone are not an effective feature for drowsiness estimation while eyelid movements or eyelid movements combined with eyeball movements are strongly related to drowsiness status.

The underlying reasons that eyeball movements alone fail

3Pin1-49

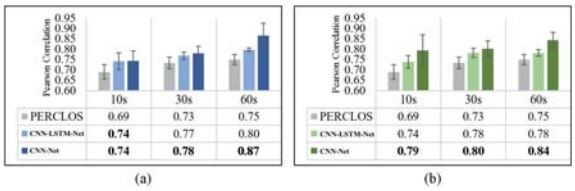


Figure 5: CNN-LSTM-Net vs. CNN-Net for drowsiness estimation using (a) eyelid movements; (b)joint movements

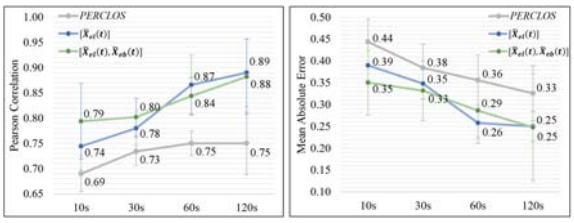


Figure 6: CNN-Net modeling of eyelid and joint movements

to capture the drowsiness levels may possibly be due to the following phenomenon: when a person feels sleepy, his/her eye gazes will not move too much, usually fixed on a point, which, from the eyeball movement's perspective, is exactly the same as the person is fixating his/her eye gazes when he/she is awake. In the following experiments, the eyeball movements will not be considered again.

3.2 Neural network modeling

The eyelid movement data and the joint movement data are input separately into the CNN-LSTM-Net and CNN-Net. From the results, as shown in Fig 5, the CNN-Net can deliver better performances than CNN-LSTM-Net. For eyelid movements, CNN-Net produces better results as drowsiness video time increases, while for the joint movements, CNN-Net consistently beats CNN-LSTM-Net for multiple video lengths. Thus, for drowsiness estimation, CNN-Net modeling is more preferable.

We proposed one possible interpretation of why CNN-Net beats CNN-LSTM-Net. For CNN-Net structure, it is naturally good at spotting short-time correlations due to its fixed-sized (usually small) filters. For CNN-LSTM-Net, however, it mainly captures the long-term temporal correlations among eye-related movements since the LSTM structure is designed to automatically "remembering" information flows along many time steps. In drowsiness estimation, most of the drowsiness levels are actually showed by instant body signals, e.g., a quick eye drooping, which possibly indicates that the short-term eye-related movements may be more important than the long-term eye movements. Consequently, the CNN-Net modeling (short-term) performs better than CNN-LSTM-Net modeling (long-term).

Furthermore, we compare the eyelid and joint movements along different time periods by CNN-Net modeling, as shown in Fig 6. The results show that the joint movements $[\tilde{X}_{el}, \tilde{X}_{eb}]$ deliver slightly better results for short time drowsiness estimation while eyelid movements alone increasingly achieves comparable or even better results as time increases.

4. CONCLUSION

To conclude, two very typical eye-related movements, eyelid movements $\tilde{X}_{el}$ and eyeball movements $\tilde{X}_{eb}$, are analyzed for drowsiness estimation. Also, two very typical neural network structure, i.e., CNN-Net and CNN-LSTM-Net, are investigated for eye-related movement modelings. The empirical evaluation shows that the eyelid movements alone $[\tilde{X}_{el}]$ as well as the joint movements $[\tilde{X}_{el}, \tilde{X}_{eb}]$ are effective for accurate drowsiness estimation while eyeball movements alone cannot deliver good performance. Moreover, the experimental results demonstrate that the CNN-Net is more effective than the CNN-LSTM-Net for eye-related movement modeling due to the possible short-term temporal correlations. In addition, we also find that the joint movements can be more useful for short time drowsiness estimation while eyelid movements alone can also produce comparable performance for long time drowsiness estimation.

References

[Akbar et al., 2017] Akbar, I. A., Rumagit, A. M., Utsunomiya, M., Morie, T., and Igasaki, T. (2017). Three drowsiness categories assessment by electroencephalogram in driving simulator environment. In *EMBC 2017, Conference of the IEEE*, pages 2904–2907. IEEE.

[Dinges and Grace, 1998] Dinges, D. F. and Grace, R. (1998). Perclos: A valid psychophysiological measure of alertness as assessed by psychomotor vigilance. *Federal Highway Administration*.

[Kim et al., 2017] Kim, H. Y., Kim, B., Lee, J., and Kim, J. (2017). Hey, wake up: Come along with the artificial learning companion to the e-learner's outcomes high! In *Proceedings of CHI 2017*, pages 1763–1770. ACM.

[Reddy et al., 2017] Reddy, B., Kim, Y.-H., Yun, S., Seo, C., and Jang, J. (2017). Real-time driver drowsiness detection for embedded system using model compression of deep neural networks. In *CVPRW, 2017 IEEE Conference on*, pages 438–445. IEEE.

[Wierwille et al., 1994] Wierwille, W. W., Wreggit, S., Kirn, C., Ellsworth, L., and Fairbanks, R. (1994). Research on vehicle-based driver status/performance monitoring. Technical report.

[Zhu et al., 2014] Zhu, X., Zheng, W.-L., Lu, B.-L., Chen, X., Chen, S., and Wang, C. (2014). Eog-based drowsiness detection using convolutional neural networks. In *IJCNN*, pages 128–134.

[Zilberg et al., 2007] Zilberg, E., Xu, Z. M., Burton, D., Karrar, M., and Lal, S. (2007). Methodology and initial analysis results for development of non-invasive and hybrid driver drowsiness detection systems. In *AusWireless 2007. The 2nd International Conference on*, pages 16–16. IEEE.

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

アセスメントデータを利用した要介護度の推定

Estimating nursing care necessity degree using by assessment information

小林　秀[*1]　Shu Kobayashi
平田 佐智子[*1]　Sachiko Hirata-Mogi
福田升二[*1]　Shoji Fukuda

[*1] 株式会社エス・エム・エス
SMS Co. ,Ltd.

Expense on elderly care is increasing more rapidly than other expense on social security benefits. To Operate long-term care insurance system, improving operating efficiency is the critical issue. Especially, we focused on assessment of nursing care necessity degree that is the first step of long-term care insurance system. Assessment productivity will improve by assessing nursing care necessity degree periodically, objectively and automatically as possible. In this paper, we created nursing care necessity degree classify model using by assessment data for planning care-plan, and analyzed mis-classify trends.We found assessment data for planning care-plan are also useful information on assessing nursing care necessity degree, and there is possibility of improving assessment productivity.

1. はじめに

本稿では要介護認定の自動化を目標として，介護アセスメントデータを利用して要介護度の推定モデルの構築を行い，誤判別の傾向を分析のうえ，その実施上の課題を検討する．

近年，社会保障給付費は増加の一途を辿っており，[財務省 2015]の資料によれば，2000 年には 78. 1 兆円であったものが，2012 年には 109. 5 兆円となり，2025 年には 148. 9 兆円に達すると見込まれている．2000 年時点では医療と年金の総額が 67. 2 兆円に対して，介護は 3. 3 兆円であった．これが，2012 年時点では 8. 4 兆円となり，2025 年には 19. 8 兆円に達すると見込まれている．このうち，2012 年から 2025 年にかけては，介護に関する給付費の増加率は 2. 3 倍となっており医療の 1. 5 倍に比べても顕著な増加が見込まれている．

介護保険制度は 1997(平成 9)年 12 月に「介護保険法」が制定され，2000(平成 12)年 4 月から施行されている．介護保険は 40 歳になった月から全ての人が加入することになり，介護保険料の支払い義務が発生する．65 歳以上は「第 1 号被保険者」，40 歳から 64 歳までは「第 2 号被保険者」にあたる．このうち，第 1 号被保険者は，介護が必要であると認定を受けると，その程度によって日常生活の支援者や介護のサポート(以下介護サービス)を受ける際に介護給付を受けることができる．

介護給付を受けるためには，要介護度認定と呼ばれる介護サービスの利用者がどの程度介護サービスを必要としているかの目安となる基準の審査を受ける必要がある．審査のためには申込みを行い，全国共通の認定調査書を使った訪問調査が行われ，コンピュータによる機械的な 1 次判定が行われる．[厚生労働省 2012]認定調査員テキスト 2009 改訂版には調査項目が掲載されており，この一部を図 1 に示す．訪問調査では 74 項目について評価を行い，さらに特記事項について調査を行う．その後，機械的なアルゴリズムにより得られた 1 次判定の結果をもとに，保険医療・福祉の専門家で構成される「介護認定審査会」が 2 次判定を行い，判定結果を市区町村に通知する．認定を受けると各市区町村の指定を受けた事業者の介護支援専門家(ケアマネージャ)が介護サービス計画書(ケアプラン)を作成し，それにしたがってサービスが実施される．


認定調査票（基本調査）

1-1 麻痺等の有無について、あてはまる番号すべてに○印をつけてください。（複数回答可）
1. ない　2. 左上肢　3. 右上肢　4. 左下肢　5. 右下肢　6. その他（四肢の欠損）

1-2 拘縮の有無について、あてはまる番号すべてに○印をつけてください。（複数回答可）
1. ない　2. 肩関節　3. 股関節　4. 膝関節　5. その他(四肢の欠損)

1-3 寝返りについて、あてはまる番号に一つだけ○印をつけてください。
1. つかまらないでできる　2. 何かにつかまればできる　3. できない

1-4 起き上がりについて、あてはまる番号に一つだけ○印をつけてください。
1. つかまらないでできる　2. 何かにつかまればできる　3. できない

1-5 座位保持について、あてはまる番号に一つだけ○印をつけてください。
1. できる　2. 自分の手で支えればできる　3. 支えてもらえればできる　4. できない

1-6 両足での立位保持について、あてはまる番号に一つだけ○印をつけてください。
1. 支えなしでできる　2. 何か支えがあればできる　3. できない

1-7 歩行について、あてはまる番号に一つだけ○印をつけてください。
1. つかまらないでできる　2. 何かにつかまればできる　3. できない

1-8 立ち上がりについて、あてはまる番号に一つだけ○印をつけてください。
1. つかまらないでできる　2. 何かにつかまればできる　3. できない

1-9 片足での立位保持について、あてはまる番号に一つだけ○印をつけてください。
1. 支えなしでできる　2. 何か支えがあればできる　3. できない

1-10 洗身について、あてはまる番号に一つだけ○印をつけてください。
1. 介助されていない　2. 一部介助　3. 全介助　4. 行っていない

図 1. 認定調査表（一部）

要介護度には，要介護への進行を予防する「要支援」と介護を必要とする状態である「要介護」に分かれており，「要支援」はさらに 2 段階．「要介護」は 5 段階に分かれている．要介護度によって給付限度額が分かれており，「要支援 1」の月額 5 万 30 円から「要介護 5」では 36 万 650 円と大きく金額差がある．要介護度は，初回の認定では一般的な場合には 6 ヶ月間が有効期間であり，以降の更新後は 12 ヶ月が有効期間となっている．

コンピュータによる 1 次判定は機械的に導出されるものの，保健・医療・福祉の学識経験者により構成される介護認定審査会により，一次判定結果，主治医意見書等に基づき審査判定（二次判定）を行う．[厚生労働省 2012] 介護認定審査会委員テキストには 1 次判定の具体的な流れや，1 次判定結果から変更さ

連絡先：小林　秀，株式会社エス・エム・エス，
shu-kobayashi@bm-sms.co.jp
** 本研究の内容は株式会社エス・エム・エスの公式見解を示すものではありません

れやすい認定調査票上の調査結果について記載があり，機械的に実施可能な要因や現在の調査項目以外の要因によっても 1 次判定結果が修正される可能性がある．

そこで，本研究ではまず，ケアプラン作成のために一定頻度で実施される 1 次判定に使用される項目以外の評価項目を含んだアセスメントの結果と要介護度の関係を比較することでその対応関係が実態としてどのようになっているかを把握する．そして，予測と実態の乖離要因を比較することで，アセスメントデータによる要介護度判定の代替可能性の検討を行った．この結果を用いることで，定期的な要介護度の見直しや 2 次審査での要介護度の補正が発生しやすいと考えられる利用者の事前抽出が実施可能となり，要介護度判定業務の業務負担低減が可能になるものと考えられる．

2. 従来研究

一般に，要介護度に大きな影響を与える要因としてサービス利用者の ADL(Activity of daily life)に関する具合が挙げられる．要介護度の推定にあたり，ADL 調査項目がどのように影響を与えているか[川越 2017]により，医学的検知からの研究が見られる．

現在の介護保険制度上の要介護度の 1 次判定に関して、その判定ロジックの妥当性については，[関 2000]らによって検証がなされている．一方で 2 次判定に関連するものとして，疾患と要介護度の関連については，例えば介護保険の新規認定者において，要介護度が重度となるような原因疾病の特定について，[高橋 2017]らにより，主治医意見書に記載された疾患名のうち，脳血管疾患，悪性新生物が要介護度 2 をこえるような重度の要介護度に関連することが述べられている．

以上のような研究は見られるものの，情報学的な観点から大量のデータを利用して，要介護認定に使用される調査項目以外も対象とした分析事例や，なかでもアセスメントの結果と要介護度の関連に関して，何らかの分析を行った事例は見られなかった．

3. 分析のアプローチ

3.1 分析データの概要

本稿では，エス・エム・エスが運営する介護事業者向けサービスである「カイポケ」のデータを利用した．このデータ概要を表 1 に示す．

表 1. 分析データの概要

対象データ	2011 年以降のカイポケ上でのアセスメント機能使用対象者
分析データ	同一サービス利用者に対する複数回のアセスメントを含む延べ 963，409 件
アセスメント方式	全社協方式準拠 必須絞込版（帳票 3 ページ） 全項目版（全社協方式準拠/帳票 11 ページ） ※いずれも厚労省（老企第 29 号）の提示する課題分析標準項目は網羅

3.2 分析アプローチの全体像

本稿で実施するアプローチでは大きく 4 つのステップが存在する．この概要を図 2 に示す．分析にあたり，データ処理やモデル構築には AmazonWebService 上に環境を準備のうえ，統計処理には R を利用した．

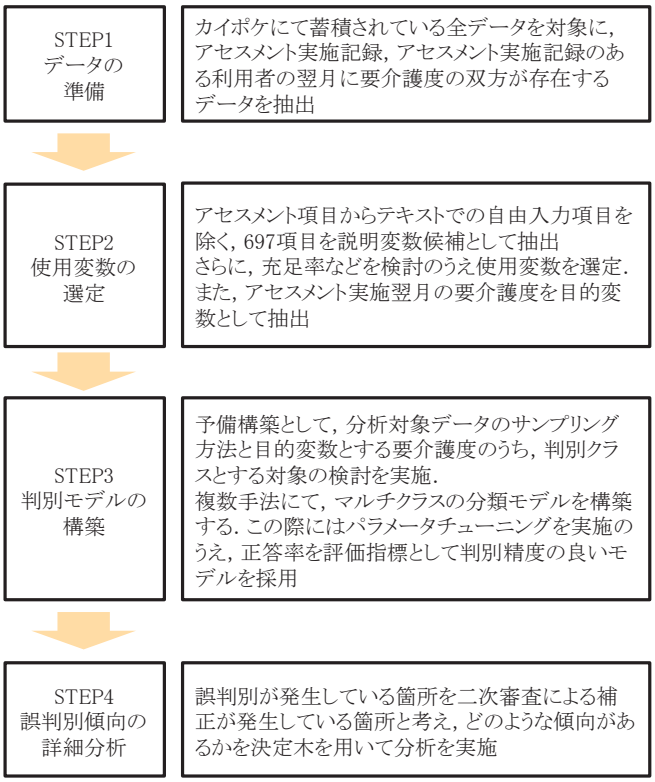


図 2. 本稿での分析アプローチ

4. 使用変数の選定

4.1 アセスメントデータの概要

本稿で説明変数として用いるアセスメントは，要介護度の認定後に具体的にどのような介護サービスを実施していくかを計画されたケアプランを作成する目的で実施される．アセスメントには様々な方式があるものの，本稿で用いるアセスメントシートは全社協方式準拠となっており，要介護度認定に使用される項目も含まれている．アセスメント項目の入力画面例を図 3 に示す．

4.2 変数

本稿で使用するアセスメント票には，認定調査員テキスト 2009 改訂版に含まれる 74 項目が含まれている．したがって，項目上は一次判定における調査に相当する判定が実施可能である．しかしながら，選択肢には当該項目についてアセスメントを行わなかったことを示す“未選択”が存在し，完全に再現ができるものではない．

説明変数はアセスメント項目のうち，テキストでの自由入力項目を除いたうえで，さらに入力率が 100%となっている 603 項目を使用した．また，目的変数となる要介護度はアセスメント翌月時点の値を用いた．



図 3. アセスメントシート入力画面例

5. 要介護度判別モデルの構築

5.1 要介護度判定モデルの構築

要介護度判定モデルの構築にあたり，予備構築として，分析対象の母集団を全件から構築:検証を 7:3 に分割した場合と，構築と検証を各要介護度ごとに構築と検証にそれぞれ 1 万件ずつランダムサンプリングした場合と，さらに，目的変数が要介護度 1 から 5 に加えて要支援 1 から 2 を含めた 7 段階，要介護度のみ 1 から 5 の 5 段階とした場合の 4 パターンを実施した．

この結果，要支援を含めた場合や，全件のデータを使用した場合には要介護度ごとのサンプル数の違いに起因すると考えられるバイアスが見られた．したがって，目的変数を要介護度 1~5 として，各要介護度から構築と検証で重複はせずに構築に 5 万件ずつ，検証用に 1 万件のランダムサンプリングを行い本分析用データとした．

本分析でのモデリングには RandomForest， XGBoost の 2 手法を用いて，パラメータチューニングを実施のうえ，正答率と構築と検証データでの正答率の差異を考慮し最適なモデルの選定を行った．

5.2 判別精度

要介護度 1-5 を対象にランダムサンプリングを実施のうえ，件数を揃えた上で，モデル構築を行った．モデルから得られた予測クラスと正解のクラスの集計結果を図 4 に示す．

正答率は構築データで 50.8%，検証データで 59.7%と非常に安定した結果が得られた．検証データにおいて不正解のうち，正解が予測より低いものが 21.0%に対して，正解が予測より高いものが 28.3%と実態は高めに要介護度が設定されていることが示唆された．

また，1 段階の推定差異を許容する場合，正答率は検証データで 87.4%となり，2 段階以上高い先は 9.0%に対して，2 段階以上低い先は 3.7%と推定よりも実際は高めの要介護度となっている場合が多く見られる傾向が伺える．

構築:件数		正解					
		要介護1	要介護2	要介護3	要介護4	要介護5	合計
予測	要介護1	34,022	18,205	7,207	3,753	2,057	65,244
	要介護2	12,599	20,706	12,552	5,210	2,142	53,209
	要介護3	2,371	8,068	17,488	8,610	2,733	39,270
	要介護4	739	2,328	9,909	19,672	7,973	40,621
	要介護5	269	693	2,844	12,755	35,095	51,656
	合計	50,000	50,000	50,000	50,000	50,000	250,000

構築:構成比		正解					
		要介護1	要介護2	要介護3	要介護4	要介護5	合計
予測	要介護1	52.1%	27.9%	11.0%	5.8%	3.2%	26.1%
	要介護2	23.7%	38.9%	23.6%	9.8%	4.0%	21.3%
	要介護3	6.0%	20.5%	44.5%	21.9%	7.0%	15.7%
	要介護4	1.8%	5.7%	24.4%	48.4%	19.6%	16.2%
	要介護5	0.5%	1.3%	5.5%	24.7%	67.9%	20.7%
		20%	20%	20%	20%	20%	100.0%

検証:件数		正解					
		要介護1	要介護2	要介護3	要介護4	要介護5	合計
予測	要介護1	6,892	3,665	1,360	744	410	13,071
	要介護2	2,455	4,132	2,523	1,019	405	10,534
	要介護3	470	1,588	3,486	1,783	545	7,872
	要介護4	136	460	2,069	3,894	1,694	8,253
	要介護5	47	155	562	2,560	6,946	10,270
	合計	10,000	10,000	10,000	10,000	10,000	50,000

検証:構成比		正解					
		要介護1	要介護2	要介護3	要介護4	要介護5	合計
予測	要介護1	52.7%	28.0%	10.4%	5.7%	3.1%	26.1%
	要介護2	23.3%	39.2%	24.0%	9.7%	3.8%	21.1%
	要介護3	6.0%	20.2%	44.3%	22.6%	6.9%	15.7%
	要介護4	1.6%	5.6%	25.1%	47.2%	20.5%	16.5%
	要介護5	0.5%	1.5%	5.5%	24.9%	67.6%	20.5%
		20%	20%	20%	20%	20%	100.0%

区分	構築		検証	
	件数	構成比	件数	構成比
正解が予測より低い箇所	52,575	21.0%	10,502	21.0%
正解が予測より高い箇所	70,442	28.2%	14,148	28.3%
実態と予測が整合	126,983	50.8%	25,350	50.7%
全体	250,000	100.0%	50,000	100.0%
実態と予測が上下1ランク以内	217,654	87.1%	43,687	87.4%
実態と予測が2ランク以上小さい	9,244	3.7%	1,830	3.7%
実態と予測が2ランク以上大きい	23,102	9.2%	4,483	9.0%

図 4 予測と正解の要介護度集計結果

5.3 誤判別先の傾向分析

構築した要介護度判定モデルから得られた予測クラスに対して，正解が高めに要介護度が設定される利用者の特徴を把握するために，要介護度を 1 と予測した 65,244 件を対象に，正解が 2 段階以上となった 13,017 件を判別対象として，決定木を用いてルール生成を行った．この結果中の LIFT が 2 以上となる特徴的なルールを表 2 に示す．寝たきり度が最重要変数となっており，未選択の場合の排尿介助現状区分が見守り必要もしくは介助必要となる場合に,正解が予測に対して 2 段階以上，高くなっている傾向が見られた．

表 2．予測要介護度 1 に関する乖離先判別ルール

ルール	該当件数	判別対象件数	判別対象件数比率
寝たきり度がランク B-2 以上	872	748	85．8%
寝たきり度　ランク B-1	678	370	54．6%
寝たきり度　未選択 かつ　移乗　未選択	2,518	1,445	57．4%
寝たきり度　未選択 かつ　移乗一部解除 or 全介助	431	800	53．9%
全体	65,244	13,017	19．9%

同様に要介護度を 2 と予測した 53,209 件を対象に，正解が 2 段階以上となった 7,352 件を判別対象として，決定木を用いてルール生成を行った結果中の LIFT が 2 以上となる特徴的なルールを表 3 に示す．寝たきり度が最重要変数となっており，未選択場合には排尿介助現状区分が見守り必要もしくは介助必要となる場合に 2 段階以上上方修正される傾向が見られる結果となった．

表 3．予測要介護度 2 に関する乖離先判別ルール

ルール	該当件数	判別対象件数	判別対象件数比率
寝たきり度　ランク C 以上	1，550	817	52．7%
寝たきり度　ランク B-2	6，653	1，883	28．3%
寝たきり度　未選択 排尿介助現状区分 見守り必要，介助必要	1，021	283	27．7%
全体	53，209	7，352	13．8%

ルール生成の結果，寝たきり度がいずれも重要な変数となった．この，厚生労働省による寝たきり度の定義を表 4 に示す．

表 4 障害高齢者の日常生活自立度(寝たきり度)

生活自立	ランクJ	何らかの障害等を有するが，日常生活はほぼ自立しており独力で外出する 1．交通機関等を利用して外出する 2．隣近所へなら外出する
準寝たきり	ランクA	屋内での生活は概ね自立しているが，介助なしには外出しない 1．介助により外出し，日中はほとんどベッドから離れて生活する 2．外出の頻度が少なく，日中も寝たり起きたりの生活をしている
寝たきり	ランクB	屋内での生活は何らかの介助を要し，日中もベッド上での生活が主体であるが，座位を保つ 1．車いすに移乗し，食事，排泄はベッドから離れて行う 2．介助により車いすに移乗する
	ランクC	1 日中ベッド上で過ごし，排泄，食事，着替において介助を要する 1．自力で寝返りをうつ 2．自力では寝返りもうてない

6. 考察

本稿ではアセスメントのデータを使用して介護度を推定することを試みた．そして、予測と正解に差異が発生している傾向の抽出を試みた．

本来は 1 次調査の結果と主治医意見書等の情報が揃ったうえで、1 次判定の結果、2 次判定の最終結果それぞれを予測のうえ比較を行うことが望ましいものの，本稿のように 87%ほどは上下 1 段階に収まっていることからも，全体的にはアセスメントの結果を用いて 2 次判定を含む要介護度について一定精度で推定することが可能そうである．

一方，2 次審査による要介護度の修正は一定数存在することが推測される．介護認定審査会委員テキストによれば，二次審査にて情報修正が発生しやすい 1 次調査における調査項目とその調査結果について記載が見られる．1 次判定結果が要介護度 2 の場合，口腔清潔:一部介助以上，洗顔:一部介助以上，整髪:一部介助以上，場所の理解:できない，となった場合により重度に変更することが多いとのことであった．本稿での結果からは、アセスメントで得られた寝たきり度ランクが B-1 以上の場合に重度になる傾向が見られていたが、障害自立度 B ランクの当否は、「日常生活活動のうち、食事、 排泄、着替のいずれかにおいては、部分的に介護者の援助を必要とし、1 日の大半をベッドの上で過ごす場合が該当」であるため、口腔清潔:一部介助以上が含まれていると考えられる．したがって，初回では難しいものの、更新の時点ではこのような情報を予め取り込むことで、効率的な要介護度判定が実施できるものと考えられる．

今後の課題として，アセスメントの目的に応じて母集団を分けた分析の実施や,本稿では使用しなかった自由入力欄のデータを使用した分析の実施が考えられる．

最後に，本稿においては医学的観点からの妥当性は検討しておらず，現介護保険制度について言及するものではない．実際の運用に向けては十分な医学的観点での見当も必要であると考えられる．

参考文献

[財務省　2015]財政制度等審議会財政制度分科会（平成 27 年 4 月 27 日開催）資料 1，Available at：http://www. mof. go. jp/about_mof/councils/fiscal_system_council/sub-of_fiscal_system/proceedings/material/zaiseia270427/01. pdf

[厚生労働省　2012]認定調査員テキスト 2009 改訂版(平成 27 年 4 月改訂)，Available at：http://www. mhlw. go. jp/file/06-Seisakujouhou-12300000-Roukenkyoku/0000077237. pdf

[厚生労働省　2012] 介護認定審査会委員テキスト 2009 改訂版(平成 28 年 4 月改訂)，Available at：http://www. mhlw. go. jp/file/06-Seisakujouhou-12300000-Roukenkyoku/0000116033. pdf

[川越 2017] 川越 雅弘: 一次判定方法への ADL 調査項目の関与と要介護度と ADL の関係性，老年精神医学雑誌 (0915-6305)28 巻 9 号，pages1004-1009，2017.

[高橋 2017] 高橋 恭子，築島 恵理: 介護保険新規認定者において要介護度が重度となる原因疾病の検討，日本公衆衛生雑誌 64(11)，pages655-663，2017 .

[関　2017]関　庸一，筒井孝子，宮野尚哉:要介護認定一次判定方式の基礎となった統計モデルの妥当性．応用統計学，29（2），pages101－110，2000.

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

患者群の状態把握を目的とした臨床データ可視化の取り組み

Attempt to visualize clinical data for grasping status of patients

石井雅通 Masamichi Ishii　美代賢吾*2 Kengo Miyo

*1 NCGM（国立国際医療研究センター）
National Center for Global Health and Medicine

This paper describes an attempt to visualize clinical data collected from multi-institutional EHR System.

1. はじめに

多施設の医療機関から患者症例レジストリとして電子カルテに蓄積された臨床データを集積して臨床データベースを構築する事業が複数始まっている．当センターでは日本糖尿病学会と連携した「診療録直結型全国糖尿病データベース事業（Japan Diabetes comprehensive database project based on an Advanced electronic Medical record System：J-DREAMS）」を平成26年度から開始しており、2017 年 12 月現在、35 施設が参加し、今後4年間で 100 施設、10～20 万人規模での登録をめざしている。

こうした患者症状レジストリの構築では臨床医師が当該症例の観察項目を入力することが一般的に実施されており，収集されるデータ項目は専門家による正解ラベルとして取り扱い可能な項目及び既知の臨床知識から判断した重要な特徴量となる項目で構成されている．こうした医師のアセスメント結果を活用し，電子カルテに記録された患者基本情報，検査結果情報，投薬情報などの構造化データから抽出した特徴量と併せて分析することで，観察する臨床データ項目の標準化による診療の質の改善及び合併症進展リスク因子の検索，合併症進展抑制効果の期待される介入の同定，糖尿病薬の副作用についての発生頻度及びリスク因子の確認，症例の未解決課題の発見といった成果が期待されている．

2. 課題

2.1 臨床データに内在する新 Np 問題とスパースネス

集積した臨床データを解析するにあたっては多施設臨床データの特徴に制約を受ける．先ずデータ件数(n)に対してパラメータ数（p）が多い（n<<p）という新 NP 問題があり，かつ医療データがスパースネスであることである．

300 床以上の大規模病院であれば，採用医薬品は 2,000～3,000 品目，検査結果値は 3,000～5,000 項目，検査値以外の観察項目等はすの数倍あり，データ項目としては 10000 を超える．今後のゲノム医療の伸展により患者ごとの遺伝子変異がパラメータに加わると数万規模となる．

一方，患者の疾患は多様でありため特定の疾病に対する分析を目的とする場合，対象となる患者（すなわちデータ件数）が稀少疾患であれば一施設あたり数名から数十名であり，一般に母数が大きいと考えられる“がん”についても，研究のための解析にあたってはがん種やステージごとに患者群を絞り込む必要ため新 NP 問題からは逃れられない．

2.2 患者群の状態把握のために

臨床現場においては専門医が相対する患者の状態を把握して必要な医療を提供する判断をしているが，多施設から収集した臨床データ全体を取り扱う場合は個別の患者の状態をすべて把握して解釈するアプローチは困難である．

そこで，各症例の専門家による探索的な患者群の傾向分析を可能とすることで患者群の状態把握が可能となり，新たなクリニカルクエスチョンの選定に貢献できると考えた．

3. 提案手法

3.1 専門家による正解ラベル選択

症例レジストリで収集しているデータ項目から専門家により患者状態を表現したデータ項目を選択する．

3.2 構造化データ抽出

正解ラベル以外の構造化データ（患者基本情報，処方情報，検査結果情報）を抽出する．

3.3 患者症状単語抽出

診療録等の非構造化データから患者症状を表現する用語を抽出する．ここでは専門用語辞書として万病辞書を使用する．

3.4 患者症状単語統計

前記抽出結果より頻度統計を作成する．

3.5 時系列データ処理

3.2 及び 3.4 の抽出データを入力として，症例レジストリ収集時点を起点として時系列情報を考慮した特徴量データを作成する．例えば，患者ごとの前回検査値からの変化量，次回検査値の変化量等を算出する．

3.6 ベイジアンネットワーク構築

3.1 及び 3.5 の出力データを入力として，ベイジアンネットワークを構築する．

連絡先：石井雅通，国立国際医

3.7 専門家による主成分探索

3.6 で構築したベイジアンネットワークを利用して当該症例の専門家による探索的な患者群の傾向分析を試行する.

3.8 クリニカルクエスチョンの検討

3.7 による合併症進展リスク因子, 合併症進展抑制効果の介入, 医薬品の副作用についてのリスク因子等の観点において新たなクリニカルクエスチョン創出の可能性について評価する.

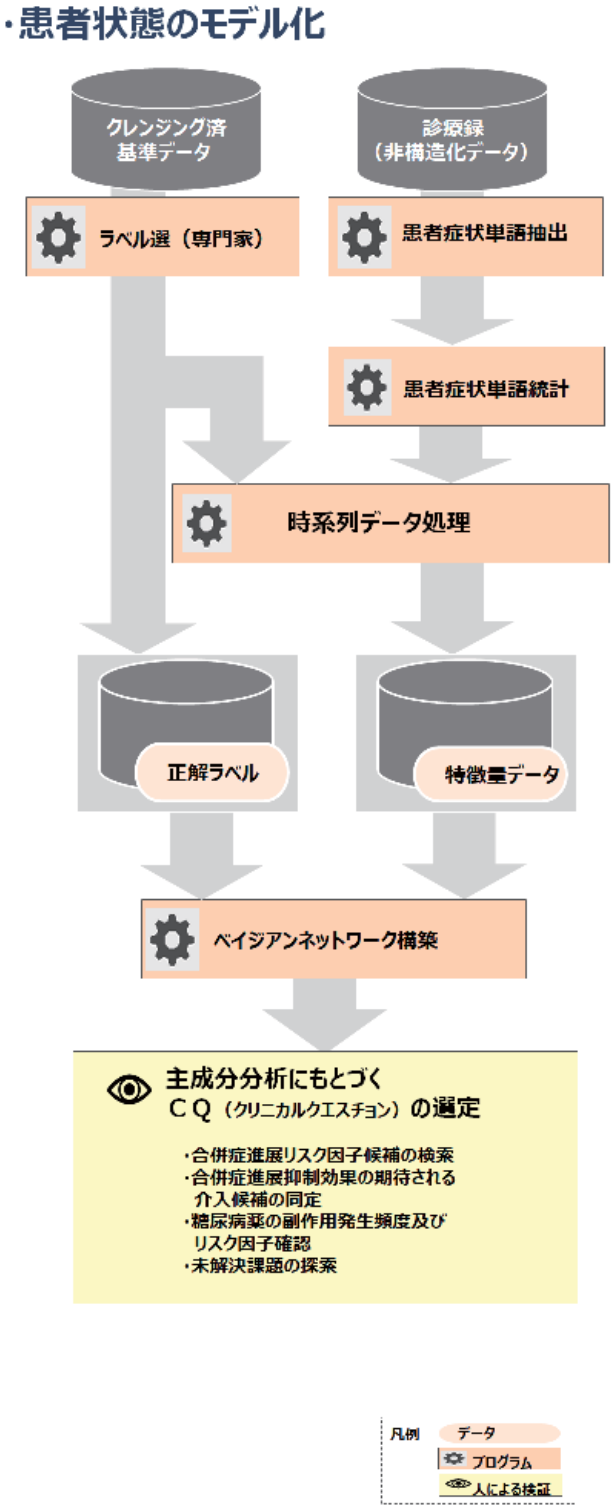
4. 今後の計画

プロトタイプによる評価実験を計画しており, 提案手法で述べた専門医によるレジストリへの入力データを正解ラベルとして活用する手法により, 専門家以外が専門家の協力を得ることが容易となり, ベイジアンネットワークによる可視化により専門家の気づきや暗黙知といったフィードバックをモデルへ反映することが容易となる好循環が期待できる.

ベイジアンネットワークを用いた感度分析を実施することでデータ収集事業が目的としている, (1)合併症進展リスク因子の検索, (2) 合併症進展抑制効果の期待される介入の同定, (3) 糖尿病薬の副作用についてのリスク因子の確認, (4) 糖尿病の未解決課題の発見, への貢献が期待できる.

上記プロセスで患者状態を表現する代表的な特徴量を抽出し, 患者状態モデルを構成する要素として特定していくスパイラルを継続することで既存の収集対象のデータ項目の解析での貢献度を元に精査することが期待できる. 入力データの評価は効率的なデータ収集項目への見直しの機会となり, データ入力元である臨床医の負担軽減の一助となすと考える.

謝辞:この研究の一部は AMED の課題番号 JP17lk1010010 の支援を受けた



参考文献

[J-DREAMS] 診療録直結型全国糖尿病データベース事業, http://jdreams.jp/

[PMDA] MID-NET (Medical Information Database Network), https://www.pmda.go.jp/safety/mid-net/0001.html

[田中博 15] 人工知能 (AI) とビッグデータの 医療と創薬への応用, http://ngbrc.com/img/file54.pdf, 2013

[統計関連学会連合理事会および有志 07] 統計関連学会連合理事会および有志, 我が国の統計科学振興への提言, http://www.jfssa.jp/TokeiKagakuShinkou0702.pdf, 2007

[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, 2017

[荒牧 17] 荒牧英治,岡久,矢野ほか, 大規模医療コーパス開発に向けて, 言語処理学会 第 23 回年次大会 発表論文集, 2017

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

睡眠日誌アプリの開発と睡眠習慣改善行動の継続の予測

Development of “Sleep Diary” application and continuation prediction of behavior for improvement sleeping habits

秋冨 穣[*1] Jou Akitomi　梶山 征央[*1] Ikuo Kajiyama　石井 美穂[*1] Miho Ishii　岡島 義[*2] Isa Okajima　山口 美峰子[*1] Mineko Yamaguchi

[*1] NEC ソリューションイノベータ株式会社 NEC Solution Innovators, Ltd.

[*2] 東京家政大学 Tokyo Kasei University

We consider that computer assistance at effective timing will be an important element in the user's behavioral change using an application. So, we tried to predict "effective timing" by using input data for first three days. As the first step, we tried a prediction of whether the user's behavior continued for several weeks.

1. はじめに

2017 年は睡眠負債という言葉が話題となったが，不眠や睡眠不足など，睡眠に問題を抱えることは精神面や身体面の両面に悪影響を与えることが知られており，疲労感や集中力の低下による産業事故のリスクを増大させ，生産性の低下など，社会的な問題を引き起こすと言われている[厚生労働省 2014]．特に我が国では，20 歳以上のおよそ 5 人に 1 人の割合で睡眠の問題を抱えていると言われており[Doi 2003]，睡眠の問題は大きな社会問題の一つであると言える．

睡眠改善の手法の一つとしては，不眠のための認知行動療法（Cognitive Behavioral Therapy for Insomnia: CBT-I）があり，これまでにその有効性が示されている[Okajima 2011]．CBT-I は特に欧米において既に広く普及しているが，我が国においては普及率が未だ低く，段階的治療の観点からも多くの人がアクセスできる CBT-I ツールの開発の必要性が挙げられている[井上・岡島 2012]．

こうした状況を踏まえ，我々は CBT-I 技法の一部である睡眠日誌の記録と睡眠衛生の教育を提供するためのアプリである「睡眠日誌」アプリを試作開発した．ユーザは，睡眠日誌アプリの利用により，日々の睡眠を記録し，良い睡眠習慣について学び，日々の睡眠の状態を振り返る．ユーザがこのアプリの利用を継続することができれば，ユーザの睡眠習慣が改善されることが期待される．

しかし，このようなユーザの生活習慣の改善，行動変容を促すための取り組みは，必ずしもユーザの継続率は高くなく，途中で脱落するケースが多いという問題が指摘されており[宗 2016]，この問題を解決するために，エージェントによる介入技術を組み入れ，エージェントによる介入を行う方法などが提案されている[日室 2017]．

これらの方法は継続率の向上に一定の成果を挙げているが，ここにそれとは違う視点からのアプローチを追加することにより，より高い効果を発揮することが期待される．そこで，本研究では，これに付加する新たなアプローチとして，アプリの利用の継続を促すための介入方法そのものではなく，介入するべきタイミングや，介入するべきユーザを予測することに注目した．本稿ではその最初のステップとして，睡眠日誌アプリに蓄積されたデータを基に support vector machine（SVM）の判別器を作成し，あるユーザが入力した最初の数日間のデータから，数週間後にそのユーザがアプリの利用を継続しているか否かを予測することを試みた．

連絡先: 秋冨 穣， NEC ソリューションイノベータ株式会社，東京都江東区新木場 1-18-7， 03-5534-2619，jou-akitomi@vt.jp.nec.com

2. 睡眠日誌アプリ

睡眠日誌アプリは，2016 年 3 月から一般公開されており，ユーザは Android 版と iOS 版をどちらも無償で利用できる．睡眠日誌アプリには大きく 3 つの機能がある．

2.1 睡眠に関する情報の記録機能

睡眠日誌アプリでは，ユーザは，自身の睡眠に関する情報を日々記録する．記録する内容は，布団に入った時刻，眠りについた時刻，目覚めた時刻，布団から出た時刻などの睡眠そのものに関する情報が中心であるが，その他にも，寝る前にアルコールを摂取したか否か，寝る前にカフェインを摂取したか否か，寝る前にタバコを吸ったか否かなど，それに付随する情報も含まれる．

特に睡眠時間に関する情報に関しては，ユーザが自身の睡眠の状態を自覚することを特に重視するために自動記録の機能は取り入れておらず，自己申告の睡眠時間を記録するというコンセプトになっている．具体的な記録内容は，図 1 の画面で振り返ることが出来る．

2.2 睡眠に関する知識（睡眠衛生）の学習機能

睡眠日誌アプリでは，ユーザは，睡眠の専門家が監修した睡眠に関するコラムを，常時 30 本以上読むことが出来る．このコラムはマイページからいつでも読むことが出来る他，毎日の睡眠の記録をした際におすすめのコラムが 1 本推薦される．コラムは，例えば図 2 のような画面で提供される．

2.3 睡眠と活動量の振り返り機能

睡眠日誌アプリでは，一週間を単位として，ユーザは自身の睡眠の状態と，その日の日中にどのくらいの活動が出来たか（元気度）をつき合わせて閲覧することが出来る．

例えば，睡眠が乱れた翌日は元気度が低いであるとか，逆に，睡眠が乱れていたとしても意外と日中元気であることが多いであるとか，そのユーザに適したそのユーザだけの睡眠習慣に対する気付きを得ることが期待できる．一週間の振り返りの画面は，図３の画面で提供される．



図1. 睡眠日誌アプリの記録内容の例

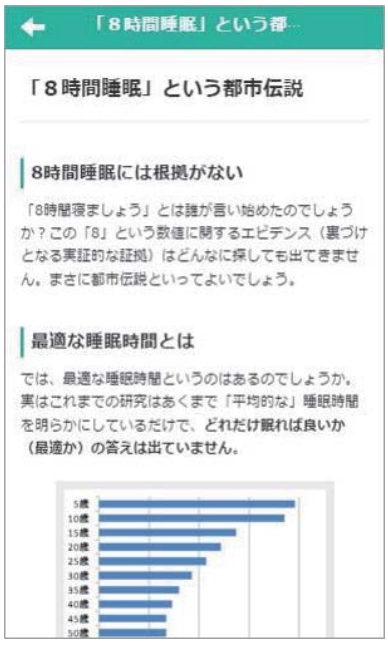


図2. 睡眠日誌アプリで提供されるコラムの例

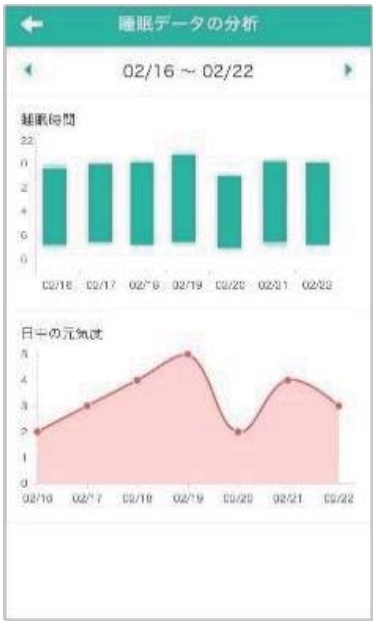


図3. 睡眠日誌アプリの一週間の振り返りの例

3. 睡眠日誌アプリユーザの睡眠の改善

これまでに述べたように，睡眠日誌アプリには，ユーザが良い睡眠習慣を獲得するための要素が含まれている．そのため，睡眠日誌アプリの継続利用者は，睡眠の問題が改善する可能性があると考えられる．睡眠状態を測るためには，例えばアテネ不眠尺度（AIS）と呼ばれる世界各国で使われているアンケートに回答することがその手段として用いられる．睡眠日誌アプリ内にも，ユーザが AIS に回答する機能と，その得点の推移を確認する機能が盛り込まれている．

3.1 アテネ不眠尺度（AIS）

アテネ不眠尺度は 8 問で構成されるアンケートである．ユーザの回答結果に応じて，0 点から最大 24 点までの得点が算出される．この得点は，以下のように解釈される．

- 6～24：不眠症の疑いあり
- 4～5：不眠症の疑いが少しあり
- 0～3：不眠症の疑いなし

3.2 睡眠日誌利用継続ユーザの AIS の変化

実際に睡眠日誌アプリを継続利用することによってユーザは自主的に良い睡眠習慣を獲得し，AIS の値が改善するかどうかについての予備的な調査を行った．調査は 2016 年 10 月から，2016 年 12 月までのデータを用いて行った．その結果を図 4 に示す．

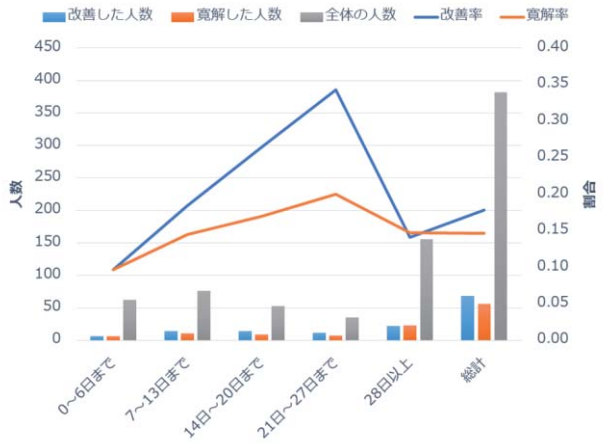


図４．睡眠日誌ユーザの継続利用日数と AIS の変化

図４では，ユーザのアプリ継続期間内において AIS の測定を 2 回以上実施し，AIS が 3 点以下になった者を「寛解」と定義し，AIS が 5 点以上低下した者を「改善」と定義した．図４に寄ると，睡眠日誌アプリユーザの中で寛解した者や改善した者は利用継続日数が増えるにつれて増加しており，増加のピークは 21～27 日の期間，即ち 4 週間程度の利用期間であることが示された．ただし，この集計においてはユーザの行動は統制されておらず，睡眠日誌アプリを利用継続するユーザが自主的に通院やその他の手段を用いて睡眠改善に取り組んだ効果が含まれている可能性があるため，この睡眠改善効果が睡眠日誌アプリによるものであると断定することは出来ない．

4. 睡眠習慣改善行動の継続の予測

アプリの利用の継続を促すために介入が必要なユーザや介入が必要なタイミングを予測するための第一歩として，アプリのユーザの 3 日分の入力データから，そのユーザがその後数週間アプリの利用を継続するか否か（規定回数以上の睡眠の記録をするか否か）の予測を試みた．

なお，睡眠日誌アプリは利用を開始する際にユーザからデータの研究利用についての同意を得ており，データは全て個人を特定できない形に処理した上で使用した．

4.1 使用したデータ項目

予測に用いたデータは，全て睡眠日誌アプリの入力データから抽出した．抽出したデータ項目は，具体的には以下の通りである．

(1) デモグラフィック

- 性別：0, 1
- 年代
- 初期の AIS の値
- 入眠困難を感じるか：0, 1
- 中途覚醒があるか：0, 1
- 早期覚醒があるか：0, 1
- 熟眠障害があるか：0, 1

(2) 日々の記録

- 入床時刻
- 入眠時刻
- 覚醒時刻
- 離床時刻
- 総睡眠時間
- 総就床時間
- 入眠潜時
- 離床潜時
- 中途覚醒時間
- 総覚醒時間
- 睡眠効率
- 入床時刻と離床時刻の中心時刻
- 入眠時刻と覚醒時刻の中心時刻
- 日中の活性度
- 昼寝時間
- 夜にアルコールを摂取したか否か：0, 1
- 夜にカフェインを摂取したか否か：0, 1
- 夜にタバコを吸ったか否か：0, 1
- 自由記述のコメントを入力したか否か：0, 1
- 覚醒してから睡眠を記録するまでにかかった時間
- AIS の測定回数

4.2 実験内容

睡眠日誌アプリを利用しているユーザの中から 10000 人分のデータを選択し，その中から特に、アプリの利用開始日から 3 日間連続で睡眠の記録をつけているユーザのみを抽出した．3 日分のデータはユーザごとに 3 日間の平均値，中央値，標準偏差の 3 通りのデータセットに加工し，そのユーザがその後規定回数分の睡眠記録をつけたか否かのラベルを付加することで，SVM の入力データとした．

5. 結果と考察

平均値，中央値，標準偏差の各データセットについて，2 週間継続（2 週間目に 3 日以上の睡眠記録を実施するか否か），3 週間継続（3 週間目に 3 日以上の睡眠記録を実施するか否か），4 週間継続（4 週間目に 3 日以上の睡眠記録を実施するか否か）の予測を実施し，11-fold cross-validation で，accuracy を評価した．その結果を以下の表１に示す．

表１．SVM による初期 3 日データからの継続予測結果

	平均値	中央値	標準偏差
2 週間継続	66.1	65.4	71.0
3 週間継続	61.7	60.1	61.9
4 週間継続	63.9	63.6	64.9

表１によると，平均値，中央値，標準偏差という 3 つのデータセットの中では，比較的標準偏差のデータによる予測結果の精度が良く，アプリの最初の 3 日の入力データから 2 週間後～4 週間後の利用継続の予測が可能である可能性があることが分かった．標準偏差による分析結果が最も

精度が良かったということから考えると，アプリの利用を継続するユーザと継続しないユーザの差は 3 日の入力データの標準偏差に最も現れやすいということになる．標準偏差の大小は，言うまでも無く，算出する数値のばらつきを反映する．つまり，今回の結果は，継続するユーザと継続しないユーザでは，入力データのばらつきに差があるという可能性があることを示している．ここで入力データのばらつきが少ないということはユーザの日々の睡眠の状態が良くも悪くも一定であるということを示しており，ばらつきが大きいということは，変動が大きいということを示している．これがアプリの利用継続率に影響を与えているとすれば，元々の生活習慣がアプリの利用継続率に影響を与えているという可能性が示唆される．

また，今回実施した内容は本格的な解析の前の予備的な検討であったが，今後予測モデルを更新し，パラメータをチューニングすることにより，より実用的な予測結果を得られる可能性があると言える．

6. おわりに

本稿では特に対象を睡眠日誌アプリのユーザに限定し，ユーザの睡眠の問題解決のための生活習慣改善，行動変容を行うための方法の提案を行った．睡眠日誌アプリに限らず，ヘルスケアアプリを用いた行動変容においては，ユーザごとに最適化されたプログラムの提供や，最適なタイミングでの介入を行うことによる行動の継続支援が重要な要素となると考えられる．本稿で取り組んだ内容は初期 3 日の入力データからの規定の期間の継続の予測であったが，これが実用的なレベルで実施可能になると，初期 3 日のデータからユーザの属性を推定し，そのユーザに最適な介入を実施することが可能になると考えられる．本稿の内容には未だ改良の余地が大いにあるため，引き続き予測精度の向上や，新たな課題への応用の検討を進めていきたい．

謝辞

本研究について大きな貢献をしていだいた NEC ソリューションイノベータの村上紘士さんをはじめ，本研究に協力していただいた皆様に感謝をいたします．

参考文献

［厚生労働省 2014］ 厚生労働省健康局：健康づくりのための睡眠指針 2014，2014.

[Doi 2003] Yuriko Doi, Masumi Minowa and Toshiro Tango: Impact and Correlates of Poor Sleep Quality in Japanese White-Collor Employees, *SLEEP*, Vol.26, No. 4, 2003.

[Okajima 2011] Isa Okajima, Yoko Kodama and Yuichi Inoue: A meta-analysis on the treatment effectiveness of covnitive behavioral therapy for primary insomnia, *Sleep and Biological Thythms*, Japanese Society of Sleep Research, 2010.

［井上・岡島 2012］ 井上雄一 ・岡島義：不眠の科学，朝倉書店，2012.

［宗 2016］ 宗未来・関沢洋一・竹林由武：人工知能で，人のこころは癒せるか？，人工知能（自然言語処理）フィードバック機能搭載型のインターネット認知行動療法（iCBT-AI）の抑うつ者に対する世界初の効果検証（無作為統制試験），RIETI Discussion Paper Series, RIETI，2016.

［日室 2017］ 日室聡仁，山本弘樹，武智小百合，新貝敦，山口美峰子：コンピュータ支援型認知行動療法におけるエージェントが行動継続に与える効果の検証，人工知能学会全国大会（31 回）講演論文集 4Q1-10in2，2017.

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

ニューラル機械翻訳における単語予測の重要性について

竹林　佑斗 *1　Chenhui Chu*1　荒瀬 由紀 *1　永田　昌明 *2

*1大阪大学　*2日本電信電話株式会社

1. 序論

本稿では、人手または統計的手法により自動作成された対訳辞書を利用するニューラル機械翻訳 (NMT) のデコーディング法を提案する。提案手法は、入力文から出力文に出現すべき単語集合を予測する方法と、予測された単語集合が生成されることに報酬を与えるようなデコーディング時のスコアの計算法から構成される。本稿では、科学技術論文の日英翻訳タスク (ASPEC-JE) を対象として、予測単語集合の再現率と適合率を様々に変化させるシュミレーションにより提案手法の有効性を検証した。例えば、予測単語集合としてオラクル単語集合 (正解訳の単語集合) を与えた場合、提案したスコア計算法を用いることにより BLEU スコアが 7.74 ポイント向上することを確認した。

2. 単語集合予測に基づく単語レベル報酬モデル

ここで、本稿の提案法を述べる。提案法は、大きく二つの構成要素からなる。

1. 入力系列から出力系列に出現する各単語の集合（目的単語集合）を予測するモデル
2. 目的単語集合を用いてデコーダが選択する単語を制御する機構

図 1 にデコーディングステップ j における提案法の振る舞いを示す。まず入力系列から目的単語集合を予測する。予測された単語の生成確率に報酬を与えることで、その単語を生成されやすくする。各ステップにおいて、以下の式を用いて単語の生成確率を増加させる。この式は [Li 17] の，出力系列の長さを制御するモデルを参考にした。

$$y_j = \arg\max_y (\log P(y_j|y_{<j}, \mathbf{x}) + \lambda d_y), \qquad d_y \in \mathbf{D}_{f2e}, \quad (1)$$

ここで $\mathbf{D}_{f2e}$ はは対訳辞書とし、λ は報酬の重みである。d_y は、 $y \in D_{f2e}$ ならば 1、そうでなければ 0 であるような関数である。

3. 単語集合予測のシミュレーション

本稿では、提案手法の 2 番目の構成要素の有用性を検証するため実験を行なった。まず参照文に対する単語予測の適合率 (precision) と再現率 (recall) が共に 100%であるオラクル単語集合を作成し、提案手法の効果の上限値を調査した。さらに、オラクル単語集合への単語の追加および削除の処理を加えることで、適合率と再現率をそれぞれ変化させて、予測結果のシミュレーションを行いその時の翻訳性能を測った。その結果、どのような適合率と再現率を持つ目的単語集合を予測できれば、提案手法を用いることでベースラインを大きく上回る結果が得られるかが明らかとなった。

3.1 対訳データと翻訳ツール

ASPEC-JE を用いて提案手法の有効性をシミュレーションする。このデータでは 300 万文のうち上位 200 万文を訓練データとし、 開発データとして 1,790 文、テストデータとして 1,812 文を用いた。提案モデルのベースラインとして「深層学習による自然言語処理」*1 の付録として公開されている mlpnlp-nmt*2 (注意機構付き LSTM エンコーダデコーダモデル) を用いた。このモデルは WAT-2017 の ASPEC-JE/EJ タスクにおいて人手評価でもっとも優れた性能を納めたものである [Nakazawa 17]。提案手法はこのモデルのデコーダ部を上述の式の通り書き換えることで実装した。ハイパーパラメータの設定は [Morishita 17] に従った。

3.2 オラクル単語集合からの精度調整

オラクル単語集合は参照文の単語を目的単語集合とすることで得た。シミュレーション用の擬似予測単語集合を作成する際はオラクル単語集合に下記の処理を加えることで得た。再現率を減少させる際は、オラクル単語集合から複数の単語を無作為に削除し True positive を減少、および False negative を増加させることで調整した。適合率を減少させる際は、オラクル単語集合に複数の単語を追加し False positive を増加させることで調整した。近似予測をできる限り現実的にするため、追加する単語は GIZA++*3 でワードアライメントを取った結果、入力系列の単語から出力系列単語への単語翻訳確率の高い単語から追加した。

3.3 実験結果

オラクルの単語集合を用いた時の BLEU スコアは、35.64 であった。これはベースラインシステムの BLEU スコアの 27.90 から+7.74 ポイントの向上であり、ベースラインの翻訳性能を有意に上回っている ($p < 0.01$)。図 2 に擬似予測単語集合を用いたシミュレーションの結果を示す。各点は擬似単語集合の適合率と再現率をそれぞれ 10% – 90% まで 10% 刻みで変化させた時の、BLEU スコアを表している。*border* は、その線以上の結果はベースラインを有意に上回っているという境界線を示している。したがって、*border* 以上の適合率と再現率をもつ単語集合を入力系列から予測できれば、我々の提案手法を用いることでベースラインを優位に上回る性能が得られる。結果より、適合率よりも再現率のほうが翻訳性能の向上に大きく貢献しており、例えば適合率が 10%であっても再現率が 50%あれば翻訳性能が大きく向上するが再現率が 10%であると適合

連絡先: 竹林　佑斗、大阪大学、大阪府吹田市山田丘 1-5、takebayashi.yuto@ist.osaka-u.ac.jp

∗1 http://www.kspub.co.jp/book/detail/1529243.html
∗2 https://github.com/mlpnlp/mlpnlp-nmt
∗3 http://code.google.com/p/giza-pp

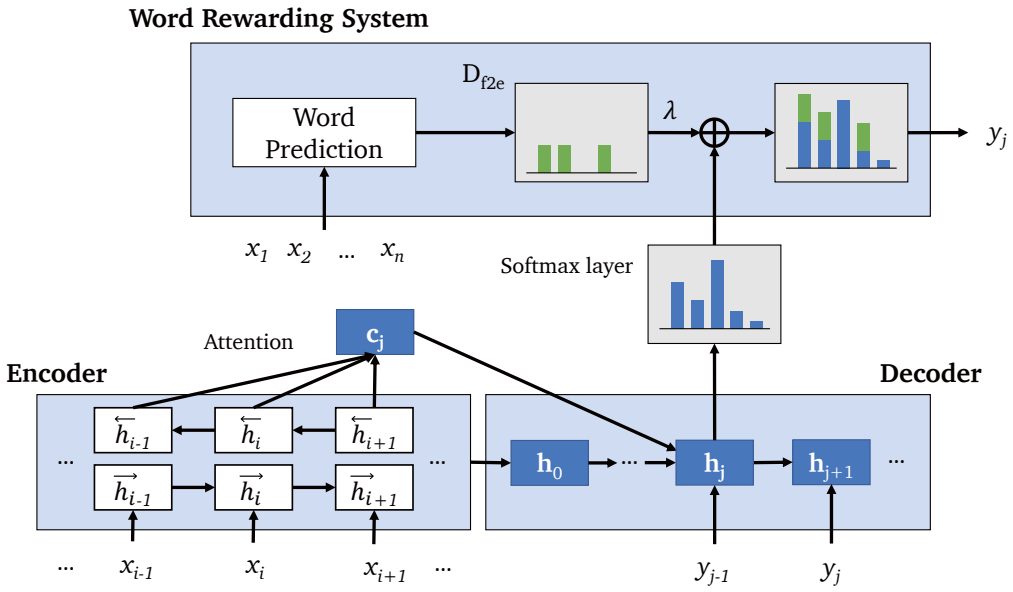


図 1: デコーディングステップ j における単語レベル報酬モデル。各デコーディングステップにおいて、予測された目的単語集合内の単語生成確率に報酬を与えることで、生成されやすくする。

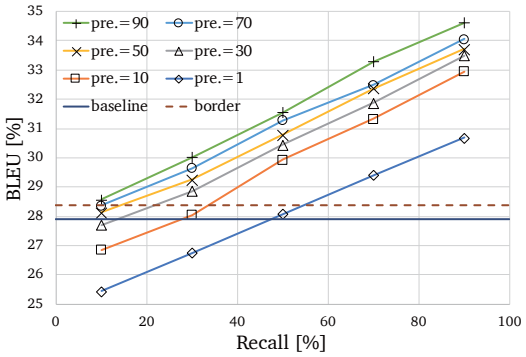


図 2: 擬似予測単語集合を用いて適合率と再現率を変化させた時の BLEU スコア。*boder* は翻訳結果がベースラインと差があるものの境界を示しており、*border* より上の結果はベースラインを優位に大幅に上回っている ($p < 0.01$) ものである。

率が 70%より多くなければ *border* を超えないという結果が得られた。

4. 結論

本稿では、出力系列を制御する手法として、単語レベル報酬モデルを提案した。このモデルは辞書などの外部知識を NMT モデルに適用するものであり、NMT モデルを再訓練する必要がないのが特徴である。実験では擬似予測を行い適合率と再現率を変化させて目的単語集合をシミュレーションし、それを用いた時の BLEU スコアを求めて、ベースラインと統計的有意差があるかどうかを検定した。その結果、予測モデルで作成する目的単語集合に求められる適合率と再現率が明確になった。今後の課題としては、実際に目的単語集合を予測して本稿のシミュレーション結果を満たす結果が得られるかを検証する。

参考文献

[Li 17] Li, J., Monroe, W., and Jurafsky, D.: Learning to Decode for Future Success, *CoRR*, Vol. abs/1701.06549, (2017)

[Morishita 17] Morishita, M., Suzuki, J., and Nagata, M.: NTT Neural Machine Translation Systems at WAT 2017, in *Proceedings of the 4th Workshop on Asian Translation (WAT2017)*, pp. 89–94, Taipei, Taiwan (2017), Asian Federation of Natural Language Processing

[Nakazawa 17] Nakazawa, T., Higashiyama, S., Ding, C., Mino, H., Goto, I., Kazawa, H., Oda, Y., Neubig, G., and Kurohashi, S.: Overview of the 4th Workshop on Asian Translation, in *Proceedings of the 4th Workshop on Asian Translation (WAT2017)*, pp. 1–54, Taipei, Taiwan (2017), Asian Federation of Natural Language Processing

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

自己修復ネットワークの異常ノード撲滅条件の一般化

Research of abnormal node eradication conditions of self-repair network

田村　真優[*1]
Yoshiyuki Tamura

石田　好輝[*2]
Yoshiteru Ishida

[*1] 豊橋技術科学大学
Toyohashi University of Technology

[*2] 豊橋技術科学大学
Toyohashi University of Technology

In the self-repair networks, a ring network has been studied. However, the network structure in the real world is more complex and diverse. This research discussed the boundary between the spread phase and the eradication phase of abnormal nodes by Mean Field Approximation (MFA) in the regular graph of degree three. We also conduct agent simulations for the regular graphs with degrees exceeding three. As a result, we have derived parameter region that guarantees abnormal nodes extinction.

1. はじめに

本研究では,ネットワークの構成要素であるノードが互いに修復をし,ネットワーク全体を正常な状態に保つ「自己修復ネットワークモデル」を扱う.

先行研究[1]ではリング状のネットワークが研究対象とされてきたが,現実世界のネットワーク構造はより複雑で多様なものである.

そこで,本研究では,次数が 3 の正則グラフのネットワーク構造について,自己修復ネットワークの異常ノード撲滅条件の導出を行い,より複雑な構造のネットワークの安定性についての考察を行う.

2. 自己修復ネットワークについて

自己修復ネットワークとは,ネットワークを構成するノードが修復試行確率 Pr で隣接するノードと相互に修復を行い,ネットワーク全体を正常に保つモデルである.各ノードは「正常」か「異常」のどちらかの状態をとるものとする.

修復は必ず成功するものではなく,修復元ノードに設定されている修復成功率で成功する.そして,修復対象のノードの状態は修復に成功した場合は正常,修復に失敗した場合は異常となる.ただし,修復元ノードの状態によって修復成功率が定まり,正常ノードによる修復成功率 Prn は異常ノードによる修復成功率 Pra 以上とする($Prn>Pra$).また,一つのノードに対して複数のノードから修復が行われた場合,本研究では,修復が全て成功した場合のみ修復成功として扱う(AND 修復).つまり,一つでも修復が失敗すれば修復を受けたノードは異常となる.

また,正則グラフとは,全てのノードが同じ数のノードと接続されているグラフのことを表す.先行研究で主に研究されてきたリング状のネットワークは,次数が 2 の正則グラフのネットワーク構造である.

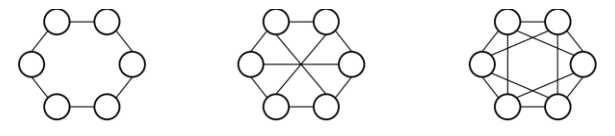


図 1. 正則グラフの例

田村真優, 豊橋技術科学大学 情報・知能工学専攻,
tamura@sys.cs.tut.ac.jp

自己修復ネットワークの目的はネットワーク内の異常ノードを撲滅し,ネットワーク全体を正常に保つことである.しかし,パラメータの取り方によっては修復の失敗によってネットワーク内が異常ノードのみになってしまう場合もある.本論文では,異常ノードを撲滅できるパラメータ領域を撲滅相,それ以外の領域を蔓延相と呼ぶ.

3. 結果

3.1 異常ノード撲滅条件の導出

平均場近似による近似計算で異常ノードの撲滅条件を計算したところ,以下の理論式で撲滅条件が表されることが分かった.

$$Pr^2-3Pr+3Pra\geqq 0$$

この条件を満たす領域を図 2 に示す.

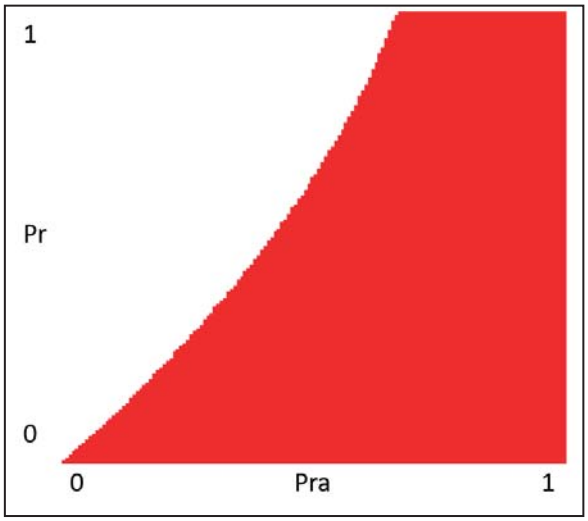


図 2. 異常ノード撲滅条件を満たすパラメータ領域

3.2 シミュレーションの結果

3 次の正則グラフのネットワークについて,表 3 の条件で自己修復のシミュレーションを行った.

表 3. シミュレーションの条件

ノード数	100
ステップ数	2000
修復試行率 Pr	0~1
正常ノードによる修復成功率 Prn	1
異常ノードによる修復成功率 Pra	0~1

今回のシミュレーションでは, 修復試行率と異常ノードによる修復成功率を 0 から 1 の間で 150 段階に変化させ, 計 22500 回のシミュレーションを行った. そして, 各試行において 2000 ステップ後の正常なノードの割合を算出した. この結果を図 4 に示す.

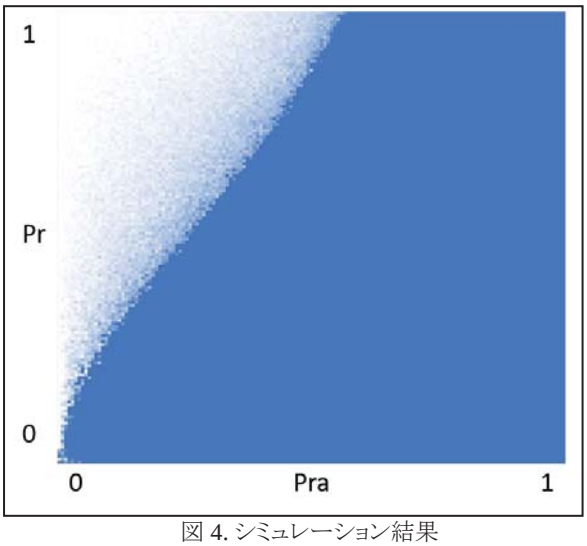


図 4. シミュレーション結果

ここで,グラフの色の濃さは 2000 ステップ後の正常ノードの割合を示す.すなわち,青色の領域は 2000 ステップ後にネットワーク内の全てのノードが正常となり,異常ノードを撲滅できたことを表す.

同様の条件で,次数が 4, 6, 8, 10 の正則グラフのネットワーク構造についても自己修復のシミュレーションを行った.シミュレーションの結果を以下の図 5(a)~(d)に示す.

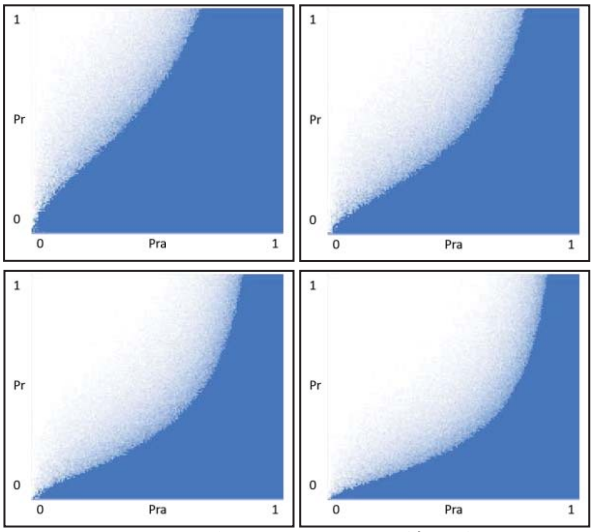


図 5. (a) 4 次　シミュレーション結果(左上)
図 5. (b) 6 次　シミュレーション結果(右上)
図 5. (c) 8 次　シミュレーション結果(左下)
図 5. (d) 10 次　シミュレーション結果(右下)

4. 考察

シミュレーションの結果から,次数が増えるほど異常ノードの撲滅条件が厳しくなる,すなわち,撲滅相が狭くなり蔓延相が広くなることが分かった.また,先行研究[1]より,*Pra* が小さい場合 *Pr* が大きくなると異常が蔓延してしまうことが分かっており,今回のシミュレーションでも同じ結果が得られた.これらの結果から,正則グラフの次数が増えネットワーク構造が複雑になることと,修復試行率 *Pr* が大きくなることは似たような効果があると考えられる.

この考察に関して,先行研究[1]より,2 次の正則グラフのネットワーク構造の場合,*Pra*/*Pr* ≤1/2 の条件で異常ノードが絶滅することが分かっている.そこで,2 次の正則グラフを基準として,次数が *n* 倍になることは *Pr* が *n* 倍になることと等価とみなせるのではないか,つまり,*n* 倍の数のノードから同じだけ修復を受けることと,1 つのノードから *n* 倍修復を受けることは同じとみなせるのではないかと考え,実際にシミュレーション結果と *Pr* を *n* 倍にした一次式の線を比較したところ,結果は以下のようになった.

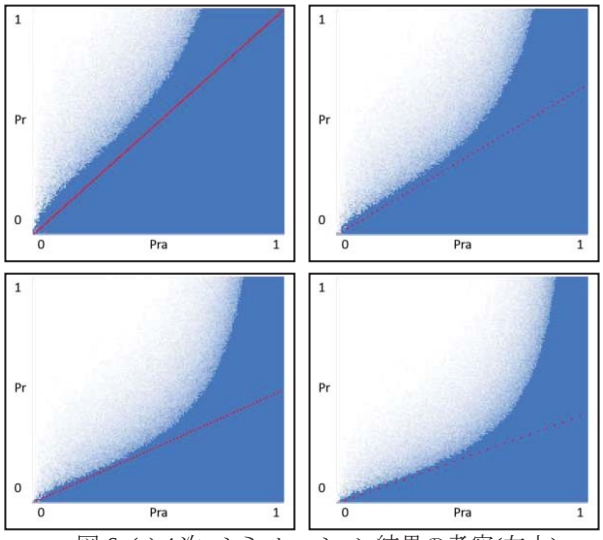


図 6. (a) 4 次　シミュレーション結果の考察(左上)
図 6. (b) 6 次　シミュレーション結果の考察(右上)
図 6. (c) 8 次　シミュレーション結果の考察(左下)
図 6. (d) 10 次　シミュレーション結果の考察(右下)

Pr と *Pra* が小さいとき,すなわちグラフの左下の領域では,一次式の条件でもシミュレーション結果とフィットしている.本研究では修復方式として AND 修復を採用しているため,修復の衝突が発生すると修復成功率は下がってしまう.しかし,修復試行率 *Pr* が低い場合,修復の衝突がほとんど発生せず,修復の衝突の影響が無視できるほど小さくなるため,このような結果になったのだと考えられる.

この結果から,修復の衝突が発生しない,あるいは,修復の衝突の影響が無視できる場合については,次数が *n* 倍になることと *Pr* が *n* 倍になることが等価とみなせるといえる.

5. おわりに

本研究では,3 次の正則グラフのネットワーク構造に平均場近似を適用することにより,異常ノード撲滅条件を導出した.また,修復方式として AND 修復を採用した場合,正則グラフの次数が増えネットワーク構造が複雑になると,異常ノード撲滅相が狭くなり,蔓延相が広くなることを確認した.

参考文献

[1] Ishida, Y.: Self-Repair Networks, Springer, 2015.

[3A1] [General Session] 2. Machine Learning

座長:椿 真史（産業技術総合研究所）

Thu. Jun 7, 2018 1:50 PM - 3:30 PM Room A (4F Emerald Hall)

[3A1-01] Task-free Attention Learning with Intrinsic Reward and Adversarial Learning

○Tatsuya Matsushima[1], Shohei Osawa[1], Yutaka Matsuo[1] （1. The University of Tokyo）

1:50 PM - 2:10 PM

[3A1-02] A new methodology of deterioration prediction using deep learning scheme for coastal facilities

○Kentaro Kumagai[1], Naoki Fujii[2] （1. Kyoto University, 2. Tokyo Electric Power Services CO.,Ltd.）

2:10 PM - 2:30 PM

[3A1-03] Improving SRGAN for Super-Resolving Low Resolution Food Images

○Yudai Nagano[1], Yohei Kikuta[2] （1. The University of Tokyo, 2. Cookpad Inc.）

2:30 PM - 2:50 PM

[3A1-04] Enhancing Visual Explanation of Deep Neural Networks by Activation Freezing

○Satoshi Hara[1] （1. Osaka University）

2:50 PM - 3:10 PM

[3A1-05] Similarity Learning Based Adversarial Training for Censoring Representatoins

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

3:10 PM - 3:30 PM

©The Japanese Society for Artificial Intelligence

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

内的報酬と敵対的学習によるタスク非依存な注意機構の学習

Task-free Attention Learning with Intrinsic Reward and Adversarial Learning

松嶋 達也 Tatsuya Matsushima　大澤 昇平 Shohei Osawa　松尾 豊 Yutaka Matsuo

東京大学
The University of Tokyo

Recent advances in artificial intelligence, especially deep learning, have enabled us to handle wider range of problems with computers. As for the real-world problem settings, however, there remain some difficulties, for example, inputs for embodied agents are partially observed representation of their states, and building models of their environments is needed for more sample efficient systems. One possible solution for coping with these difficulties is to use attention mechanism, which models the visual system of human and regards its inputs as a sequences, learning to where to attend.

In this paper, we propose a method to train attention mechanism of neural network without external rewards. The proposed method consists of two ideas, one is to use intrinsic reward for attention mechanism and the other is to adopt adversarial learning in the model.

1. 研究の背景と目的

近年，人工知能の活用による社会の生産性向上への期待が高まっている．この期待の背景として，深層学習が人工知能技術のブレイクスルーになったことが挙げられ [Goodfellow 16]，強化学習と組み合わせた深層強化学習を利用することにより，ビデオゲームや囲碁などのタスクにおいて従来の手法を上回る結果を記録している [Mnih 15, Silver 17]

しかし，実世界環境で活用可能な人工知能の構築には，課題が残されている．特に，観測が部分的であること，タスクに対する報酬の設計が難しいことの 2 点が挙げられる [Thrun 05]．

部分的な観測を扱うニューラルネットワークのモデルとして，人間の視覚的注意を模倣した注意機構 (attention mechanism) を持つモデルが提案されている．しかし，これらのモデルでは，注意機構の学習がタスクから定義される外的な報酬信号を用いた強化学習によって行われており，外部からの報酬信号が得られない問題設定下では注意機構の学習を行うことができない．

本研究の目的は，特定のタスクに依存しない方法で注意機構を学習させ，状態の予測を行う手法を構築することである．

提案手法のアイデアは，(i) 内的な報酬の利用と (ii) 敵対的学習の二点である．まず，注意機構を用いたニューラルネットワークのモデルである Recurrent Attention Model (RAM) [Mnih 14] において，タスクから定義され注意機構に与えてられていた外的な報酬の代わりに，1 時間ステップ後における観測の予測誤差を注意機構の内的報酬として与える．次に，観測の予測モデルと注意機構を敵対的な学習により訓練する．

2. 関連研究

2.1 注意機構

RAM は，各時間ステップにおいて画像として得られる観測データをリカレントニューラルネットワークにより時系列方向に統合して，画像のラベルの予測と，次の時間ステップにおいて観測する場所を決定するモデルである．

連絡先: 松嶋達也，東京大学，〒 113-8656 東京都文京区本郷 7-3-1，matsushima@weblab.t.u-tokyo.ac.jp

RAM では画像の識別タスクにおける正誤の情報を報酬として，強化学習を用いて注意機構の学習を行っている． そのため，RAM は状態 (画像全体) のモデルの学習をしているのではない．

2.2 内的な報酬の利用

エージェントにとって環境が未知であり，環境に関する知識を学習する必要のある場合には，エージェントの探索を促進する必要がある．エージェントに環境の探索を促す方法として，内的な動機づけ (intrinsic motivation) や好奇心 (curiosity) を導入する手法が考案されている．

特に，Pathak らの研究 [Pathak 17] では，報酬がスパースな設定の強化学習の問題に対して，好奇心を内的な報酬として導入し探索行動を促している．この研究では，エージェントは入力として受け取る次の観測を予測し，その予測誤差を内的な報酬 (好奇心) として定義している．エージェントの行動は，タスクにおける報酬と好奇心による報酬の重み付き和を報酬とする強化学習により学習されている．実験では，報酬が得られるまでに長い行動の系列が必要なビデオゲーム (Super Mario Bros.) に対し，好奇心を用いることでエージェントが以前に経験していない状態を探索する行動を促し，タスクの達成にかかる時間を短縮できることが示された．

RAM では，画像の分類タスクという特定のタスクに対して，そのタスクから定義される報酬を用いて注意機構の学習を行っている．一方，本研究では，特定のタスクに依らず状態 (RAM でいう画像全体に対応する) のモデルを学習することを目的とするため，注意機構の学習に内的な報酬を利用する．

3. 提案手法

状態のモデルを学習することによってタスク間で共有可能な状態に関する表現を学習できる．

これは，RAM のような単一のタスクを行う問題設定ではなく，訓練時に画像のほかにラベルのような正解データや存在しない場合や，途中でタスクが変化する場合に，一度学習した内容を他のタスクに転移させるときに有効である．

本研究では，RAM を拡張し，注意機構の学習に外的な報酬を用いる代わりに観測に対する予測の誤差を注意機構の内的な

報酬として与え，観測の予測モデルと注意機構を敵対的な学習により訓練する手法を提案する

3.1 問題設定

モデル全体として，状態 (本研究の場合は画像全体)$\boldsymbol{x}$ に関する予測 $\hat{\boldsymbol{x}}$ を行うことを目標とする．つまり，真に最小化を行いたい予測誤差 L は以下のように与えられる．

$$L = \|\hat{\boldsymbol{x}} - \boldsymbol{x}\|^2 . \tag{1}$$

しかし，エージェントは画像全体の情報 $\boldsymbol{x}$ を受け取ることができないため，提案手法では，エージェントが利用可能な情報である各時間ステップ t における観測 $\boldsymbol{o}_t$ を用いて間接的に状態に関する予測を行う．

一様乱数から観測する位置をサンプルし，観測に対する予測を行なった場合，観測に対する予測誤差の期待値は，状態 (画像全体) の予測誤差に比例する．つまり，この最小化問題は観測の予測誤差 $J_p(\theta_p)$ を最小化する問題として考えることができる．

$$J_p(\theta_p) = \frac{1}{T}\sum_{t=1}^{T} \|\hat{\boldsymbol{o}}_t(l_{t-1};\theta_p) - \boldsymbol{o}_t\|^2 . \tag{2}$$

ただし，l_{t-1} は観測 $\boldsymbol{o}_t$ の位置，$\hat{\boldsymbol{o}}_t$ をエージェントによる観測 $\boldsymbol{o}_t$ に対する予測，θ_p は観測を予測するエージェントのモデルパラメータ，T を観測の時間ステップの数とする．

3.2 内的な報酬

RAM における注意機構の学習では，ラベルの識別タスクにおける正誤を報酬として利用する強化学習を行っていた．しかし，ラベルなどの正解データが存在しない場合や，状態に関するモデル自体を学習する場合には，モデルの外部から報酬が与えられず RAM を直接利用することはできない．

そのため，以上に挙げたような問題設定下でも，注意機構の学習に利用することのできる指標として観測の予測に関する誤差 $\|\hat{\boldsymbol{o}}_t - \boldsymbol{o}_t\|^2$ を用い，注意機構を訓練するための報酬として定義することを考える．

しかし，RAM を観測の予測誤差の最小化するというアイデアのみで拡張し，観測の予測誤差が小さくなる位置の決定に対して報酬を多く与えるように設定すると，注意機構によって決定される位置が固定してしまうことが容易に考えられる．

3.3 敵対的な学習

そのため，本論文の提案手法では，注意機構に対して観測の予測誤差が大きくなる行動に対して大きな報酬を与えることで，エージェントの探索を促し，式 1 で表現された真の目的関数を間接的に最適化することを考える．

注意機構に対し，観測の予測誤差が大きくなる行動に対して大きな報酬を与えるためには，報酬として観測の予測誤差の値をそのまま利用すれば良い．時間ステップ t における注意機構に対する報酬を R_t とすると，

$$R_t = \|\hat{\boldsymbol{o}}_t - \boldsymbol{o}_t\|^2 . \tag{3}$$

とできる．

注意機構の入力は，観測を予測するエージェントが持つ状態 (画像全体) に関する予測であり，更新するパラメータは，注意機構が持つパラメータ θ_l のみである．つまり，状態の予測を通じて観測を予測するエージェントには強化学習によるパラメータ更新の勾配を伝播させない．

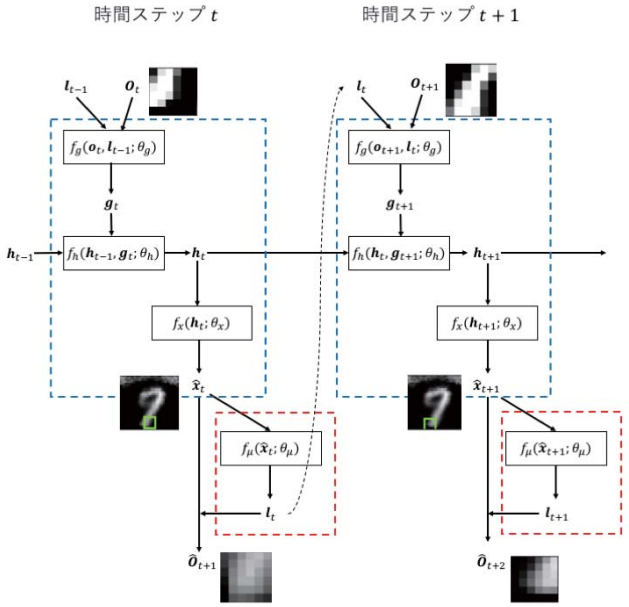


図 1: 提案モデルの概略図

すなわち，注意機構の最適化問題は，式 4 で表される目的関数 $J_l(\theta_l)$ の最小化問題となる．

$$J_l(\theta_l) = -\mathbb{E}_{\pi(\theta_l)}\left[\sum_{t=1}^{T} R_t\right] . \tag{4}$$

ただし，π を注意機構の方策とする．

以上より，提案手法は観測する位置が与えられた上でその観測の予測誤差を最小化するように教師あり学習を行うエージェントと，行動を観測の位置とし，その位置における観測の予測誤差が大きければ大きいほど大きい報酬が与えられる強化学習を行うエージェント (注意機構) の 2 つのエージェントによる学習として考えることができる．

つまり，これらのエージェントは，

$$\min_{\theta_p}\max_{\theta_l} \mathbb{E}_{\pi(\theta_l)}\left[\sum_{t=1}^{T}\left\|\hat{O}_t(\theta_p) - O_t\right\|^2\right] . \tag{5}$$

というミニマックスゲームに基づく，敵対的な学習を行っている．

図 1 は提案モデルの概略図であり，時間ステップ t と $t+1$ における各変数の関係を示している．左上の枠線で囲まれた部分は観測を予測するエージェント，右下の枠線で囲まれた部分は注意機構に相当する．

Algorithm1 は，提案手法におけるモデルの学習の流れを擬似コードを用いて表したものである．1 つの画像に対して，注意機構による観測の位置の決定と，その位置における観測の予測の組み合わせを T 回行ったあと，観測の予測エージェントと注意機構それぞれに対して損失 (loss) を計算し，勾配効果法を用いてそれぞれのモデルのパラメータを更新する．以降，この一連の流れを 1 エポック (epoch) と呼ぶことにする．

Algorithm 1 提案手法における学習

Input: 画像:$\boldsymbol{x}$

$\boldsymbol{l}_0$ を一様乱数を用いて初期化する
for $t = 1, 2, \ldots, T$ **do**
  $\boldsymbol{o}_t \leftarrow Crop(\boldsymbol{x}, \boldsymbol{l}_{t-1})$
  $\boldsymbol{g}_t \leftarrow f_g(\boldsymbol{o}_t, \boldsymbol{l}_{t-1}; \theta_g)$
  $\boldsymbol{h}_t \leftarrow f_h(\boldsymbol{h}_{t-1}, \boldsymbol{g}_t; \theta_h)$
  $\hat{\boldsymbol{x}}_t \leftarrow f_x(\boldsymbol{h}_t; \theta_x)$ ▷ 画像全体に関する予測を行う
  $\boldsymbol{\mu}_t \leftarrow f_\mu(\hat{\boldsymbol{x}}_t; \theta_\mu)$
  $\boldsymbol{l}_t \sim N(\cdot; \boldsymbol{\mu}_t, diag(\sigma^2))$ ▷ REINFORCE
  $\hat{\boldsymbol{o}}_{t+1} \leftarrow Crop(\hat{\boldsymbol{x}}_t, \boldsymbol{l}_t)$
$J_p(\theta_p) \leftarrow \frac{1}{T}\sum_{t=1}^{T} \|\hat{\boldsymbol{o}}_t(\theta_p) - \boldsymbol{o}_t\|^2$ ▷ 損失を計算
$J_l(\theta_l) \leftarrow -\mathbb{E}_{\pi(\theta_l)}\left[\sum_{t=1}^{T} \|\hat{\boldsymbol{o}}_t - \boldsymbol{o}_t\|^2\right]$
$\theta_p \leftarrow \theta_p - \eta_p \nabla_{\theta_p} J_p(\theta_p)$ ▷ パラメータの更新
$\theta_l \leftarrow \theta_l - \eta_l \nabla_{\theta_l} J_l(\theta_l)$

ただし，パラメータ θ_p を観測を予測するエージェントのパラメータ全ての集合 $\theta_p := [\theta_g, \theta_h, \theta_x]$，パラメータ θ_l を注意機構のパラメータ全ての集合 $\theta_l := [\theta_\mu]$，$N(\boldsymbol{x}; \boldsymbol{\mu}, \boldsymbol{\Sigma})$ を平均が $\boldsymbol{\mu}$ で共分散が $\boldsymbol{\Sigma}$ の多変量正規分布，$Crop(\boldsymbol{x}, \boldsymbol{l})$ を画像 $\boldsymbol{x}$ から位置 $\boldsymbol{l}$ を中心とした部分を切り取る操作，η_p を観測を予測するエージェントの学習率，η_l を注意機構の学習率，b を適当なベースライン (定数) とする．

4. 評価実験

提案手法の有効性を検証するために，画像に関するタスクのベンチマークとして利用される MNIST データセット [LeCun 98] を用いて評価実験を行った．また，注意機構の強化学習アルゴリズムとして REINFORCE アルゴリズム [Willia 92] を利用した．

4.1 実験の設定

注意機構のモデルに関する比較実験を行った．実験のタスクは，画像の一部を観測しモデルの内部状態として画像全体の予測を行うことである．以下の 3 つの手法を比較する．

提案手法
注意機構は予測モデルの内部状態を入力として，次に観測を行う位置を決定する．注意機構には，観測の予測誤差が大きければ大きいほど，その位置の選択に対して大きな報酬を与える．このとき，注意機構は観測の予測モデルに対して敵対的な設定となる．

ベースライン (ランダム)
次に観測を行う位置は一様分布からサンプリングされた値を用いる．

ベースライン (協力的)
注意機構には観測の予測誤差が小さくなればなるほど大きい報酬を与える．これは RAM を内部報酬というアイデアのみで拡張したものであり，このとき，注意機構は観測の予測モデルに対して協力的な設定となる．

評価時には，以上のように訓練されたネットワークを用いて，訓練時とは異なる画像に対し，モデルの内部に表現された画像全体に対する予測と正しい画像全体との誤差を評価指標として評価を行う．

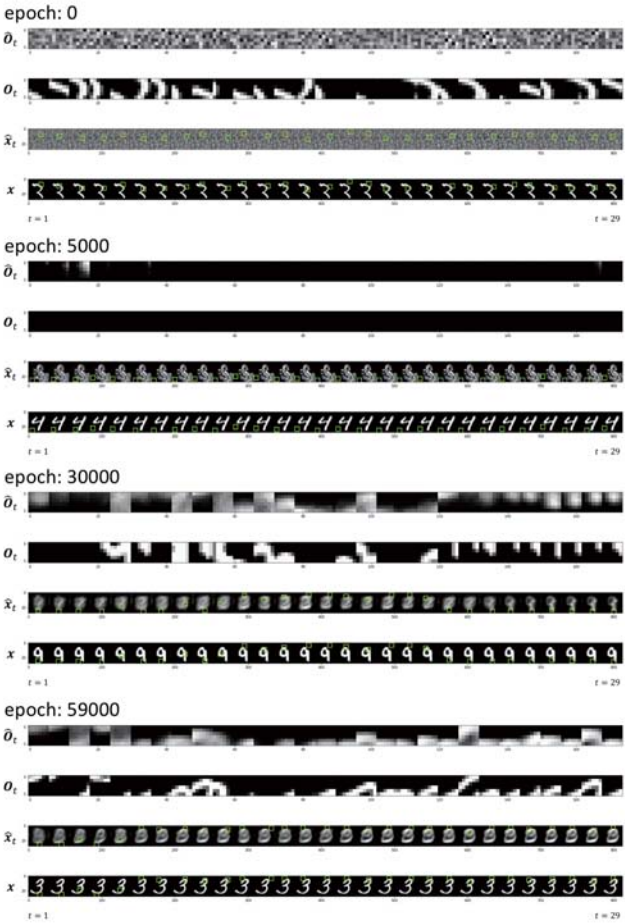


図 2: 提案手法により予測した結果

4.2 結果

図 2 は訓練データに対して，提案手法により予測した結果を表している (図の上からエポックが 0, 5000, 3000, 59000 のときを掲載している)．図の左側から右側に向かって時間ステップが経過している．各エポックに対し，最上段はエージェントによる観測の予測 ($\hat{\boldsymbol{o}}_t$)，2 段目はエージェントが得た実際の観測 ($\boldsymbol{o}_t$)，3 段目はエージェントによる画像全体の予測 ($\hat{\boldsymbol{x}}_t$)，4 段目は実際の画像全体を表している ($\boldsymbol{x}$)．3 段目と 4 段目の緑色の枠は，注意機構により決定された観測の範囲を表している．

学習の初期は，観測の予測モデルが学習されていないため，観測の予測と画像全体に対する予測はランダムなものとなっている (epoch: 0)．ある程度エポックが経過すると，観測の予測をするエージェントの学習が進み，観測の予測は実際の観測と近くなるが，観測の位置は固定してしまっている (epoch: 5000)．その後，注意機構の学習が進み，ステップが進むごとに観測の位置が変化するようになり，画像全体の予測が実際の画像に近づく (epoch: 30000)．学習の終盤では，観測によって画像全体の特徴を反映した予測ができるようになっている (epoch: 59000)．

図 3 は，テストデータに対するステップごとの画像全体に対する予測誤差を示している．提案手法は，ベースライン手法に比べて，少ない観測の回数で高い精度で画像全体を予測することができていることがわかる．

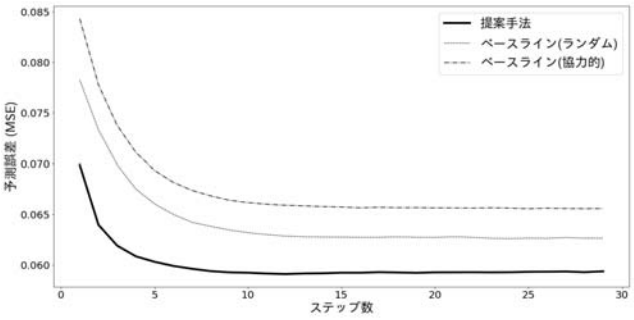


図 3: テストデータ内の画像全体に対する予測誤差

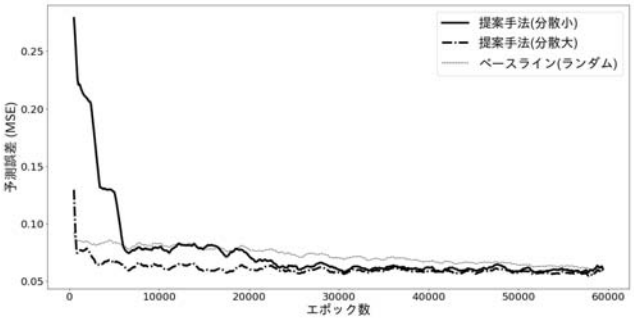


図 4: 提案手法で分散を変更したときの学習曲線

図 4 は，提案手法において，観測の位置の決定に用いる正規分布の分散の値を大きくした場合の学習曲線を表している．分散の値を大きくすると，画像全体に対する予測誤差が学習の早い段階で減少することがわかる

4.3 結果に対する考察

観測の予測誤差を大きくする観測を行うようにする位置の決定に報酬を与えることで，高い効率で状態の予測が可能なことを示した．

提案手法では，学習の初期において観測の予測モデルの学習が進んでおらず，観測の位置が固定してしまう．分散の値を大きくすると，状態の予測誤差が早く減少するようになる．これは，分散の値が大きいほど，実際に観測が行われる位置のランダム性が上がり，もし注意機構の出力する値が固定してしまっても，その値から観測位置が遠くに決定される確率が上昇する．この場合，観測の予測エージェントの予測誤差が大きくなるため，注意機構に対する報酬の値が大きくなり位置の固定から早く抜け出せるようになるためであると考えられる．

以上より，注意機構の出力のランダム性を高め，次第に小さくしてゆくことが有効であると結論づけられる．

5. 考察

今後の研究の方向性として手法のアイデアを動的な状態に適用することが考えられる．これは部分的な観測しか得られない状況下での動画像全体の予測問題となる．

提案手法を実ロボットなどの 3 次元空間内に没入したエージェントの問題へ適用することが考えられる．しかし，実世界の 3 次元空間において，カメラによる画像を入力として用いると，入力の次元が大きく学習が難しくなるため，入力の予測による環境のモデルの構築が難しくなる．そのため，観測やモデル内部での状態表現に対し，何らかの抽象化・離散化が必要になると考えられ，その手法を考案する必要がある．

6. 結論

本研究では，観測に対する予測誤差を注意機構の内的な報酬として与え，観測の予測モデルと注意機構を敵対的な学習により訓練する手法を提案した．

評価実験では，画像のうち一部分が観測として得られる問題設定下で画像全体を予測するタスクにおいて効率的な状態の予測が可能なことを示した．

参考文献

[Goodfellow 16] Ian Goodfellow, Yoshua Bengio, and Aaron Courville. Deep learning. MIT Press, 2016.

[Mnih 15] Volodymyr Mnih, Koray Kavukcuoglu, David Silver, Andrei A. Rusu, Joel Veness, Marc G. Bellemare, Alex Graves, Martin Riedmiller, Andreas K. Fidjeland, Georg Ostrovski, Stig Petersen, Charles Beattie, Amir Sadik, Ioannis Antonoglou, Helen King, Dharshan Kumaran, Daan Wierstra, Shane Legg, and Demis Hassabis. Human-level control through deep reinforcement learning. Nature, 518(7540):529-533, 2015.

[Silver 17] David Silver, Julian Schrittwieser, Karen Simonyan, Ioannis Antonoglou, Aja Huang, Arthur Guez, Thomas Hubert, Lucas Baker, Matthew Lai, Adrian Bolton, Yutian Chen, Timothy Lillicrap, Fan Hui, Laurent Sifre, George Van Den Driessche, Thore Graepel, and Demis Hassabis. Mastering the game of Go without human knowledge. Nature, 550(7676):354-359, 2017.

[Thrun 05] Sebastian Thrun, Wolfram Burgard, and Dieter Fox. Probabilistic robotics. MIT Press, 2005.

[Mnih 14] Volodymyr Mnih, Nicolas Heess, Alex Graves, and Koray Kavukcuoglu. Recurrent Models of VisualAttention. In Advances in Neural Information Processing Systems 27, pages 2204-2212, 2014.

[Pathak 17] Pathak, Deepak and Agrawal, Pulkit and Efros, Alexei A. and Darrell, Trevor. Curiosity-Driven Exploration by Self-Supervised Prediction. In Proceedings of the 34th International Conference on Machine Learning, pages 2778-2787, 2017.

[LeCun 98] Y. LeCun, L. Bottou, Y. Bengio and P. Haffner. Gradient-based learning applied to document recognition. In Proceedings of the IEEE, pages 2278-2324, 1998.

[Willia 92] Ronald J. Willia. Simple Statistical Gradient-Following Algorithms for Connectionist Reinforcement Learning. Machine Learning, 8(3):229-256, 1992.

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

深層学習による海岸保全施設の劣化の新たな予測手法

A new methodology of deterioration prediction using deep learning scheme for coastal facilities

熊谷　兼太郎[*1]
Kentaro Kumagai

藤井　直樹[*2]
Naoki Fujii

[*1] 京都大学経営管理大学院
GSM, Kyoto University

[*2] 東電設計株式会社
Tokyo Electric Power Services CO.,Ltd.

A new framework of a methodology of deterioration prediction using deep learning scheme for coastal protection facilities was proposed. As a basic examination, a deterioration prediction model was developed based on an inspection report of damaged facilities and observed data of wind-direction from 1966 to 1985. According to the simulation results, an average value of accuracy rate of the model was 0.44. Although sufficient accuracy could not be obtained in this trial, points to be considered for further investigations were discussed.

1. 序論

我が国の海岸に設けられた護岸，堤防等の海岸保全施設の延長は 9,600 km に達する．その維持管理は，主に巡視・点検という人の手で行われている．海岸保全施設の維持管理を効率的に行うには，施設の劣化状況を適切に予測する必要がある．

コンクリート構造物の劣化は塩害，中性化，アルカリシリカ反応，凍害，乾燥，摩耗等の多様な機構で生じる．例えば塩害は，コンクリート中の塩化物イオンに起因して鋼材が腐食する現象である．塩化物イオンは，建設時にコンクリート中に入る場合と海からの飛来等により建設後に入る場合とがある．そのうち建設後に入る場合については，表面から浸透していく塩化物イオンの濃度を表面濃度，経過時間，拡散係数等で定式化する手法が提案されている．しかし正確な予測は困難で，また，表面濃度測定のためにコア採取，化学分析等が必要である（和泉ら，2016）．

そこで，これまでにない劣化の新たな予測手法として，多数の劣化事例（ビッグデータ）を用いて劣化の特徴量を発見するアプローチをとることを考える（**図-1**）．海岸保全施設の点検結果は蓄積されてきているし，また，劣化を引き起こす要因のうち環境要因（気温，湿度，海からの塩分を運ぶ風等）は，気象官署等の全国約 1,450 地点の観測値を長期間にわたって入手できる（気象庁，online）．こうしたビッグデータの解析は，深層学習の利用が期待されている分野である．さらに，鬼頭（2015），吉野（2010）等を参考にすれば，地球温暖化等の長期の気象変化をふまえたシナリオを想定することがある程度可能となってきている．想定シナリオを反映させた想定気象データを用意して，施設の劣化予想をある程度の精度で行うことが期待できる．

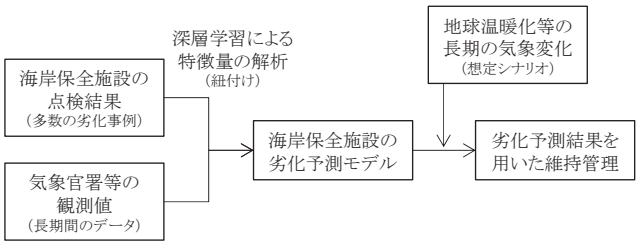


図-1 新たな予測手法の枠組み

連絡先：京都市左京区北白川追分町，Tel. 075-753-5104
kumagai.kentaro.3e@kyoto-u.ac.jp，防災研究所特別研究員

このように，海岸保全施設の劣化の特徴量を発見して劣化予測モデルを構築し，長期の気象変化をふまえた想定シナリオに基づいて劣化予測を行う枠組みを考えた．

本研究は，深層学習により海岸保全施設の多数の劣化事例について施設建設後の環境要因と紐付けた特徴量の解析を行う，海岸保全施設の劣化の新たな予測手法について検討した．

2. 予測手法及び予測結果

既に述べた通り，劣化は多様な機構で生じる可能性があるが，海岸保全施設は海からの影響を受けやすいとの特徴を有した施設であると考え，ここでは基礎的な検討として，大胆な仮定ではあるが劣化の代表的な機構が塩害であると仮定した．また，ここでは基礎的な検討として塩化物イオンが建設後にコンクリート中に入る場合に着目した．塩化物イオンは空気中を飛来するか波しぶきによって運ばれてくるので，海からの風を代表的な環境要因として仮定した．

2.1 劣化事例の抽出と気象データの作成

中島ら（1996）のデータベースから，劣化あり（Positive 群）と劣化なし（Negative 群）のそれぞれ 10 例を抽出した．施設の種類は，直接海に面していて波返し（パラペット）を有する護岸を主として選定した．両群の施設はいずれも建設後平均経過年数が 21.7 年（1985 年時点）で，青森県～長崎県の範囲に所在する．

それぞれの施設の最寄り気象官署等の 20 年間（1966～1985 年，出典：気象庁 online）の気象観測値（日最多風向）を地点ごとに 1 枚の PNG 形式の画像として可視化した．**図-2** に，そのうち 1 地点の例を示す．1 つの図は 86×86 格子で構成されており，左下隅の格子が 1966 年 1 月 1 日の値，その一つ上が同年 1 月 2 日の値，…となる．上まで達すると左から 2 列目一番下の格子に続く．1985 年 12 月 31 日の値は右上隅付近となる．海風（0 度）が赤色，陸風（180 度）が青色である．なお，静穏・欠測の日については 180 度の値を与えた．また，元々の風向のデータは 16 方位で示されているが，施設ごとに海岸線に直交し海に向かう方向（海風となる方向）を 0° として時計周りに角度を与えるようにデータを修正している（**図-3**）．

2.2 予測手法

機械学習のライブラリである Google 社の TensorFlow Ver. 1.5.0 を用い，足立（2017）を参考に，畳み込みニューラルネット

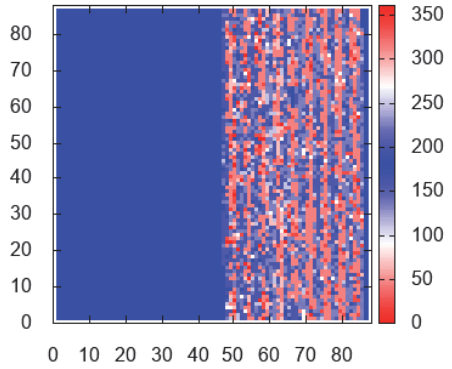


図-2 可視化した日最多風向の例
（海風となる方向から時計回り，凡例の単位：度）

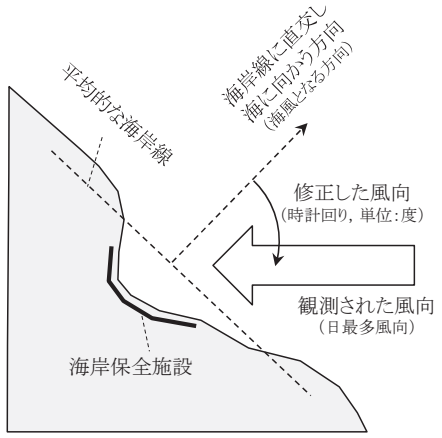


図-3 海風となる方向を基準とした風向データの修正

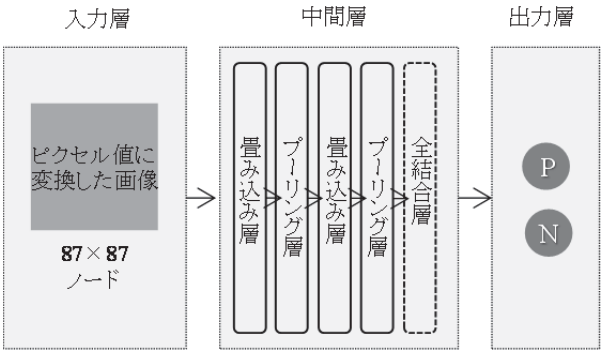


図-4 畳み込みニューラルネットワーク

ワーク（Convolutional Neural Network）の画像分類器を作成した．画像分類器はまず，与えられた画像を学習用データと，モデルの精度を検証するためのテスト用データとにランダムに分ける．次に，学習用データを用いて教師あり学習を行う．**図-4** に，足立（2017）を参考に作成した概略図を示した．CNN の入力層は 87×87 ノード，畳み込み層・プーリング層はそれぞれ 2 層とした．劣化あり（P）または劣化なし（N）の 2 クラスに分類するモデルが出来ると，モデルに基づいてテスト用データを P または N に分類してみて，モデルの精度を示す正答率を算出する．

2.3 予測結果及び考察

劣化予測モデルの正答率平均値は 0.44 となり，今回は十分な精度は得られなかった．

その原因として，空気中を飛来するか波しぶきによって運ばれてくる塩化物イオンについて，ここでは基礎的な検討として日最多風向だけを指標として分析を試みたが，風向だけではなく例えば風速も含めた複合的な指標による分析が必要なことが考えられる．

収集できた劣化事例の制約から，今回は，1985 年以前に建設された比較的古い構造物を分析の対象にした．このような場合は，建設後にコンクリート中に入る塩化物イオンだけでなく，建設時にコンクリート中に入る塩化物イオンの存在についてどう考慮するかという点が今後の課題である．ただし，1986 年から生コンクリートに含まれる塩化物イオンの総量が規制されたことに伴い，建設時に入る塩化物イオンによる塩害は少なくなったとされる（和泉ら，2016）．従って，この点については，1986 年以降に建設された比較的新しい構造物を中心に十分な数の劣化事例を収集すれば，大きな課題とはならない可能性がある．また，環境要因だけでなく，かぶり不足，コンクリートの品質不良等の施工不具合についてどう考慮するかという点が今後の課題である．

また，気象官署等は 1 か所である程度の地理的範囲をカバーしているため，同じ気象条件となる範囲内に複数の海岸保全施設が含まれる場合がある．劣化事例の収集にあたっては出来る限り近傍の施設が同様の劣化度を示している施設を代表として抽出するように試みたが，収集できた劣化事例の制約からこの点は必ずしも十分に考慮できていないため，今後の課題である．

3. 結論

深層学習による海岸保全施設の劣化の新たな予測手法の枠組みを提案した．基礎的な検討として，風向データに基づいて劣化予測モデルを構築した結果，正答率平均値は 0.44 であった．今回は十分な精度は得られなかったが，その原因として考えられる点を今後の課題として整理した．

参考文献

[和泉ら 2016] 和泉意登志・竹田宣典・神谷清志・古賀裕久・鳥取誠一・長尾覚博・濱幸雄・前田俊也・横関康祐：コンクリートの劣化と補修がわかる本 update，コンクリート新聞社，127 p.，2016.

[気象庁 online] 気象庁：過去の気象データ・ダウンロード，http://www.data.jma.go.jp/gmd/risk/obsdl/，最終閲覧日 2018 年 2 月 28 日．

[鬼頭 2015] 鬼頭昭雄：日本の気候はどうなるか，異常気象と地球温暖化，岩波書店，pp. 129-151，2015.

[吉野 2010] 吉野正敏：地球温暖化時代の異常気象，成山堂書店，201 p.，2010.

[中島ら 1996] 中島晋・横田弘・関根好幸・山道広人：海岸保全施設の改良・更新事例集，港湾技術研究所資料，運輸省港湾技術研究所，No. 848，316 p.，1996.

[足立 2017] 足立悠：初めての TensorFlow，リックテレコム，pp. 114-129，2017.

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

低解像度の料理画像を超解像するための SRGAN の応用

Improving SRGAN for Super-Resolving Low Resolution Food Images

永野 雄大 *1　　菊田 遥平 *2
Yudai Nagano　　Yohei Kikuta

*1東京大学
The University of Tokyo
*2クックパッド株式会社
Cookpad Inc.

Super resolution, especially SRGAN, can generate photo-realistic images from downsampled images. However, it is difficult to super-resolve originally low resolution images taken many years ago. In this paper we focus on food domains because it's useful for our service if we can create better looking super-resolved images without losing content information. Based on the observation that SRGAN learns how to restore realistic high-resolution images from downsampled ones, we propose two approaches. The first one is downsampling methods using noise injections in order to create desirable low-resolution images from high-resolution ones for model training. The second one is training models for each target domain: we use {*beef*, *bread*, *chicken*, *poundcake*} domains in our experiments. Comparing to existing methods, we find the proposed methods can generate more realistic super-resolved images through qualitative and quantitative experiments.

1. はじめに

1.1 クックパッドのレシピ画像と超解像

クックパッド*1 は 1998 年から始まった日本最大の料理レシピサービスであり, コンテンツの中心はユーザが投稿する画像とテキストから構成されるレシピである. 画像はレシピを表現する重要な要素であるが, 同じ内容のレシピであっても, カメラやサービスの進化により画像の質には強い時間依存性がある. サービス初期に投稿されたレシピの画像は, 近年のものと比較すると, 解像度が数分の一であったりカメラのノイズが含まれていたりする. 近年の超解像技術を活かし, 投稿者の意図を尊重しつつ画像を高解像度のものへ変換できれば, ユーザにとってより有用なサービスを提供できる可能性が広がる.

1.2 Deep Learning と超解像

Deep Learning によって目覚ましい発展を遂げた研究分野の一つに超解像が挙げられる. SRCNN を筆頭とした Deep Learning を用いた超解像手法は, Bicubic 法などの既存手法と比較すると画質評価指標 PSNR や SSIM などにおいて優秀な成績を収めている.

様々なモデルが既存の評価指標の改善を実現する中, SRGAN [Ledig 16] は人間にとっての見た目を評価する MOS testing において他の超解像手法を凌ぐ性能を発揮している.

2. 目的とアプローチ

本稿では, 過去に投稿された低解像度画像に超解像処理を施し, 料理らしいテクスチャを復元することを目的とする. 特に, 過去に投稿された低解像度画像と近年に投稿されている高解像度画像の解像度や鮮明さの違いをいかに埋めるかを考察・実験し, 実際に投稿された画像への適用可能性を明らかにする.

既存手法である SRGAN は, 4 倍の超解像を行える上に, ピクセル単位よりも人間の評価による見た目を再現することに長けているため, 我々の目的に適している. 本稿では, 超解像画像の見た目の評価を重視し, このモデルに注目して以降の議論を展開する.

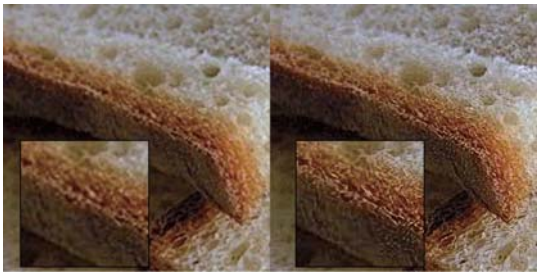


図 1: Bicubic 法 (左) と SRGAN(右) で画像を超解像したもの. SRGAN では画像は鮮明であるが望ましくないテクスチャが生成されている. 画像はクリエイティブ・コモンズの画像 (http://flic.kr/p/6UL1m/).

SRGAN における学習は, 高解像度でノイズの少ない画像とそれを縮小した画像のペアを用いることを想定しており, 元々が低解像度である画像を超解像しても図 1の SRGAN の結果のように望ましいテクスチャを復元できない場合もある.

我々が解決したい問題と解決策として以下の 2 つに着目し, 実験を行う.

- (問題 1) 画像の jpg ノイズやブレなどを修復できない.
  (解決策 1) 高解像画像から対となる低解像度画像を作成する際に, 人為的にノイズを加えることで情報復元を可能とするような学習を促す.
- (問題 2) 料理らしいテクスチャが生成されていない.
  (解決策 2) 特徴的なテクスチャを有する料理ドメイン毎に SRGAN を学習し, 適切なテクスチャの生成を可能とするような学習を促す.

SRGAN は高解像度画像と低解像度画像のペアに基いて学習

連絡先: 永野雄大，東京大学，nagano@nlab.ci.i.u-tokyo.ac.jp
*1 https://cookpad.com

をするため, 解きたい問題に応じた適切なデータセットを構築する, というのが解決策の基本的なアイデアである. この考えを検証するために実際にデータセットを構築してモデルを学習し, 定性的・定量的実験により通常の SRGAN と比較をする.

3. 関連研究と提案評価指標

本章では, SRGAN の特徴と超解像タスクの評価方法について説明する.

3.1 SRGAN

SRGAN は画像の鮮明さを保ちつつ超解像倍率を 4 倍まで上げることに成功したモデルであり, 従来手法で使われていたピクセル単位の誤差と中間層単位の誤差に加えて,GAN の構造を持ち込んだことがその本質である. discriminator は真の高解像度画像と generator から生成される高解像画像を判別するものであり, これらの競合的な学習によって, 人間にとって見た目に美しい画像の生成を可能としている.

興味深いのは, 従来手法と比べて見た目は明らかに改善しているのによく用いられる評価指標においては劣っている, という点である. これは既存評価指標の不十分さや GAN の構造の奥深さを示唆している.

3.2 評価指標

既存手法である PSNR と SSIM を用いる. 前述のようにこれは適切な指標ではないが, 先行研究との乖離がないかを調べるのが主な用途である.

また, 新たな指標として, 1000 クラス分類の ImageNet モデルの出力 sotmax 値 p_c (c はカテゴリ) の平均値を提案する.

$$s_c = \frac{1}{N}\sum_{i=1}^{N} p_c(x_i) \tag{1}$$

ここで, N はテストデータ数, x_i は入力画像を表す. 超解像された画像が特徴的なテクスチャを再現しているならば, 汎用的なモデルはそのテクスチャに近いカテゴリの出力を増幅することが期待されるため, それを測る指標となる.

4. 実験

本章では, データ作成と SRGAN の学習に関して述べる.

高解像度画像は, 基準となる DIV2K [Agustsson 17] と, クックパッドのレシピカテゴリからテクスチャの質やドメインの違いを考慮して選別した 5 種類 { 鶏肉 A, 鶏肉 B, 牛肉, 食パン, パウンドケーキ } の高解像度画像を使用する. 鶏肉のデータを 2 組用意したのは, 同種のデータセットからは類似のテクスチャが生成されることを確認するためである. クックパッドのデータに関しては, まず自動で解像度が不十分なものや重複を排除し, 次にピンぼけやノイズの多い画像を手動で除いている. 学習:テストを 800:100(枚) ずつ準備し, 準備した高解像度画像から低解像度化したコピーを作成することで解像度の異なるペアを準備して実験に用いる.

4.1 低解像度画像の作成

章 2.で述べた通り, 超解像で復元したい情報に着目して低解像度画像を作成することが重要となる. 本稿では, 特にサービスで扱うための圧縮の過程や昔のカメラ性能に起因するピンボケに注目し,jpg ノイズと 2 種類のぼかしを加えて低解像度化する手法を提案する.

jpg ノイズ

画像を圧縮する際などに発生するノイズを再現するため, Python の Pillow ライブラリを用いて jpg のノイズを人為的に加える. jpg の品質が最低 20, 最高 100 となるように一様乱数で全ての画像の画質を下げている.

ぼかし

カメラの性能などに起因するピンボケやブレなどを再現するため, Python の scikit-image ライブラリを用いてフィルタリングを適用する. ぼかし方にも様々な種類があるが, 画像の質を確認しながら選んだメディアンフィルタとガウシアンフィルタの 2 種類を用いる. 画像全体のうち, 50%にはメディアンフィルタ (全てデフォルトのパラメタ), 25%にはガウシアンフィルタ (半分は $\sigma = 1$, もう半分は $\sigma = 2$), 残りはフィルタなし, という処理を施す.

低解像度画像の作成手順を図示したものが図 2である.

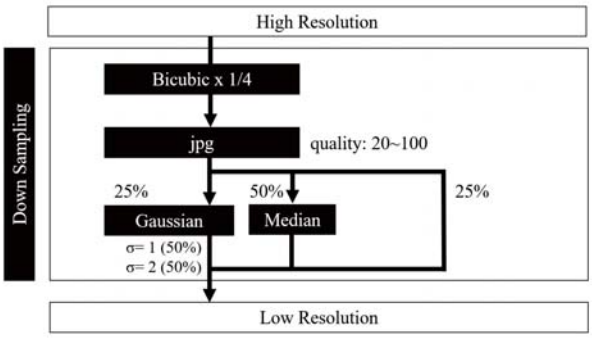


図 2: 低解像度画像の作成ステップ.

4.2 学習

モデルは GitHub の公開レポジトリ*2 に基き TensorFlow で実装する. SRGAN の学習は 2 段階に分かれており, 第 1 段階は SRResNet を出力の MSE で最適化し, 第 2 段階は損失関数に VGG の中間層の MSE と GAN の損失項を加え SRGAN として学習する. VGG 中間層出力には任意性があるが, 原論文でも使われている VGG54 を使用する. バッチサイズは 16, 入力画像は元画像から 96×96, 正解画像はこの 4 倍の 384×384 サイズにランダムクロップしバッチを作成している. Adam のパラメタは学習率以外は TensorFlow のデフォルト値を用いている. 具体的な学習パラメタを表 1に示す.

表 1: SRGAN 学習時のパラメタ

	エポック数	損失関数	最適化	学習率
step 1	100	MSE	Adam	1e-4
step 2-1	1-1000	SRGAN loss	Adam	1e-4
step 2-2	1000-2000	SRGAN loss	Adam	1e-5

1 つのモデルの学習には AWS P3 インスタンスで 1 日程度の時間を要する.

5. 結果と評価

本章では, {DIV2K (Bicubic), DIV2K (jpg), 鶏肉 A, 鶏肉 B, 牛肉, 食パン, パウンドケーキ } のデータセットで学習をし

*2 https://github.com/tensorlayer/srgan

た計 7 つのモデルの結果を示す. ここで, DIV2K(Bicubic) のみは提案手法の低解像度化を使わず, 単純な Bicubic 法での低解像度化を施している. 比較のため, 結果にはこれらのモデルの出力に加えて, HR (元画像), LR (図 2 の手順で低解像度化した画像) も合わせて示す. 低解像度化した画像に関しては, 比較のために Bicubic 法で 4 倍に拡大しスケールを合わせている.

定性評価に関しては, 紙面の都合上, 食パンと牛肉のテスト画像に対する結果の一部のみを示す. 鶏肉とパウンドケーキに関しては, それぞれ牛肉と食パンの結果に近いものが得られた. 結果は効果がある程度顕著に現れたものを紹介しており, 全体的にはどのモデルでも上手くいく画像やどのモデルでも上手くいかない画像も一定数含まれていた. 前者は元々高解像度で画質も良い画像, 後者はノイズやピンボケの程度が強すぎる画像, という傾向が観測された.

5.1 食パン画像の超解像結果と定性評価

図 3に結果を示す. ここでは, 詳細なテクスチャを比較するためにパンの断面部分を拡大して比較している.

DIV2K (Bicubic) はノイズが強調されてあまり画質が向上していないことが確認できる. DIV2K (jpg) は上段と中段はきれいに生成できているが, 下段のように望ましくないテクスチャが生成されているものもある. これは, 様々な画像で学習したモデルでは特定のドメイン依存性の強いテクスチャを十分に学習できていないためと考えられる.

牛肉・鶏肉 A・鶏肉 B は共に出力画像に不自然な光沢のテクスチャが現れる傾向が確認できる. これは肉系統のドメインには脂が乗っている画像も多く, その光沢のテクスチャを強く再現してしまったためと考えられる. また, 鶏肉 A と鶏肉 B は出力の見た目は異なるものの, 光沢があり, 生成テクスチャの傾向が似ているのが分かる. この結果から, 得られた結果が偶然ではなく, SRGAN がドメイン毎の特徴を捉えていることが推測される.

食パンは他のモデルと比較すると, 細部が食パンらしいテクスチャをより適切に生成していることが確認できる. パウンドケーキは食パンほど綺麗に復元できているわけではないが, 望ましくないテクスチャは生成されず, 比較的食パンに近い結果が得られている. これは, 食パンとパウンドケーキのドメインの近さによって生成されるテクスチャも近いものが得られているためと考えられる.

5.2 牛肉画像による超解像結果と定性評価

図 4に結果を示す. 食パンの場合と同様に画像の一部を切り出して比較している.

食パンの場合と同様に, DIV2K (Bicubic) では改善が見られずノイズを強調してしまっている. DIV2K (jpg) では画像は鮮明になっているが, 肉系統のドメインと比較すると, 肉系統に顕著な光沢や質感は再現できていないように見え, 料理画像本来のテクスチャを復元する, という本稿の目的においては不十分な結果である.

牛肉・鶏肉 A・鶏肉 B は, 光沢が豊かで肉類の脂をよく再現できている. 過剰に再現してしまっているが, SRGAN がテクスチャの特徴を顕著に学習できていることが伺える.

食パン・パウンドケーキに関しては, DIV2K (jpg) ほどではないが光沢が少ないように見える. これもドメインの特徴を適切に反映した結果であると考えられる.

5.3 既存評価指標での定量評価

既存の評価指標である PSNR と SSIM を用いてテスト画像に対する評価を実施した. 低解像度化手法の有無やテスト画像にかかわらず, 各ドメインの学習によって得られたモデルにおいて PSNR と SSIM に変化は見られなかったため, 結果は割愛する.

5.4 提案評価指標での定量評価

式 (1) で導入した指標を用いてテスト画像に対する評価を実施する. ImageNet モデルには本稿で用いた食パンや鶏肉などと同一のカテゴリは含まれていないが, *meat loaf* (ミートローフ) や *French loaf* (フランスパン) などのドメインが近いカテゴリが含まれている.

使用した ImageNet モデルは Keras で使用できる VGG16 と Xception である. 結果は同様であったため, ここでは傾向が顕著であった Xception の結果の一部を示す. 予測をする際は超解像した入力画像を 299×299 にリサイズしている.

パウンドケーキのテスト画像に対する結果のうち, スコア上位 3 件を表 2に示す. 食パン・パウンドケーキの *French_loaf* のスコアが肉系のドメインと比べると高く, 牛肉・鶏肉 A・鶏肉 B の *meat_loaf* のスコアがパン系のドメインと比べると高い. この結果から, SRGAN がドメイン毎のテクスチャを適切に学習し, そこから復元された画像は ImageNet のモデルによって近いドメインのカテゴリと認識されやすくなっているものと推測される. しかし, この指標は SRGAN の特徴の一部を捉えていはいるものの, DIV2K (jpg) の *French_loaf* のスコアも高くなっているなど, 不十分な指標である可能性もある.

6. 結論とディスカッション

SRGAN に対し, ノイズを加えた低解像度画像の作成やドメイン毎にデータを分割してモデルを作成・比較することで, 定性的・定量的に性能が向上することを示した.

定性的には, jpg ノイズの除去やドメインに適したテクスチャを復元できることが観測され, SRGAN が我々の目的にも有効であることが明らかとなった.

定量的には, ImageNet モデルの出力を比較することで, 対象のドメインに近い ImageNet のカテゴリへのスコアが高くなることが確認された. しかしこれは定量評価として不十分な点も含んでいる. その他にも 2 次元離散フーリエ変換を用いた周波数領域での比較や, 出力画像の Inception score の算出も行ったが大きな違いは見出されなかった. 人間にとっての見た目を適切に反映した定量的な評価指標を考案するということは, この分野の課題の一つとして残っている.

本稿での提案手法はあらゆる画像で上手くいくものではないため完全に自動化した上でサービスに導入することは難しいが, 適切に対象を絞ることや, 人手でのチェックと組み合わせることでサービスに導入していくことを検討している.

参考文献

[Agustsson 17] Agustsson, E. and Timofte, R.: NTIRE 2017 Challenge on Single Image Super-Resolution: Dataset and Study, in The IEEE Conference on Computer Vision and Pattern Recognition (CVPR) Workshops (2017)

[Ledig 16] Ledig, C., Theis, L., Huszár, F., Caballero, J., Cunningham, A., Acosta, A., Aitken, A., Tejani, A., Totz, J., Wang, Z., et al.: Photo-realistic single image super-resolution using a generative adversarial network, arXiv preprint (2016)

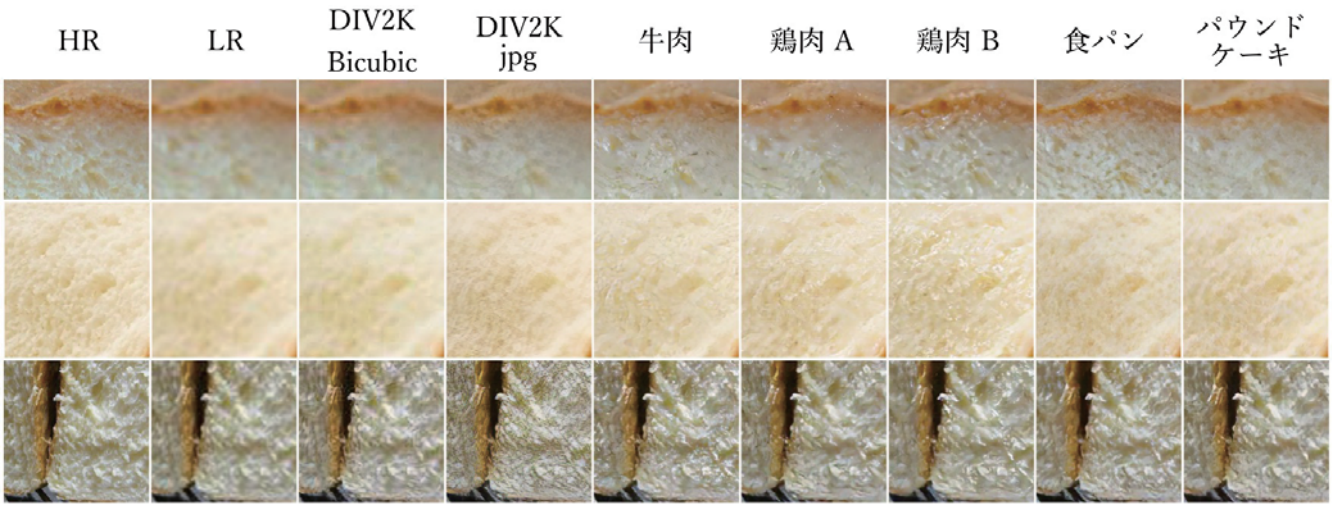


図 3: 各学習モデルによる食パン画像の超解像結果を切り出したもの. 画像は 2018 年 3 月 8 日時点で上から順に (レシピ名, レシピ作者, URL) のレシピ画像を使用. (HB で☆リッチな卵ミルク食パン, ジョンリークッカー, https://cookpad.com/recipe/690987). (HB*超リッチ♪生クリームと練乳の絹パン, ねっちゃんっ, https://cookpad.com/recipe/983984). (ハチミツレモンブレッド, はなむん, https://cookpad.com/recipe/397851).

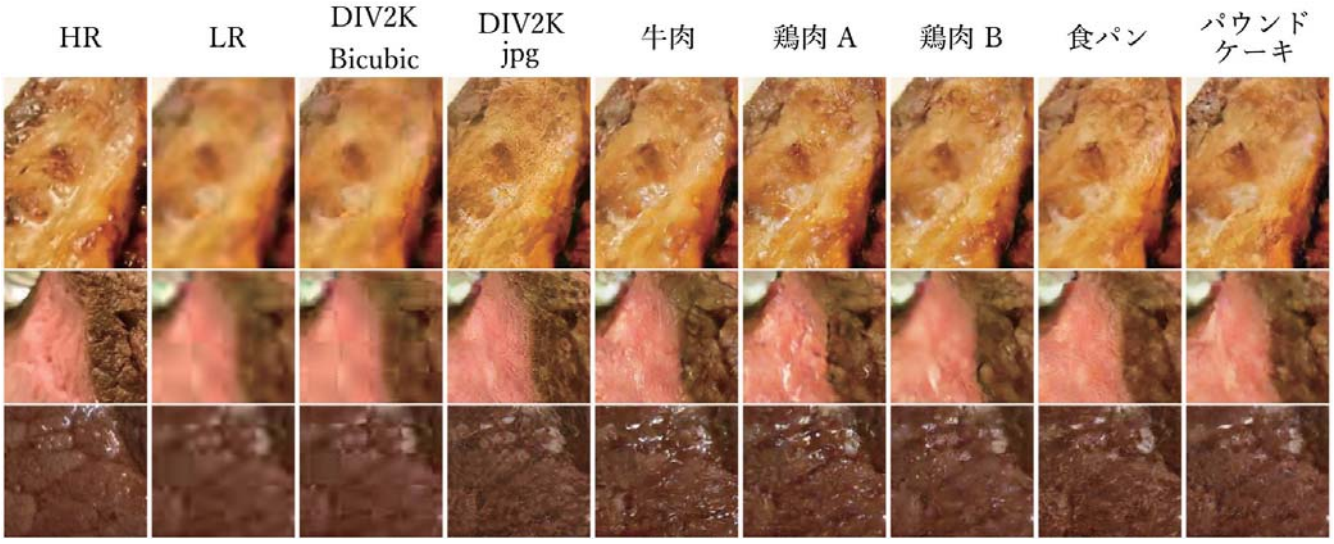


図 4: 各学習モデルによる牛肉画像の超解像結果を切り出したもの. 画像は 2018 年 3 月 8 日時点で上から順に (レシピ名, レシピ作者, URL) のレシピ画像を使用. (どんな材料でもお手軽☆味噌漬け焼き, AyakoOOOOO, https://cookpad.com/recipe/1008812). (ローストビーフをフライパンで作ろう！, はーたんのおっかさん, https://cookpad.com/recipe/1900893). (安いお肉を美味しいステーキにする方法♪, ElisabethF, https://cookpad.com/recipe/2767568).

表 2: Xception を用いたテスト用画像 (パウンドケーキ) に対する提案評価指標の結果.

rank	LR	HR	DIV2K (jpg)	牛肉	鶏肉 A	鶏肉 B	食パン	パウンドケーキ
1	French_loaf (**0.34**)	French_loaf (**0.31**)	French_loaf (**0.34**)	French_loaf (0.20)	French_loaf (0.23)	French_loaf (0.23)	French_loaf (**0.34**)	French_loaf (**0.32**)
2	plate (0.15)	plate (0.16)	plate (0.12)	meat_loaf (**0.18**)	meat_loaf (**0.17**)	plate (0.16)	plate (0.12)	plate (0.13)
3	potpie (0.11)	meat_loaf (0.11)	meat_loaf (0.08)	plate (0.18)	plate (0.16)	meat_loaf (**0.14**)	meat_loaf (0.07)	meat_loaf (0.11)

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

活性固定化による深層学習モデルの視覚的説明の鮮明化

Enhancing Visual Explanation of Deep Neural Networks by Activation Freezing

原 聡
Satoshi Hara

大阪大学 産業科学研究所
The Institute of Scientific and Industrial Research, Osaka University

The "black box" nature of deep neural networks hinder us from inspecting the logic hidden inside the networks. To alleviate this difficulty, for image recognition tasks, several visual explanation methods are proposed. The aim of visual explanation is to highlight a segment of the image as a clue of the network's recognition. In this paper, we propose a method for enhancing the highlights of the existing visual explanation methods. In the proposed method, we *freeze* the activations of the some of the network nodes in middle layers. With the proposed method, we can obtain clear highlights with less noises than the existing methods.

1. はじめに

深層学習モデルは画像認識など多くの問題で高い認識性能を誇る。しかしながら、深層学習モデルのその複雑な内部のネットワーク構造がゆえに、モデルがどのような認識機構に基づいて画像認識を行っているかを人間がうかがい知ることはできない。このような深層学習モデルのブラックボックス性は、深層学習モデルを実用する上で大きな障害となる [1]。例えば、病気の診断やローンの審査などの人間の生活に深く関わる問題では、医師や銀行は患者や顧客に最終的な判断結果だけでなくその結果に至った理由を説明する責任を有する。深層学習モデルはそのブラックボックス性がゆえに判断結果についての説明能力を持たないため、このような問題へと安易に適用することはできない。

深層学習モデルのブラックボックス性を緩和して説明性を高めるために、特に画像認識の分野において視覚的な説明性を向上させる方法の研究が進められている [2, 3, 4, 5, 6]。これら視覚的な説明では、深層学習モデルが画像中のどの領域を根拠に認識を行なっているか、その認識対象を特定してハイライトする。図 1 にハイライトの一例を示す。このような説明法を用いることで、モデルが画像中の対象を適切に認識しているか、それとも誤った対象を根拠に誤認識しているか、を人間が事後的に検証できるようになる。

既存の視覚的説明法にはハイライトに多くのノイズが載るという欠点がある。ハイライトがあまりにも多くのノイズを含む場合、モデルが適切に対象を捉えているか否かを人間が視覚的に検証することが困難となる。そのため、ノイズを含まない鮮明なハイライトこそが良い視覚的説明であると言える。

本研究では鮮明なハイライトを得るための前処理方法として**活性固定化**を提案する。既存の視覚的説明法ではハイライトを生成する際に、深層学習モデルのネットワーク全体の構造を利用している。これに対し、活性固定化ではまず前処理として深層学習モデルの認識に寄与している主要な構造だけを残して、残りの非主要部を枝刈りする。その後で既存の視覚的説明法でハイライトを生成する。このように前処理として活性固定化によりモデルの非主要部を枝刈りすることで、非主要部に由来するノイズを除去した鮮明なハイライトを生成できる。なお、活性固定化はモデルへの前処理であるため、任意の視覚的説明法と組み合わせることができる。

連絡先: 原 聡 satohara@ar.sanken.osaka-u.ac.jp

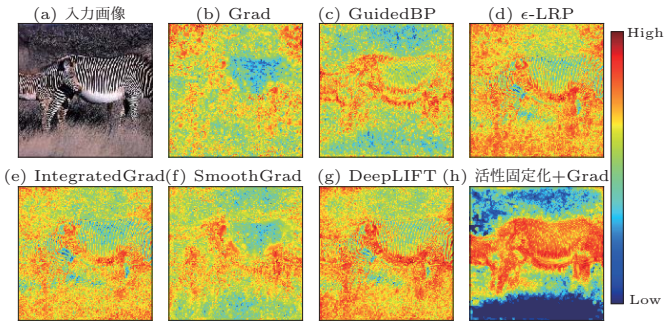


図 1: 深層学習モデルの視覚的説明：入力画像 (a) を深層学習モデルがシマウマと認識した根拠を既存の説明手法 (b)–(g) 及び提案法 (h) でハイライトした結果。詳細は 4. 節を参照。

図 1(h) に活性固定化を用いた視覚的説明の一例を示す。既存の視覚的説明法、例えば GudedBP [2] や ϵ-LRP [3], IntegratedGrad [4], SmoothGrad [5], DeepLIFT [6] といった説明法ではノイズを多く含むハイライトが生成されるのに対し、これらの方法に活性固定化を前処理として導入することで鮮明なハイライトが生成できる。

2. 深層学習モデルとその視覚的説明法

本節では本研究で扱う深層学習モデルについて述べる。また深層学習モデルの視覚的説明法の代表的な方法として勾配に基づく方法を紹介する。

2.1 本研究で扱う深層学習モデル

本研究では入力 $x \in \mathbb{R}^p$ を受け取り出力 $y(x) \in \mathbb{R}^q$ を返す $L+1$ 層の q クラス分類のための深層学習モデルを考える。ここで、モデルの第 ℓ 層への入力とその出力をそれぞれ $z^{(\ell-1)}(x), z^{(\ell)}(x)$ とする。なお、モデルの出力 $y(x)$ や中間層の入出力 $z^{(\ell-1)}(x), z^{(\ell)}(x)$ は入力 x に依存する関数であることを明示するために引数に x を持つ関数として記述することとする。このとき、入力 x を受け取る第 1 層において $z^{(0)}(x) = x$、また出力 $y(x)$ を返す第 L 層において $z^{(L)}(x) = y(x)$ である。本研究では特にネットワークの各層で活性化関数として

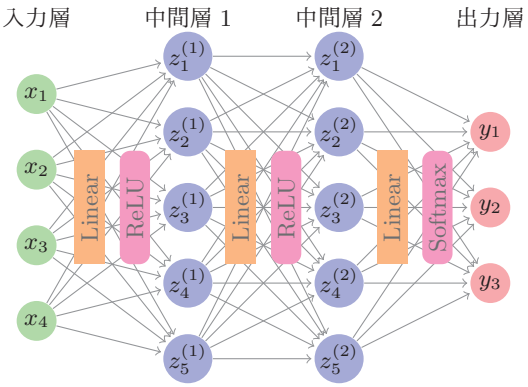


図 2: 4 層の深層学習モデルの例: Linear, ReLU/Softmax はそれぞれ各層の線形変換及び活性化関数である。図中の有向辺は出口側の変数が入口側の変数に依存する関数であることを示している。

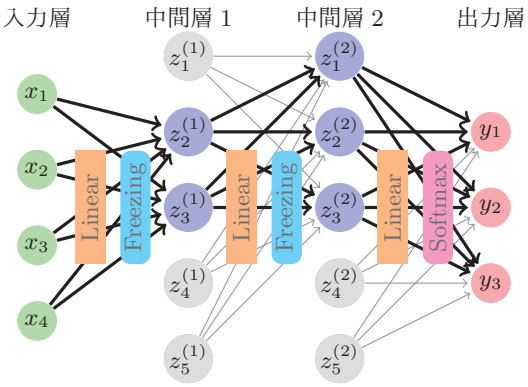


図 3: 活性固定化のイメージ図：活性化関数として活性固定化 (Freezing) を使うことで、入力 x の認識に寄与する主要な構造として太線部が抽出される。$z_1^{(1)}, z_4^{(1)}, z_5^{(1)}$ 及び $z_4^{(2)}, z_5^{(2)}$ が活性が固定化されて定数に置き換えられたノードである。

Rectified Linear Unit (ReLU) を用いる以下のようなモデルを考える。

$$z^{(\ell-1/2)}(x) = W^{(\ell)} z^{(\ell-1)}(x) + b^{(\ell)}, \tag{1}$$

$$z_i^{(\ell)}(x) = f_{\mathrm{ReLU}}(z_i^{(\ell-1/2)}) = \max\{0, z_i^{(\ell-1/2)}(x)\}, \forall i. \tag{2}$$

ここで式 (1) の $W^{(\ell)}, b^{(\ell)}$ は第 ℓ 層での線形変換のパラメータであり、また式 (2) は $z^{(\ell-1/2)}(x)$ の各要素 $z_i^{(\ell-1/2)}(x)$ についてゼロ以下の値のものをゼロに切り上げる操作である。ただし、最終層 $\ell = L$ では式 (2) の ReLU の代わりに活性化関数として以下の Softmax 関数を用いる。

$$z_i^{(L)}(x) = \frac{\exp\left(z_i^{(L-1/2)}(x)\right)}{\sum_{j=1}^{q} \exp\left(z_j^{(L-1/2)}(x)\right)}. \tag{3}$$

図 2 に 4 層の深層学習モデルの例を示す。

2.2 深層学習モデルの視覚的説明法

既存の視覚的説明法の多くはモデルの勾配を元にハイライトを生成する。出力 $y(x)$ の j 番目の要素 $y_j(x)$ に寄与している入力 x の要素をハイライトする最も単純な方法は $y_j(x)$ に対して x の各要素 x_i に関する勾配を計算することである。これは、入力の要素 x_i を微小変化させたときに出力 $y_j(x)$ が大きく変化する要素 x_i こそがモデルの出力に大きく貢献している要素、つまり認識対象としてハイライトすべき対象であるとするアイディアである。具体的には、入力要素 x_i の出力 $y_j(x)$ への貢献度（ハイライトの大きさ）を以下で定義する。

$$\mathrm{Highlight}(x_i) = \left| \frac{\partial y_j(x)}{\partial x_i} \right|. \tag{4}$$

式 (4) の勾配に基づく方法は計算が簡単な一方、ハイライトが多くのノイズを含むことが知られている。そこで、勾配に修正を加えた方法 [2, 3, 6] や勾配の平均を用いてノイズを低減させる方法 [4, 5] など、様々な改善法が提案されている。

3. 提案法：活性固定化

本節では、提案法の活性固定化の基本的なアイディアとその具体的な方法について述べる。活性固定化を前処理として用いることで、既存の視覚的説明法により生成されるハイライトからノイズが低減され鮮明なハイライトの生成が可能となる。

以下、本研究では説明対象の深層学習モデルは学習済みであり、その構造及びパラメータは与えられているとする。また、説明対象の入力 x も与えられ固定されているとする。

3.1 基本的なアイディア

提案法の基本的なアイディアは『ハイライト生成時に、認識に寄与するネットワークの主要な構造のみを用いる』というものである。従来の説明法ではハイライトを生成する際に深層学習モデルのネットワーク全体を用いていた。しかし、このような全体を用いるアプローチではネットワーク内で認識にほぼ寄与していない非主要部の影響をもハイライト生成の際に加味してしまう。本研究ではこのような非主要部の影響がハイライトにノイズとして載っているのではないかという仮説を取る。そして、この仮説に基づいて、ハイライト生成の際に非主要部の影響を排除することで鮮明なハイライトを生成することを目指す。

図 3 に提案法の活性固定化のイメージを示す。活性固定化ではネットワーク中の弱い信号しか伝搬していない辺を認識に寄与しない非主要部として枝刈りする。この枝刈りにより、出力 $y(x)$ は強い信号だけを伝搬させるネットワークの主要部を通じてのみ入力 x に依存するようになる。このように弱い信号しか伝搬させない辺を刈ることで、入力 x の微小変化の影響の多くは出力 $y(x)$ までたどり着かなくなる。つまり、入力 x の微小変化の多くは出力 $y(x)$ に影響しなくなる。その結果、強い信号が伝搬している経路に対応する入力 x の要素の微小変化のみが出力 $y(x)$ に影響しえる要素として、つまりハイライトすべき認識対象として特定できる。

3.2 活性固定化の方法

ここでは活性固定化の具体的な方法について述べる。前節で述べたように、本研究ではネットワークの主要な構造のみをハイライト生成に用いることを考える。活性固定化はこのような主要な構造のみをネットワークから抽出する前処理である。

本研究ではネットワークの各層において強い信号が伝搬しているノードとそうでないノードとを区別して考える。いま入力 x が与えられ固定されている状況を考えているので、各層におけるノードの関数 $z_i^{(\ell)}(x)$ の具体的な値 $v_i^{(\ell)} = z_i^{(\ell)}(x)$ を計算できる。そこで、この値 $v_i^{(\ell)}$ がある閾値よりも大きい場合に、そのノードは強い信号を伝搬させるネットワークの主要部だと

判定する。逆に、$v_i^{(\ell)}$ が閾値より小さい場合にはそのノードは弱い信号しか伝搬させないネットワークの非主要部だと判定する。

活性固定化では、活性化関数として ReLU の代わりにネットワークの主要部、非主要部に対応した以下のような Freezing 関数を用いる。

$$z_i^{(\ell)}(x) = f_{\text{Freezing}}(z_i^{(\ell-1/2)}(x); t^{(\ell)}) = \begin{cases} z_i^{(\ell-1/2)}(x) & \text{if } z_i^{(\ell-1/2)}(x) \geq t^{(\ell)}, \\ v_i^{(\ell)} & \text{otherwise.} \end{cases} \quad (5)$$

ここで $t^{(\ell)}$ は Freezing 関数のパラメータで、ネットワークの主要部・非主要部を判定するための閾値である。閾値 $t^{(\ell)}$ の具体的な与え方については 4. 節にてその一例を示す。Freezing 関数は閾値 $t^{(\ell)}$ よりも強い信号が伝搬するノードをネットワークの主要部として信号を通し、閾値 $t^{(\ell)}$ よりも弱い信号が伝搬するノードでは活性化関数を定数で置き換える処理を行う。本研究では後者の定数による活性化関数の置き換えを活性の固定化と呼ぶこととする。Freezing 関数の特徴はこの固定化を通じて関数 $z_i^{(\ell)}(x)$ の入力 x への依存性を除去する、つまりネットワークの枝刈りを行う点にある。図 3 に活性固定化の適用例を示す。活性固定化で弱い信号が伝搬する部分の辺を刈ることで、十分大きな信号だけが伝搬しているネットワークの主要な構造を抽出したモデルを構築できる。

4. 実験

本節では活性固定化の有効性を確認するための実験とその結果について述べる。

4.1 実験設定

本実験では説明対象の深層学習モデルとして Tensorflow のリポジトリで配布されている学習済みの VGG16 [7] を用いた。VGG16 は ImageNet [8] という 1000 クラスの画像を認識・分類するための深層学習モデルである。また、説明対象の入力画像には COCO データセット *1 を用いた。COCO データセットは 8 種類の動物の写真を含むデータセットである。

活性固定化で用いる各層の閾値 $t^{(\ell)}$ は以下のように設定した。まず、説明対象の入力 x が与えられたときの第 ℓ 層の各出力の値を $v_i^{(\ell)} = z_i^{(\ell)}(x)$ とする。このとき、これらの値 $v_i^{(\ell)}$ の多くは ReLU による活性化のためにゼロを取る。そこで、正の値を取る出力の集合 $\{v_i \mid v_i > 0\}$ を考え、この集合の p%分位点を閾値 $t^{(\ell)}$ とした。本実験では p の値は 80 で固定した。これは、ReLU を通過した信号の経路の上位 20%のみを主要なネットワークとして抽出することに相当する。

実験では視覚的説明法として Grad（式 (4)）, GuidedBP [2], ϵ-LRP [3], IntegratedGrad [4], SmoothGrad [5], そして DeepLIFT [6] の計 6 種類を用いた *2。そして、これら 6 種類の説明法全てについて活性固定化を前処理として用いなかった場合と用いた場合とを比較した。

4.2 実験結果

図 4–6 に示す通り、全ての結果において活性固定化を用いることでノイズの少ない鮮明なハイライトを生成できた。

図 4 では、活性固定化を前処理として施すことで、活性固定化なしの場合よりも鮮明なハイライトが生成されていることを確認できる。特に、活性固定化を用いない場合はハイライトが全体的に明るくなり認識対象のシマウマが適切にハイライトできていないのに対し、活性固定化を用いた場合はシマウマの胴体部分だけをハイライトすることに成功した。

図 5 においても、図 4 同様に活性固定化を使うことで認識対象の馬車をより鮮明にハイライトできた。特に大きな差異として、活性固定化を使った場合には地面のハイライトを認識に関係ないものとして十分低く抑えることができた。この点は、ノイズを多く含み全体的に明るいハイライトになりがちな既存の説明法に対する、活性固定化を用いることの明確な優位点であると言える。

図 6 は本来「馬」に分類されるべき画像が誤って「野球選手」として誤認識された画像とそのハイライトである。活性固定化を用いたハイライトでは、馬だけでなく背景にも大きな値が割り振られていることがわかる。このことから、深層学習モデルが背景を野球場と勘違いしたことで画像を「野球選手」と誤認識したと推測できる。これに対し、活性固定化を用いない場合では明確なハイライトが得られず、画像のどの領域が誤認識の原因となったかを推測することは困難である。この結果は鮮明なハイライトが得られる活性固定化の実用上の有用性を示している。

5. まとめ

本研究では、深層学習モデルの視覚的説明をより鮮明にするための方法として、活性固定化というモデルの前処理法を提案した。活性固定化では、入力中の認識対象をハイライトする前に入力と閾値に基づいてモデルのネットワークの枝刈りを行い、強い信号が伝搬する主要な構造だけを抽出する。そして、抽出された主要な構造だけを対象に既存の説明法で認識対象をハイライトする。このような前処理を導入してネットワーク中の認識にほぼ寄与していない部分に由来するノイズを除去することで、ハイライトを鮮明にすることができる。VGG16 を用いた実験では、活性固定化を既存のどの説明法と組み合わせても非常に鮮明なハイライトを生成できることが確認できた。また、このような鮮明なハイライトがモデルの誤認識の原因を特定するために有用であることも確認できた。

参考文献

[1] Finale Doshi-Velez and Been Kim. Towards a rigorous science of interpretable machine learning. *arXiv:1702.08608*, 2017.

[2] Jost Tobias Springenberg, Alexey Dosovitskiy, Thomas Brox, and Martin Riedmiller. Striving for simplicity: The all convolutional net. *arXiv:1412.6806*, 2014.

[3] Sebastian Bach, Alexander Binder, Grégoire Montavon, Frederick Klauschen, Klaus-Robert Müller, and Wojciech Samek. On pixel-wise explanations for non-linear classifier decisions by layer-wise relevance propagation. *PloS ONE*, 10(7):e0130140, 2015.

[4] Mukund Sundararajan, Ankur Taly, and Qiqi Yan. Axiomatic attribution for deep networks. *arXiv:1703.01365*, 2017.

*1 `cs231n.stanford.edu/coco-animals.zip`

*2 Grad, GuidedBP, SmoothGrad の計算には `https://github.com/PAIR-code/saliency` を改変したものを、ϵ-LRP, IntegratedGrad, DeepLIFT の計算には `https://github.com/marcoancona/DeepExplain` をそれぞれ用いた。

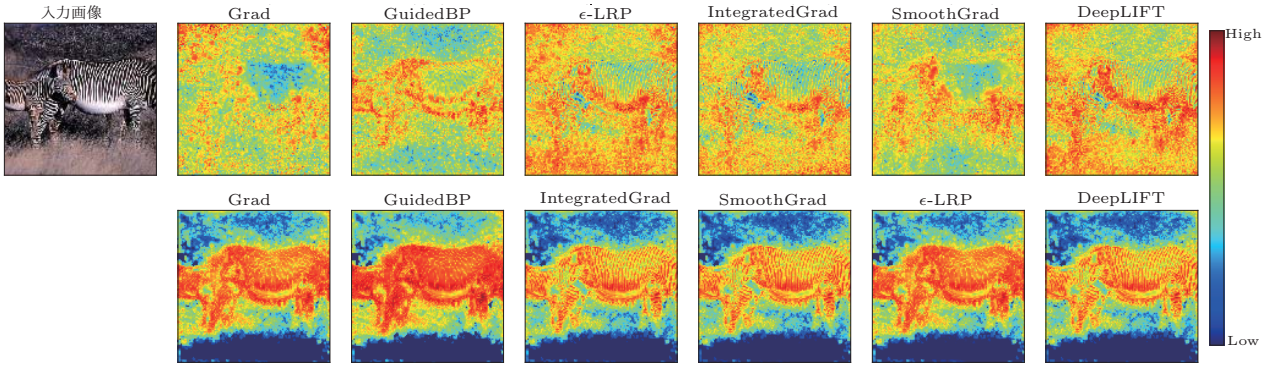


図 4: 活性固定化の適用結果 1 [認識結果 = シマウマ]：（上段）活性固定化なし；（下段）活性固定化あり。

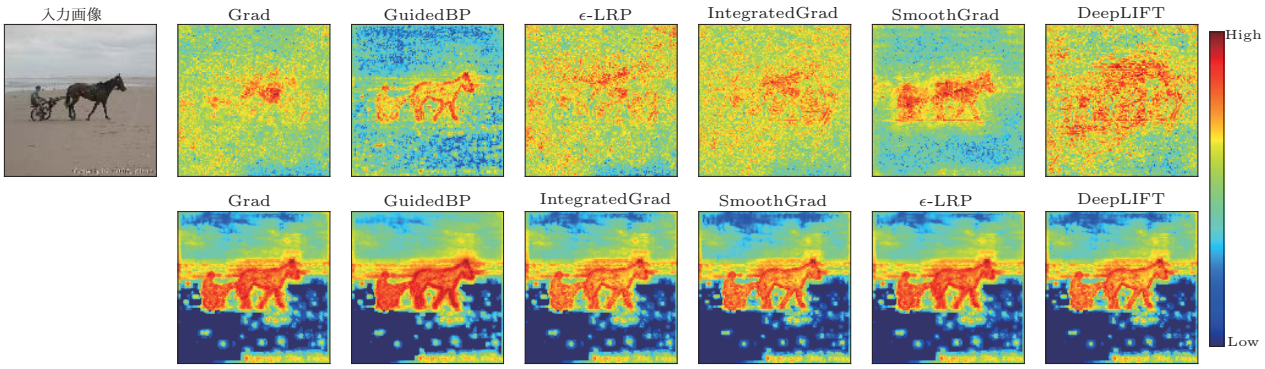


図 5: 活性固定化の適用結果 2 [認識結果 = 馬車]：（上段）活性固定化なし；（下段）活性固定化あり。

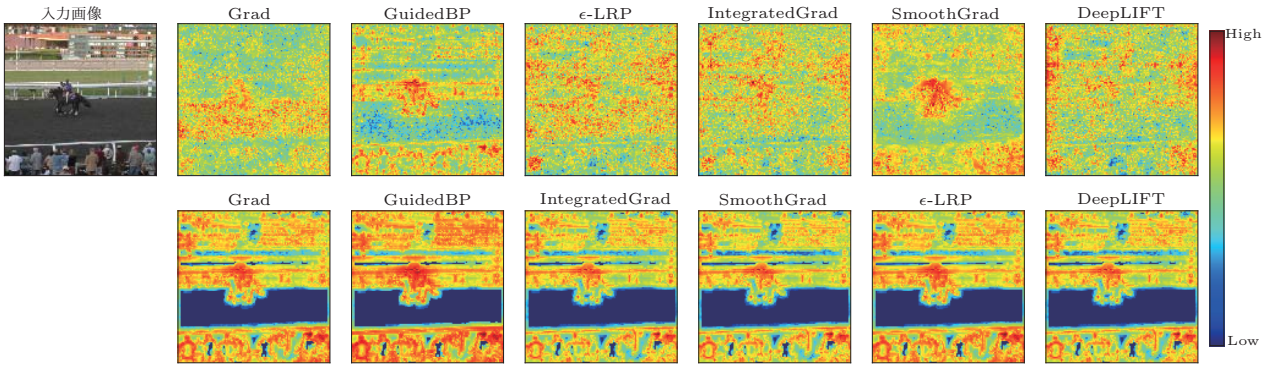


図 6: 活性固定化の適用結果 3 [認識結果 = 野球選手]：（上段）活性固定化なし；（下段）活性固定化あり。

[5] Daniel Smilkov, Nikhil Thorat, Been Kim, Fernanda Viégas, and Martin Wattenberg. Smoothgrad: removing noise by adding noise. *arXiv:1706.03825*, 2017.

[6] Avanti Shrikumar, Peyton Greenside, and Anshul Kundaje. Learning important features through propagating activation differences. In *Proceedings of International Conference on Machine Learning*, pages 3145–3153, 2017.

[7] Karen Simonyan and Andrew Zisserman. Very deep convolutional networks for large-scale image recognition. *arXiv:1409.1556*, 2014.

[8] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E Hinton. Imagenet classification with deep convolutional neural networks. In *Advances in Neural Information Processing Systems*, pages 1097–1105, 2012.

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

類似度学習を用いた敵対的訓練による特徴表現の検閲

Similarity Learning Based Adversarial Training for Censoring Representatoins

岩澤 有祐 *1　　松尾 豊 *1
Yusuke Iwasawa　　Yutaka Matsuo

*1東京大学工学系研究科
The University of Tokyo

Deep neural networks (DNN) continuously demonstrates excellent performance in various application domains. However, how to control the representations is critical issues to use DNN in real-world scenarios. Notably, control the invariance of the representations is essential to incorporate social constraints, such as privacy-protection and fairness. This paper proposes a novel way to control the representations learned by DNN, called "similarity confusion training". Empirical validations on an task of learning anonymous representations from the data of wearables shows that the proposed method successfully remove unwanted information with less performance degradation compared to the existing methods.

1. はじめに

データから有用な表現を学習する深層ニューラルネットワーク（以降 DNN と表記する）は，画像認識や音声認識をはじめ多種多様なタスクで予測精度を向上させることが報告されており，実世界での利用に期待が集まっている．一方，実世界への適用を考えると，認識精度だけでなくさまざまな社会的な制約が問題になる場合がある．例えば社会システムの一部として機械学習を利用する場合は，人種や性別など，公平性に問題があるような情報を含む表現を判断に利用しないことが求められる [Louizos 16, Edwards 16]．あるいは，プライバシーの観点からはデータにあるユーザ個別の情報に過剰にアクセスしないことが望ましい場合もあるだろう [Edwards 16, Iwasawa 17]．しかし，深層学習は最適化の結果としてブラックボックスに表現を獲得するだけであり，獲得した表現がどのような情報を持つかを事前に予期することは容易ではない．このような背景から，DNN が学習した/する表現が特定の情報を利用していないかを検閲するような技術（英語では *censoring representations* と呼ばれる）に関する研究が進められている．

表現の検閲を実現する最も単純な方法の 1 つは，本来最適化したい目的関数（例えば，予測したい情報 y に関する交差エントロピー）に,「違反度合い」を定量化した指標を正則化項として陽に組み込む方法である．このクラスに属する手法の 1 つに，近年提案された敵対的特徴学習（*adversarial feature leaning; AFL*) がある（図 1-a）[Edwards 16, Iwasawa 17, Xie 17]．敵対的特徴学習では，現在の特徴表現 z が望ましくない因子 s についてどの程度の情報を持っているかを，識別器 D による z から s の分類しやすさとして定量化し，識別器 D が予想しにくくなる（敵対的な）方向に特徴表現 z を修正する（より厳密な定式化については．2.1 節で言及する）．敵対的特徴学習は，Maximum Mean Discrepancy といった統計的な尺度を利用した手法群 [Zemel 13, Louizos 16] と比較して高精度な検閲が報告されている．

本稿では，z と s の単一ペアに依存した従来の敵対的特徴学習の代わりに，2 つのサンプルに紐付いた特徴表現 z_1, z_2 が同じグループに属するかを判別する類似度識別器を用いた敵対的訓練の枠組み（類似度学習を用いた敵対的訓練）を提案する（図 1-b）．既存のクラス分類に基づく敵対的特徴学習（以降 AFL と表記する）の問題点として，s が複雑になると分類タスクが複雑になりかつ騙すのが簡単になるという問題がある（例えば，s が 100 クラスのユーザ ID であった場合，この識別器を騙すためには 99 クラスのどれかに予想させるようにすれば良い）一方で類似度学習を用いた敵対的訓練では，1 つのサンプル z から対応する s を判別する識別器を騙すように E を更新する代わりに，2 つのサンプル z_1 と z_2 が同じ s に属するかを判別する識別器 D_{sim} の情報を利用した学習をおこなう．類似度学習を用いた敵対的訓練では s がどのような形式であっても識別器のタスクは 2 クラス分類であり，結果として s が複雑な場合でも安定した学習が行えることが期待できる．

本稿の主要な貢献は次の 2 つである．(1) 類似度学習を敵対的特徴学習に組み合わせた新たな枠組みを提案した．本手法は，類似度学習と敵対的特徴学習を橋渡しする初めての試みであり，類似度学習の発展的な手法を利用した敵対的特徴学習の高精度化に繋がるものである．(2) 提案した枠組みに基づく具体的な方法として，Similarity Confusion Training（SCL）と Learned Similarity Maximization（LSM）の 2 つを提案した．また，SCL および LSM が既存手法と比較してよい性能を達成できることを，ウェアラブルセンサを用いた行動認識におけるユーザ匿名化タスクにおいて確認した．

連絡先: 岩澤有祐，東京大学工学系研究科技術経営戦略学専攻，
iwasawa@weblab.t.u-tokyo.ac.jp

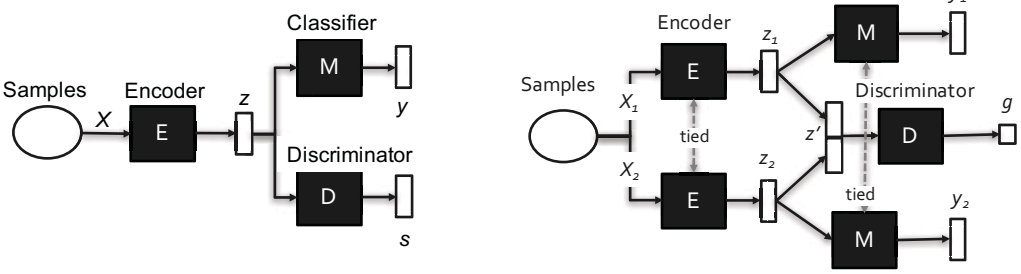
2. 関連研究

2.1 敵対的特徴学習

1 章で言及したように，敵対的特徴学習 *(adversarial feature leaning)* とは，DNN が学習する表現 z が本来予測したかった対象 y についての情報を含みながら別の因子 s に関する情報を持たないように明示的に制約を加える方法の 1 つである．以降，X を入力データ，E を X を z に変換する符号化器，M を z から y を予測する分類器とする．定式的には，AFL は次の最適化問題を解く．

$$\min_{E,M}\max_{D}\mathbb{E}[-\log q_M(y|z=E(X))+\lambda\log q_D(s|z=E(X))]. \tag{1}$$

ただし，q_M および q_D はそれぞれ M と D でパラメタ化された条件付き分布であり，λ は制約の強さを制御するハイパーパ



(a) クラス識別器を用いた敵対的特徴学習.　　(b) 類似度学習を用いた敵対的特徴学習.

図 1: クラス識別器を用いた敵対的特徴学習と（a，既存手法）と，類似度学習を用いた敵対的特徴学習（b，提案手法）の比較．(a) クラス識別器を用いた敵対的特徴学習では，不変性を確保したい因子 s を予測する識別器 D を騙すように符号化器 E を更新する．(b) 敵対的類似度学習では，2 つのサンプル X_1 と X_2 が同じ s に属するかに基づくグループラベル g を予測する類似度識別器 D を利用する．具体的な実装例については 3 章を参照されたい．

ラメタである．(1)E を固定した上での D の更新（式 1 の第 2 項の最大化），(2) D を固定した上で式 1 全体の最小化，の 2 つのステップを交互に繰り返す（あるいは，Gradient reversal layer[Ganin 16] を利用した場合は同時に学習する）ことにより AFL では z が持つラベル y に関する情報量の最大化と s に関する情報量の最小化を同時に行う．

2.2 類似度学習

類似度学習 (*Similarity learning*) とは，2 つのサンプルを入力にそれらのサンプルが同一のグループに属するかを判定する機械学習のタスクの 1 種である．類似度学習を定式化する方法には単純なクラス分類を用いるもの [Vo 16]，Saiamese 構造を用いるもの [Lin 15, Wang 15]，トリプレット損失を用いるもの [Wang 14, Parkhi 15]，より最近の方法では Angular 損失を利用したもの [Wang 17] などいくつかの種類がある．ここでは画像マッチングのタスクで良い精度が出ることが報告されており，本稿でも利用する Saiamese 構造とクラス分類を利用したハイブリットな方法の定式化 [Vo 16] について説明する．

以降，X_1 および X_2 を訓練集合 $\mathcal{X}$ から得られたサンプルであるとする．この時，クラス分類に基づく類似度学習では，X_1 と X_2 が同じグループに属する（あるいは，近くであると判定して欲しい）場合を正例，そうでない場合には 0 を出力するように訓練する．定式的には，g を X_1 と X_2 が同じグループに属する場合には 1，そうでない場合には 0 を取るようなグループラベルであるとすると，

$$-\mathbb{E}[g \log q_{D_{sim}}(g|z') + (1-g)\log(1-q_{D_{sim}}(g|z'))] \quad (2)$$

を最小化するように特徴抽出器 E および類似度識別器 D_{sim} を学習する．ただし，z' は 2 つの特徴量 z_1 と z_2 を特徴方向に結合したものとする（すなわち，z' の次元は z_1 および z_2 の 2 倍になる）．

類似度学習は主に顔画像の同一性判定や検索に利用されてきたが，敵対的訓練の文脈で類似度学習を利用することを提案する本稿と類似した試みもいくつか存在する．Li らは，2 サンプルが同じ分布から得られたかを判定する 2 サンプル識別器を敵対的生成ネットワーク（GAN）の学習やドメイン適応に利用することを提案している [Li 17]．同様の試みとして，Dou は，類似度学習と関連性の強いメトリック学習を GAN の学習に利用することを提案している [Dou 17]．Motiian らは，類似度学習と同様のペアリング・グループ化技術を利用することにより，教師ありドメイン適応がより効率的に（サンプルが少ない場合でも）行えることを報告している [Motiian 17]．これらの研究は，クラス分類に基づく従来の敵対的訓練とは異なり複数のサンプルのペアを利用するという点で提案法と類似しているものの，1) いずれの研究も s がそもそも 2 値の問題設定であり，応用先が異なる，2)Motiian らの研究はサンプル数が少ない問題を補うためにペアリングを利用することに主眼が当たっており学習された類似度自体に基づく敵対的訓練を提案しているわけではないという点で本論文とは本質的に異なる．

3. 類似度学習に基づく敵対的訓練

本稿の提案は，z と s の単一ペアに依存した従来の敵対的特徴学習の代わりに，2 つのサンプルに紐付いた特徴表現 z_1, z_2 が同じグループに属するかを判別する類似度識別器に基づいた E の更新を行うことである．図 1 に，クラス分類に基づく敵対的訓練および類似度学習に基づく敵対的訓練を対比した図を示す．本章では提案した枠組みに基づいた 2 つの具体例として，Similarity Confusion Training と Learned Similarity Maximization を説明する．

3.1 Similarity Confusion Training

類似度学習を敵対的訓練に利用するもっとも単純な方法は，通常の敵対的特徴学習が識別器 D が判別不能な方向に E を更新するのと同様に，類似度識別器 D_{sim} が正しく類似度を判別不能な（すなわち，同じ s であるかどうかの 2 クラス分類が正しく行えない）方向に E を更新する方法である．具体的には，SCT では次の 2 つのステップを交互に行う．

ステップ 1: 類似度識別器の更新

類似度識別器 D_{sim} は通常の類似度学習と同様に，式 2 を最小化するように訓練する．ただし，通常の類似度学習と異なり符号化器 E が類似度をよく表すように更新したいわけではないので，E は更新したまま D_{sim} のみ更新する点に留意されたい．また，グループラベル g は，s が同じ場合は 1，異なる場合は 0 であるとする．

ステップ 2: 符号化器の更新

ステップ 1 で更新した類似度識別器を利用して，類似度識別器が正しく類似度を測定できない用になる方向に符号化器を更新する．定式的には，次の similarity confusion loss を最小

化するように E を更新する．

$$L_{sc} = -\mathbb{E}[(1-g)\log q_{D_{sim}}(g|z') + g\log(1-q_{D_{sim}}(g|z'))]. \quad (3)$$

従来の AFL と同様に，ラベル予測に関する損失の最小化を同時に行うとすると，全体の最適化問題は．

$$\min_{E,M} L_y + \lambda L_{sc}, \quad (4)$$

となる．ただし，L_y はラベル予測に関する交差エントロピーであり，形式的には

$$L_y = -\mathbb{E}[\log q_M(y_1|z_1) + \log q_M(y_2|z_2)],$$

となる．ただし，y_i はサンプル X_i に対応したクラスラベルである．

3.2 Learned Similarity Maximisation

類似度学習を敵対的特徴学習に利用するもうひとつの方法として，学習された類似度関数に基づき，異なる s に対応したサンプルのペアの類似度が高くなる方向に符号化器 E を更新する方法が考えられる．定式的には，式 3.1 の代わりに次の式を最小化するように E を更新する．

$$L_{sim} = -[\mathbb{E}_{\mathcal{G}_{np}}[\log q_{D_{sim}}(g|z')] + \mathbb{E}_{\mathcal{G}_{nn}}[\log(1-q_{D_{sim}}(g|z'))].] \quad (5)$$

ただし，$\mathcal{G}_{np}$ は s が異なるが y が同じサンプルのペアの集合，$\mathcal{G}_{nn}$ は s も y も異なるサンプルのペアの集合を表す．すなわち，第 1 項目は s が異なるが y が同じペアについては近づくようにすることを，第 2 項目は s も y も異なるサンプルのペアについては離れたままになるように符号化器を更新する．ここで，第 2 項目は y が異なるサンプル同士を近づけてしまうとラベル予測精度を毀損する可能性があるために加えている制約である．

SCT と LSM はどちらも類似度識別器を利用した学習方法であるものの，(1) SCT は $\mathcal{G}_{pp}$ のサンプルを異なる s のペアであると誤分類する方向に E を更新する，(2) LSM は $\mathcal{G}_{nn}$ の類似度が近くならないように E の更新に制約をつけるという点で異なっている．4 章では，実験的に SCT と LSM の性能を比較することで，これらの差分の影響について検討する．

4. 実験・考察

4.1 実験設定

検証タスク： [Iwasawa 17] で利用されていたウェアラブルセンサデータにおけるユーザ匿名化タスクのうち 1 つ（USC-HAD）を利用した．ユーザ匿名化タスクとは，複数のセンサデータ系列 X から，対応する時刻における行動 y を予測でき，かつユーザ ID を予測出来ないような特徴量 z を獲得することを目標とするタスクである．データセットとしては，USC-HAD データセットを利用した．USC-HAD には，14 名分の計測データ（3 軸加速度＋ジャイロセンサの合計 6 次元）に 12 クラスの行動ラベルが付与されている．分類問題を解くにあたり，一般に利用されるスライディングウィンドウ方式（スライド幅 30，重なり率 0.5）により学習サンプルを生成し，結果として 14 ユーザ合計で 172,169 のサンプルを得た．この内，ユーザ ID が 1 から 10 のユーザのうち 90%を訓練データとし，残りの 10%および残りのユーザのデータをテスト用のデータとして利用することで，既知ユーザに対する予測精度と未知ユーザに対する予測精度の双方を計測した．

ネットワーク構造： 符号化器 E の構造および分類器 M の構造としては，既存研究に基づき，E: 3 層の畳み込み層（畳み込み＋最大プーリング）+1 層の全結合層，M: ロジスティック回帰，とした．活性化関数は出力層にソフトマックス関数を利用したほかは ReLU を利用し，各畳み込み層および全結合層のあとにはドロップアウトを行った．また，敵対的ドメイン分類器 D_{sim} としては，800-200 の中間層を持つ全結合ニューラルネットを利用した．

最適化： ラベル予測精度を最大化するように E を事前学習した後に，敵対的訓練を利用して表現を検閲する後処理を行った．事前学習の段階では Adam（学習率 0.0001）を利用した．後処理の段階では，RMSprop（学習率 0.000025）を用いて最適化した．バッチサイズは 100 とし，200,000 サンプルの学習ごとにステップ 1 と 2 を交互に 30 回繰り返し学習した．

ベースライン： 1) CNN：敵対的訓練を用いずに，単純にラベル予測精度を最大化するように訓練したもの．2) AFL-MLP：クラス分類を用いた敵対的特徴学習で，D を中間層が 800 の全結合層の多層パーセプトロンとしたもの．3) AFL-DNN：クラス分類を用いた敵対的特徴学習で，D を 800-200 の中間層を持つ全結合ニューラルネットとしたもの．4) SCT：式 4 に基づきに訓練したもの．

評価方法： 既存研究にならい，ラベル予測精度とユーザ予測精度のバランスを評価に利用した．ラベル予測精度としては，既知ユーザと未知ユーザそれぞれのデータに関する F 値のマクロ平均（それぞれ F_y^v，F_y^t と表記）を利用した．ユーザ予測精度としては，800-200 の中間層を持つ全結合ニューラルネットによる正解率（Acc_u）を利用した．

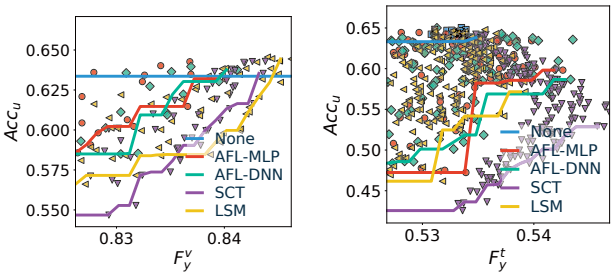
4.2 実験結果

図 2 に，各手法のラベル予測精度とユーザ予測精度のトレードオフに関する比較結果を示す．図中 X 軸はラベル予測精度（左側が F_y^v，右側が F_y^t）を，Y 軸がユーザ予測精度を表している．各点は λ=0.1, 0.2, 0.5, 1.0, 1.5, 2.0, 2.5 で訓練した場合の，各繰り返し終了時の性能を示しており，各線は，ラベル予測精度の棄損を一定以下に限定した場合に各手法が達成した最も低いユーザ予測精度を表しており，右下側を通るほどよい性能（ラベル予測精度を毀損することなく匿名性を高めることができている）ことを示す．それぞれの手法は，異なる色およびにマーカーで表されている．また，図 3 には提案手法とベースライン手法の学習曲線を比較した結果に示す．

これらの結果から，SCT および LSM が AFL と比較して同等以上の性能を達成していることがわかる．特に SCT は，ラベル予測に関するどちらの指標を利用した場合でもその他の手法と比較して良い性能を達成していた．また，F_y^t の精度については，SCT はほとんどその性能を棄損することなく，むしろ良い性能となる傾向が見られた．これは，SCT により得られた特徴が未知ユーザに対して良く汎化する方向に学習が進んでいたことを示している．LSM は F_y^t を指標として用いる場合には AFL と同程度の評価指標であったものの，F_y^v をラベル予測指標として用いる場合には AFL より優れた精度（SCT と同程度）を達成していた，

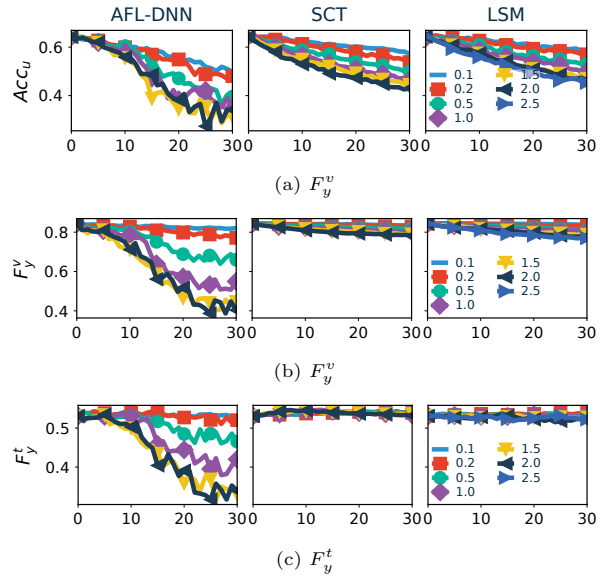
5. 考察・おわりに

本稿では，類似度学習を敵対的特徴学習に組み合わせた新たな枠組みを提案した．また，提案した枠組みに基づいた 2 つの具体例として Similarity Confusion Training（SCT）と Learned Similarity Maximization（LSM）を提案し，ウェアラブルセンサを用いた行動認識におけるユーザ匿名化タスクで



(a) F_y^v に関するトレードオフ　(b) F_y^t に関するトレードオフ

図 2: 提案手法とベースライン手法間でのラベル予測精度とユーザ予測精度のトレードオフに関する比較.



(a) F_y^v

(b) F_y^v

(c) F_y^t

図 3: 提案手法とベースライン手法の学習曲線に関する比較.

その有効性を確認した．特に，類似度識別器が正しく類似度を識別できなくなる方向に符号化器を更新する SCT は，匿名化と性能維持の良いトレードオフを実現するし，また未知のユーザについての汎化性能も改善することを確認した．今回の検証はユーザ匿名化にとどまるものの，提案した枠組み自体は敵対的訓練を利用する多くのアプリケーションに応用可能であり，多様なアプリケーションでの検証を進めていきたい．

参考文献

[Dou 17] Dou, Z.: Metric Learning-based Generative Adversarial Network, *CoRR*, Vol. abs/1711.02792, (2017)

[Edwards 16] Edwards, H. and Storkey, A.: Censoring Representations with an Adversary, in *Proceedings of the International Conference on Learning Representations (ICLR)* (2016)

[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 (JMLR)*, Vol. 17, No. 1, pp. 2096–2030 (2016)

[Iwasawa 17] Iwasawa, Y., Nakayama, K., Yairi, I. E., and Matsuo, Y.: Privacy Issues Regarding the Application of DNNs to Activity-Recognition using Wearables and Its Countermeasures by Use of Adversarial Training, in *Proceedings of the IJCAI*, pp. 1930–1936 (2017)

[Li 17] Li, C., Alvarez-Melis, D., Xu, K., Jegelka, S., and Sra, S.: Distributional Adversarial Networks, *CoRR*, Vol. abs/1706.09549, (2017)

[Lin 15] Lin, T.-Y., Cui, Y., Belongie, S., and Hays, J.: Learning deep representations for ground-to-aerial geolocalization, in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 5007–5015 (2015)

[Louizos 16] Louizos, C., Swersky, K., Li, Y., Welling, M., and Zemel, R.: The variational fair auto encoder, in *Proceedings of the International Conference on Learning Representations (ICLR)* (2016)

[Motiian 17] Motiian, S., Jones, Q., Iranmanesh, S., and Doretto, G.: Few-Shot Adversarial Domain Adaptation, in *Advances in Neural Information Processing Systems(NIPS)*, pp. 6673–6683, Curran Associates, Inc. (2017)

[Parkhi 15] Parkhi, O. M., Vedaldi, A., Zisserman, A., et al.: Deep Face Recognition., in *BMVC*, Vol. 1, p. 6 (2015)

[Vo 16] Vo, N. N. and Hays, J.: Localizing and orienting street views using overhead imagery, in *European Conference on Computer Vision (ECCV)*, pp. 494–509Springer (2016)

[Wang 14] Wang, J., Song, Y., Leung, T., Rosenberg, C., Wang, J., Philbin, J., Chen, B., and Wu, Y.: Learning Fine-Grained Image Similarity with Deep Ranking, in *Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 1386–1393, Washington, DC, USA (2014), IEEE Computer Society

[Wang 15] Wang, F., Kang, L., and Li, Y.: Sketch-based 3d shape retrieval using convolutional neural networks, in *Computer Vision and Pattern Recognition (CVPR), 2015 IEEE Conference on*, pp. 1875–1883IEEE (2015)

[Wang 17] Wang, J., Zhou, F., Wen, S., Liu, X., and Lin, Y.: Deep Metric Learning with Angular Loss, in *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (2017)

[Xie 17] Xie, Q., Dai, Z., Du, Y., Hovy, E., and Neubig, G.: Controllable Invariance through Adversarial Feature Learning, in *Proceedings of the Annual Conference on Neural Information Processing Systems (NIPS)* (2017)

[Zemel 13] Zemel, R., Wu, Y., Swersky, K., Pitassi, T., and Dwork, C.: Learning fair representations, in *Proceedings of the 30th International Conference on Machine Learning (ICML)*, pp. 325–333 (2013)

Oral presentation | Organized Session | [Organized Session] OS-22

[3B1-OS-22a] [Organized Session] OS-22

Thu. Jun 7, 2018 1:50 PM - 3:30 PM Room B (4F Moon Light)

[3B1-OS-22a-01] On a Multi-faceted Structure of the Representation of a Cup of Sake

○Hiroki Fukushima[1] （1. Kyushu Women's University）

1:50 PM - 2:10 PM

[3B1-OS-22a-02] Mimetic words and nursing care level in the free description text of long-term care records

○Sachiko Hirata-Mogi[1], Shu Kobayashi[1], Shoji Fukuda[1] （1. SMS Co., Ltd.）

2:10 PM - 2:30 PM

[3B1-OS-22a-03] Effects of Context Creation Work in Impression of Abstract Paintings

○Kotone Tadaki[1], Akinori Abe[1,2] （1. Chiba University (Graduate School of Humanities), 2. DWANGO Artificial Intelligence Laboratory）

2:30 PM - 2:50 PM

[3B1-OS-22a-04] A Consideration on a Multiple Approach for Haiku Generation

○Takuya Ito[1], Kota Igarashi[1], Takashi Ogata[1] （1. Iwate Prefectural University）

2:50 PM - 3:10 PM

[3B1-OS-22a-05] Body-mind integrative science to increase cellular power (1)

○Yoriko Atomi[1], Miho Shimizu[1], Yoshikazu Higashi[1], Eri Fujita[1], Tomoaki Atomi[2], Kazuya Tanaka[2], Yu Takada[3] （1. Tokyo University of Agriculture and Technology, 2. Teikyo University of Science, 3. Uno hospital）

3:10 PM - 3:30 PM

©The Japanese Society for Artificial Intelligence

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

一杯の酒の多相性について

On a Multi-faceted Structure of the Representation of a Cup of Sake

福島宙輝[*1]
Hiroki Fukushima

[*1] 九州女子大学
Kyushu Women's University

In this paper, the author proposes a multi-faceted model for making a representation of a cup of Sake. The perceptual domain of taste presents a symbol-grounding problem in which language does not capture the target domain straightforwardly. We suggest that analogy, defined as a process of finding relevance in a metaphorical expression, is a key to handling the problem in the domain of taste.

1. はじめに

1.1「たそうせい」について

「たそうせい」については複数の表記が可能である. 多層性を意図する表記として一定程度の容認度をもつ表記としては, 多層性, 多相性, 重層性, 重相性, 重奏性, 複層性, 複相性など[1]が考えられる. このうちカバータームはおそらく「多層性」「重層性」であろうと思われる. ここでは, 今後の研究に向けてこれらの表記を, それぞれの使用事例を見つつ整理しておきたいと思う.

このような多層性の表記バリエーションは, おそらくそれぞれの筆者にとっては思い入れがあって用いていることと思われるが, その表記意図を明示した例はさほど多くない.

(1) た

対訳としては"multi(ple)"をあらわす「多／重／複」について, それぞれ類的表現ではあるが, 一般的に了解できそうな区別を示しておく. まず「複」は「単」に対する語であり, 何かが「2 以上」存在するということを示す. 一方「多」は, 筆者には 3 以上を表すように思える. したがって二層の構造をしめすには「複層」を用いることが望ましく, 「多層」というと容認度が下がるだろう.

「多」と「重」については, 「多」がニュートラルに「たくさん」という複数性を示すのに対して, 「重」となると層間の関係性を示唆する表現となるだろう. 「多層」は関係なくバラバラでも良いが, 「重層」となると層の位置関係, 上下関係, 階層関係など何かしらの関係性を説明することが求められる. したがって「多／重／複」はおそらく順に包含的な関係にあり, 単に2以上の複数性をあらわす「複」がもっとも意味が広く, ニュートラルであると思われる. つまりカバータームとしては「複層性」が好ましいように思われるが, おそらく「輻輳」との音の衝突(そして意味も近い)から「複層性」を避けて「重層性」「多層性」が一般的に用いられるのではないかと思う.

(2) そう

「そう」については「層」と「相」の表記が可能である. 例外的に[鈴木, 2003]は「重奏性」という表記を用いている. このメタフォリカルな表記は, 知の性質が冗長で, 使えるものはなんでも使うという貪欲さをもち, あるシステムの背後で別のシステムが働いているという点を踏まえたものであり, オーケストラの演奏のように複数のシステムが同時にかつ意味のある全体として機能しているという解釈にたてば, 音の響きと漢字の意味が相まって優れた表記に思えてくる. ただしこのニュアンスを保って英語にするのは難しそうである.

「層」と「相」はそれぞれ英語にすると"layer"と"aspect"ということになる. (多面的に近くなるが"multi-faceted"のような表記も可能). ただし機械学習における layer, あるいは言語学における aspect など, 研究ドメインごとに専門用語として規定されている場合があることに注意が必要である. 一般的な語義としては, 「多層」あるいは「重層」とすると, ある現象を各層に還元して説明したり, 層ごとの独立した構造をもっていることが示唆される. なお「多相」は一般的な表記ではないために, この表記を用いるには注釈を付す必要があるだろう.

「層」と「相」を明示的に区別している数少ない事例としては, 深谷&田中(1990)を挙げることができる. 同書ではとくにコミュニケーションにおける意味の重相性について,

> *ポール・リクールの「発話の意味」と「発話者の意味」の両者は, 融合的な関係にある. そこで我々は「重相性」という用語を好んで用いる. なお慣用的には「重層性」と綴られるが, 「層」という語は「重ね合わせ」の意味合いが強いため, 意味諸相のゲシュタルト的な融合体を協調するため, 「重相性」という造語を用いる.*

と明示的に区別を行っている. ここでは「相」という表記の選択の背景としてウィトゲンシュタインの「アスペクト盲」の考え方を意識したという(田中氏私信). 深谷&田中ではアスペクトを意味する「相」を用いることであるシステムの全体を意図しつつ, そのある一面を図化し, 一方あるアスペクトは地化, 盲化されるという意味の重相性を主張している.

2. 味の多面的な表象構成モデル

2.1 一次性

多面表象モデルをくみたてるには, その出発点を記号の一次性に置くのがよいだろう. 記号の一次性の議論は, 端的に言うと「対象はどのように現出するか」, そして「対象と自己はどこにあるのか」という問いになるだろう. ただ筆者の主眼は一次的な現出のあとの記号過程, 表象構成過程にあるので, ここでは一次的な現出のあり方については稿を改めることとし, 一次性を出発点に置く意図を中心に説明するに留める.

連絡先:福島宙輝, 九州女子大学, 福岡県北九州市八幡西区自由ヶ丘 1-1, fukushima@kwuc.ac.jp

[1] バリエーションとしては重層性, 重相性, 重奏性[鈴木 2003], 重創性, 多層性, 多相性, ?多奏性, 多創性, 多重性, 多元性, 多面性, 複層性, 複相性, ?複奏性, ?複創性, 成層性[市川 1989]などが考えられる. 英語については稿を改めて検討.

一次性，すなわち対象（の像）がいかに現出するか，立ち現れるかを認識の出発点に置くことは，現象論に近いモデルを志向するということである．この点において筆者の味覚表象構成論は，先験的かつ客観的な対象のあり方を認め，その対象を計測し，その属性に表象を還元しようとする（おおきく言うと自然科学的な）アプローチとはその視座をたがえるものである．

筆者が提案するモデルは，モノの属性あるいは自己の神経パルスに表象を還元しようとする二元論を去り，対象とのかかわりによって生起し，一回性を伴って構成される事態として表象をとらえるというものである．

「対象と自己はどこにあるのか」という問いは，要するに一元論に立つか二元論を引き受けるかというもんだいである．大森(1976)は「対象はじかに立ち現れる」として「立ち現れ一元論」を主張するが，本研究ではそこまで一元論を先鋭化させることは避けようと思う．本研究では自己が（対象をふくむ）環境に融け出しつつ拡張するなかで，対象との関係性としての表象を構成するという立場をとるので，自己と明確に対象を切り離した二元論は否定するが，かといって原理主義的な一元論でもないというのを一応の弁明としておく．ただし表象構成のモデルじたいは一次性から出発することは確かであり，市川(1990)の主張する「一次的なあらわれののち，内省によって，そのかかわりの両項として自己と対象が析出する」という考えかたに沿うものとして一次性をあつかいたい．

2.2 仲だちによる関係としての表象構成

一次的立ち現われののちには，表象構成の段階に入ることとなる．なお，のちには，と記したが，厳密にいうならば，一次的立ち現れと表象構成は自覚できるほどその時間差があることはなく，むしろ我々が「立ち現れた事態」として認識しうるのは構成された結果としての表象という事態であり，一次的立ち現れという現象じたいは内省の後に（内省によって）遡及的に定位されるものであろう．ただしここではモデルの構造を簡明に示すという本節の目的に照らして，一次的立ち現れののちにくる表象構成のフェイズということで議論を進めていく．

さて，少なくとも本研究で扱おうとする表象とは，静的な，安定した図像のようなものではない．本研究で筆者の考える味覚表象とは，その場限りの，一回性を前提とした，関係としての表象のあり方である．

関係としての表象を考えるには，自らの身[1]が世界のなかでどのような位置づけであるかを把握することがまずもって重要である．本研究では現象論的な立場から，身が環世界[Uexküll, 1998]にたいして拡張し，融け合うことで対象を自らの系の裡にひきいれるという対象把握の様式をとる．ここにおいて表象とは融け合うような拡張（「融拡」としておく）の結果，その場その瞬間に生起する現れとしての関係である．繰り返しになるが，この認識のあり方は，表象を自己あるいは対象のどちらかに還元しようとする自然科学的立場へのアンチテーゼである．波を理解するのに海水と風をいくら調べても答えが得られないように，主体性を伴う身のかかわりとしての表象のあり方を離れては，表象の本質にたどり着くことはできないだろう．

かかわりとしての表象は，漫然と酒を呑んでいては得ることは難しい．認知的際立ちという用語を持ち出すかはともかく，他の知覚領域と異なり，味わいの感覚は自発的な注意と意識を向けないことには言語化をはじめとした表象構成は困難である．すなわち直接的認識が困難なときに，いかにして間接的認識を得るかという問題が，味覚においては他の知覚領域以上に頻発することとなる．

筆者はこれまでに，味わいの言語化，とくに動詞概念のような抽象的なイメージを把握する上では，身体性を帯びた言語媒介的なイメージ図式（中間スキーマ）が必要であることを主張してきた．本研究では，この中間スキーマを言語記号からさらに拡張し，対象を自らの身と同一の系にひきうけるうえでの接面的媒介としての記号や道具，用具のあり方を検討する．この媒介は，筆者の用語では「中間スキーマ」となり，市川のいう「仲だち」と趣旨を同じくするものである．ただし本稿では概念の乱立を避けるため，市川の「仲だち」という概念に沿って味覚の間接的認識のあり方を議論する．

さて，仲だちによる表象構成というと，あたかも仲だちによって構成された表象は「仮の姿」であって，その仮の姿の先に，（仲だちのヴェールを脱いだ）「対象そのもの」があるというような誤解を抱くかもしれない．しかしその考え方はまさに誤解である．多様な仲だちによって構成された多様な表象の錯綜体こそが世界なのであり，構成の関係を離れた「真の姿」なるものは幻想に過ぎない．この点において，筆者はセンサによる計測を，道具的（用具的）な対象理解のひとつの相として表象構成モデルの裡に引き入れることを試みる．

2.3 仲だちの三相

それでは，間接的な認識を支える仲だちの様相とはいかなるものか．本論考では，仲だちのありかたとして，言語的仲だち，物理的仲だち，心理的仲だちの三相を操作的に措定し，各相の性格を検討したい．なお，この三相は独立の認知能力ではなく，多分に共通する背景をもつ作用の三つのアスペクトであると思われる．

(1) 言語的な仲だち

まず言語的な仲だちは，端的には言語媒介的な世界把握の様式である．味覚も他の知覚同様，言語，とりわけ母語の（語や文法上の）分節構造に組み込まれた知覚を余儀なくされる．言語と知覚の関係については多くの議論があり，ここでは微細に検討することは避けるが，本論で「言語的仲だち」として重視するのは，前節で検討したような（認知能力としての）メタファを基軸とする作用である．再確認となるが，重要なのは，メタファは単なる形容方略ではなく，表象を構成し，生成する力をもつということである．

(2) 心理的仲だち

心理的仲だちによる表象の構成は，類推的な作用である．言語は認知的，心理的な営みであるので，一般に類推と比喩とされるものが不可分であるように，心理的仲だちと言語的仲だちのあいだには明確な区分は無いだろう．

本論でおもに心理的仲だちとして扱うものは，共感覚的な類推である．すなわち非言語的な色や形，音のイメージなどを仲だちとした表象構成である．本稿ではこの類推による表象構成作用を，「中間参照枠」という概念装置を導入しつつ論じる．その後，心理的仲だちによる味覚表象構成の事例として音象徴および描画表象を検討する．

(3) 物理的仲だち

物理的仲だちとは，狭義には身体の拡張としての道具と言いかえることができる．身体の拡張とは「盲人の杖」「外科医のゾンデ」などがよく挙げられる例であるが，（体表ではなく）杖の先で

[2] 市川は「身体」あるいは「からだ」という言葉が「から（空／殻）」に通じ，モノとしての物理的身体のみを指す二元論的用語であるとして，主体的なコトとしての身体にたいしては「実（み）」に通じる「身」という用語を好んで用いる．

じかに地面を感じるというように，感覚が道具の先まで延長するというものである．味覚に関する道具をかんがえてみると，ナイフやフォーク，箸などの食器としての道具を用いることでテクスチャなどを捉えることが想定できるだろう．

味覚における道具は，対象や世界の切り取り方を決めるという点で重要である．味覚は外界に開かれた感覚器官ではなく，選択的な性格をもつ．味覚では道具によって対象が切り取られ，感覚器官へと運ばれる．適切な酒器を用いることは，ピントの合った眼鏡を装用するように，酒のかたちを際立たせる．

本研究では，味覚認識における道具的仲だちを，もう少し広義で捉える．具体的には，センサによる対象の計測値を，道具的仲だちの序列に配するということである．計測値に，とかく神話的，絶対的なハード・エヴィデンスとしての地位を認めたがる風潮にあって，仲だちとしての言語による世界認識の相とおなじく，センサデータをわれわれの世界認識の一つの相として，他の表象構成相と相対的な地位におきたいということである．

物理的な仲だちは，道具的，あるいは用具的な媒介物による認識のあり方である．道具と用具の区別は連続的であるが，身体の拡張としての意味合いのつよいものを道具とすることができよう．酒においては酒器が道具として旧くから重んじられている．酒器は単に酒を掬いだすもののみならず，例えばワイングラスに典型的であるが，酒の立ち現われ方そのものを変容させるという意味で重要なことは言を俟たないだろう．筆者を含む味わいの長期言語化実験メンバにおいても酒器を含んだ記述を扱っているが，本研究では酒器の検討は行わないものとし，ここでは，以下に示すような用具としての仲立ち，とりわけセンサによる計測値を多相表象構造のひとつの相としてみなす考えかたを中心に検討する[1]．

さて，味覚の言語化や，絵や色，音による表現（共感覚的な実験を含む）を行っていると，その言葉や表現の精度あるいは確度のようなものを，味覚センサの数値によって計測するという手法がちらつく．いわば言語記述などのように，確たる分析の手法あるいは分析の基準のないものにハード・エヴィデンスを与えるというものであり，この手法自体は有効なもののように思われる．

しかし，ここで注意すべきなのは，我々の認識あるいは表象はかかわりとして生起するものであって，かかわりを離れた，「客観的」な構造というものは存在し得ないということである．認識の主体としての経験をある一つの相に絶対的に還元しようとする姿勢は，かりそめの明証性と引き換えに，我々の世界理解の様式を貧困化させるだけである．市川はいう，

> *「赤の知覚は，実は……である」といわれる場合の「本当は」とか，「実は」は，「直接経験に対応する物理・科学的出来事を理論と用具に仲だちされた経験によって記述すれば」という以上の意味をもたない*．(市川, 1990, p.106).

したがって本研究では，「科学的な」計測に特権的な地位を与えず，多相的な対象理解の一つの相として考える．自然科学的な計測値は多相的な対象理解のための記述の，あるひとつの相に過ぎず，他の表象相とくらべて特権的な地位や，絶対的な真理性を約束されたものではないということである．
もちろんこれは，自然科学的な用具による対象理解を我々の多様な表象相のなかにおいて相対化することが目的であって，センサによる計測を代表とする自然科学的なアプローチを真っ向から否定することでは当然ない．筆者が目指すのは，一杯の酒の認識を，自然科学的な用具による計測を含む多様な表象相の重合的な記述としてとらえるあり方である．

[3] 本項では道具，用具的な仲だちとしてセンサによる計測が取り上げられるが，もちろんセンサによる計測値そのものは我々の（一般的な定義における）表象ではないので，用具的なかかわりによる対象理解を多相「表象」のなかにくみこむことは不自然に思えるが，この点は今後モデルを発展させる上での課題とし，いったんは表象相のうちのひとつに組み入れて議論する．

2.4 仲だちによる表象構成をささえる中間参照枠構造

先段でも強調したが，とりわけ味わいの認識は，対象としてのものことがはっきりと現れていて，それを予め用意された適切な表現で描写するのではない．本研究では，類推による投射的な表象構成を説明するために参照点能力に着目し，中間参照枠という概念装置を新たに導入する

認知言語学分野では，多様な部分構造を含む概念構造において認知的な際立ちの小さい情報構造にアクセスする際の方略として，参照点構造の利用が指摘されてきた[Langacker Ronald, 1990]．参照点とは，ある事物との心的接触を果たす目的で，別の事物の概念を想起する行為において，最初に想起される構造であり[Langacker, 1993]，この参照点を利用する人間の基本的な能力を参照点能力と呼ぶ．

本稿では，味覚の表現においても，この参照点構造が表現方略として用いられていると考える．ただしこの際参照されるのは特定の味の要素ではなく，例えば「ヨーグルトのような香り」，「色で言うと黄緑色」のように，フルーツや他の食べ物，色，形，音など，他のドメインやモダリティの情報である．こうした味覚表現において類推のソースドメインとして参照され，我々の認識の仲だちとして利用可能な知識の枠組み，情報群を，「参照枠(referential framework)」とする．この参照枠は，言語記号としての抽象性や恣意性をもたない，すなわち身体感覚に動機づけられた知識であるという個人内における有縁性が重要であると思われる．この，感覚と言語を媒介的に接地させる性質（中間性）を踏まえて「中間参照枠 (inter referential framework)」と呼称する．

ここでいう中間参照枠は，状況依存的，文脈依存的な性質を持つため厳密に定義することはむずかしいが，以下，考えられるその特徴を示す．

- 中間参照枠は，身体感覚，感覚情報に動機づけられた iconic な認知能力である．仲だちとして参照される領域は，具体的には，心理的な仲だちを中心に列挙すると（マルチモーダルな）イメージ図式，概念メタファ，共感覚，音象徴，色や形による象徴などが含まれる．
- 中間参照枠は，味覚表象のように認知的際立ちの小さい情報にアクセスする際，あるいは知覚できる情報そのものが少なく焦点化が困難な際に，類推表現のソースドメインとして機能する．この際，ソースドメインを経由してターゲットドメインに至るという参照点構造を提供する．
- 何が中間参照枠として利用されるかは，文脈や対象，個人の認知能力に強く依存する．
- 中間参照枠としての知識は，その場限りの表現として，限定目的的に用いられることが多いと思われる．しかし例えば語彙としてのオノマトペのように，より精緻化され概念化あるいは事例化されるとその意味が個人間で共有できる可能性が高まる(社会的な entrenchment [Taylor, 2012]).

3. まとめ：味わいの多相表象構成モデル

ここまで議論してきたように，味覚の認知過程の特性は，記号系の不在と認知能力の不足という二重の制約を抱え，他の感覚を類推的かつトップダウン的に用いるという点にある．こうした制約を含む特性をもつ味覚について，他の感覚領域，言語領域，非言語領域，モノとしての身体，表象された身体，身体の延長と

しての器，味わっている環境など，あらゆるものごとを含んだモデルを筆者はこれまでに提案した[Fukushima, 2018]．ただしそのモデルでは，対象の科学としての自然科学的計測を表象モデルのうちに組み入れた形式になっておらず，「現象」から「表象」を生成するという過程とは異なる路線に，「対象」としての理解を配したものとなっている．そこで本研究は，このモデル図を底におきつつ，さらに明瞭なモデルを提案する．（図 1）．

3.1 表象構成：モデルの流れの概説

味覚表象構成の出発点は，記号過程の第一次性，すなわち一杯の酒がどのようにして我々の認識に立ち現れるかということである．図中①で示された部分が立ち現れを示している．本モデルにおいては認識はかかわりとして措定されるので，ここではまだ関係づけられた認識は成立していない．

かかわりとしての認識は，視点（パースペクティブ）（図中②）をおくことによってはじめて生起する．本研究であつかう表象は動的なものであり，ある視点をとることによって，能動的に（一度限りの）対象の像を構成するというはたらきである．その際，主体と客体の間の関係性をとりもつものが様々な相の仲だちである．本研究では，仲だちによる認識の原動力として類推的能力，とくに参照点能力を想定し，参照点としてもちいられる情報群を中間参照枠（③）とした．中間参照枠として用いられる仲だちは，渋って立ち現われた対象（①）に，その仲だちの図化効果のおよぶ限りの新たな形を与え，仲だちされた表象を構成する（④）．

これが一回の，あるいは一杯の酒の表象構成であり，何度も繰り返すたびに仲だちされた表象はその姿を豊かにする．そしてその複相的な表象の，錯綜体としての重ね合わせ（⑤）が，ある人のある銘柄にたいする理解の総体である．

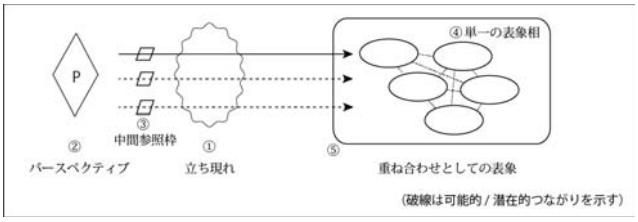


図 1　多相表象構造のモデル図

3.2 多相性：有機的なセミ・ラティス構造としての表象

事態としての表象を考えるとき，事態は視点とのかかわりにおいて生起するものなので，一つのパースペクティブにたつとき（一つの相を中間参照枠として用いるとき），同時に他の相をとおした視点を得ることは困難である．しかしあるアスペクトによる対象把握は常に対象の全体としての理解像（⑤）を更新するため，一杯酒を呑むたびに（一つのアスペクトによる表象構成をするたびに），その酒の総体としての理解も変容するという構成論的な対象把握の様式になる．

モデル図では各領域は分かれて描かれているが，一度の味わいの経験は多様な表象の総体として（すなわち常に更新される場の状態として）生起する．ごちゃついた全体としての酒の味を受け入れ，流れに身を委ねて酔いを楽しむのも乙なものではあるが，ここでは内省的に，より精緻な表象を構成するはたらきを考えたい．

モデル図においては各相，各ドメインはおのおの独立に存在しているように見える．しかし実際には各ドメインは整然と並んでいたりはしておらず，たとえば音の相の「次の」相や「一つ上の次元の」相を規定することもできない．あるいは日本酒の酸味の表象に S 音（五感の層の音アスペクト）を用いたり，同時にトゲトゲした描画（非言語表象層の描画アスペクト）がアプライされたりする．すなわち表象は層やアスペクトをまたいで短絡的に相互に関係するし，その関係性は個人に依存する．したがってこの関係性はツリー構造ではなくセミ・ラティス構造[Alexander, 1966]をとっているものと考えられる．

3.3 アスペクト間のつながりの様相

アスペクト間のつながりの様相としては，実際に観測可能な顕在的なつながりのほかに，潜在的なつながりと可能的なつながりとがある．これらの三態が分かちがたく連なり行き来するものであることは言を俟たないが，一応の整理を与えるならば，顕在的なつながりとは「この味は色で言うと黄色」と意識できるつながりであって，ここでは内省的に報告可能，あるいは何かしらの外化を伴って観察可能な外的表象を与えられた状態とさしあたって考えておく．

顕在的なつながりは，対象の立ち現われののちに生起するもので，このセミ・ラティス的な多層構造においては，酒を呑むという行為，あるいは酒の立ち現われの以前に，先験的に層間の明確なつながりはない．そこにあるのは潜在的なつながりの可能性だけである．つながりは人の味わうという活動の結果として現れる．つまり表象された表象を階層的に分類することはできるが，しかし表象以前の表象の層は潜在的なつながりの可能性をもったセミ・ラティス的な集合体であって，その総体を記述することはできない．

潜在的なつながりと可能的なつながりの違いは，個人差ということになろう．可能的なつながりは可能性であって，例えばヴィゴツキーは「青」と「進む」という感覚が（かれの中では顕在的に）つながっているが，正直に行って筆者にはその感覚はわからない．したがって「青（色ドメイン）」と「進む（動きドメイン？）」はつながる可能性のある「可能的つながり」ではあるが，筆者にとっては（すくなくとも現在は）潜在的なつながりではない．

Acknowledgments

本論文の一部は，平成 29 年度慶應義塾大学博士論文として発表したものである．

参考文献

Alexander, C. A city is not a tree. *Design*, 46–55, 1966. https://doi.org/10.1017/CBO9781107415324.004

Fukushima, H. A Phenomenological Model for Generating the Tasting Description of Japanese Sake. In T. Ogata (Ed.), *Content Generation Through Narrative Communication and Simulation*. IGI Grobal, 2018.

Langacker, R. W. Reference-point constructions. *Cognitive Linguistics (Includes Cognitive Linguistic Bibliography)*, *4*(1), 1–38, 1993.

Langacker Ronald, W. Concept, Image, and Symbol-The Cognitive Basis of Grammar. *Berlin: Mouton de Gruyter*, 1990.

Taylor, J. R. *The mental corpus: How language is represented in the mind*. Oxford University Press, 2012.

Uexküll, J. V. O. N. A stroll through the worlds of animals and men : A picture book of invisible worlds *, *4*(1934), 319–391, 1998.

市川浩. < 中間者> の哲学. 岩波書店, 1990.

大森荘蔵. 物と心. 東京大学出版会, 1976.

鈴木宏昭. 認知の創発的性質. 人工知能学会論文誌, *18*(4), 2003.

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

介護記録の自由記述に含まれるオノマトペと要介護度の関係

Mimetic words and nursing care level in the free description text of long-term care records

平田 佐智子[*1] Sachiko Hirata-Mogi
小林 秀[*1] Shu Kobayashi
福田 升二[*1] Shoji Fukuda

[*1] 株式会社エス・エム・エス
SMS Co., Ltd.

The long-term care records keep the detailed information of daily life and behavior for the members in need of nursing care. In this paper, we conducted an analysis focused on the relationship between mimetic words in free description text of the records and nursing care level to demonstrate the real state and behavior of the people in each care level. As the results, text of milder level of care needed contains more active and positive type of mimetic words like *don-don, wai-wai*, whereas that of severer level of care needed contains dull and uncomfortable type of mimetic words like *bon-yari. sowa-sowa.* These results reveal that the mimetic words reflect the differences of people's behavior in each care level. Further analysis focused on the mimetic words toward the massive text data should be effective to excavate the collective wisdom from long-term records.

1. はじめに

介護記録とは，介護を必要としている人々（介護利用者）に対して介護従事者がケアを行った際に，介護利用者の状態やケアの内容を記録するものである．これらの記録の中には，介護利用者の身体情報やどのような処置を受けたか，という内容だけではなく，デイサービス施設などにおいてどのように過ごしていたか，に関する情報が含まれている．これらの情報から，介護利用者の日々の様子を，その記述から知ることが可能であると考える．本研究では，介護記録ソフトウェアの「その他」項目の自由記述部分に入力された内容に含まれるオノマトペと，当該介護利用者の要支援・介護度を照らし合わせることで，各介護度の利用者がどのように日々を過ごしているのかを明らかにする．

2. 序論

2.1 介護記録とは

介護記録とは，介護を必要としている人々に対して，介護施設やデイサービス施設において介護従事者がケアを行った際に，その内容を記録するものである．これらの記録の中には，介護利用者がどのようなケアを受けたか，といったケアの内容や，バイタルサインと呼ばれる体温・血圧などの情報，排泄や睡眠の状態，食事やレクリエーションの内容が記録されている．また，それ以外の特記事項として，施設などにおいてどのように過ごしていたか，介護職員とのやり取りの様子も含まれている．そのため，介護を必要とする方々の日々の様子を，その記述から垣間見ることができる．

介護記録は，医療レセプトと同様に，介護保険の給付費請求に必要な重要な書類である．しかし，記録すべき項目が非常に多く，介護従事者の労働時間を圧迫していることがかねてより問題視されてきた．介護記録に関する先行研究は数多く存在し，その多くが介護記録システムの改善を目的とした研究である．例えば，介護記録データを構造化し，頻出する単語をもとに入力支援オントロジーの作成を提案したり[金竹 14]，医療・介護の現場での気づきを「音声のつぶやき」として記録し，準リアルタイムに共有するシステム[内平 13]などが開発されている．また，介護記録の書き方を改善することで，問題を解決し介護の質を上げようとする試み[古市 17]もみられる．しかしながら，介護記録の内容を通して介護利用者の実態に迫ることを試みた事例は現在までに見当たらない．

2.2 オノマトペ

オノマトペ(mimetic words, onomatopoeia)は，「ドンドン」などの擬音語，「ふわふわ」などの擬態語，そして「そわそわ」などの擬情語の総称である．音声が持つ特徴と，語の意味の間に関連性がみられる（類像性をもつ）点において，特殊である．また，日本語オノマトペは，触感や動きなどをわかりやすく表現することばとして，様々な媒体で使用される．特に，身体動作の表現に関しては，「スポーツ・オノマトペ」[藤野 06]と呼ばれる一連のオノマトペがあり，スポーツのコーチングにおいてオノマトペを効果的に用いることで，適切な身体動作の伝達が可能であるとされている．また，動き以外にも，人の表情・感情や環境音を豊かに表現することが可能である．

2.3 介護記録に含まれるオノマトペ

介護記録には介護利用者の様々な情報が含まれている．なかでも自由記述欄は，フォーマットに限定されない記述が可能であることから，介護従事者から見た介護利用者の状況がより自由な形式で記録されていることが予測される．本研究では，自由記述テキストデータに含まれるオノマトペに着目する．先述の通り，オノマトペは人の身体動作や状態・感情について豊かに表現できる性質がある．そのため，オノマトペを通して介護利用者の日々の過ごし方を捉えることができるのではないかと考える．また，要支援・介護度とあわせて分析を行うことで，介護度によって過ごし方に差があるのかどうかを知ることができる．そのため，本研究では，この仮説を検討するため，介護利用者個々人の要支援・要介護度のデータもあわせて分析対象とする．

要支援・要介護度とは，介護サービスを受ける際に，どの程度の介護・支援が必要なのかを把握するために受ける認定である．要支援（1 と 2 の段階がある）状態は，ともに日常生活動作

連絡先：平田佐智子，株式会社エス・エム・エス 介護事業本部 事業開発部，〒105-0011 東京都港区芝公園 2-11-1 住友不動産芝公園タワー sachiko.hirata@bm-sms.jp

** 本研究の内容は株式会社エス・エム・エスの公式見解を示すものではありません

(ADL:食事や排泄，入浴など，日常生活を送る上で必要な動作)には支障はないが，手段的日常生活動作(IADL:買い物や洗濯，金銭管理など，日常生活動作の中でもさらに複雑な動作)において何らかの支援が必要な状態を指す．また，要介護(1～5 の段階がある)状態とは，手段的日常生活動作のみでなく日常生活動作を行う上でも何らかの支援を必要とする状態を指す[厚生労働省 03].

3. 方法

3.1 対象データ

本研究では，株式会社エス・エム・エスが提供する介護記録ソフトウェア「カイポケ」(株式会社エス・エム・エス製)に入力された介護記録データを分析対象とした．「カイポケ」は，PC やタブレットを使用して介護記録を作成するための介護支援ソフトウェアである．カイポケでは，各利用者の情報以外に，施設利用・バイタル・入浴・排泄・水分・食事・処置・おやつ・レク・機能訓練・写真や動画など，複数項目の情報を入力することが可能である．なお，カイポケが対象としている介護関連サービス種別は「居宅介護・通所介護・訪問介護・通所リハ・訪問看護・サ高住」である．本研究では，カイポケを通じて入力された介護記録データのうち，「ケース実績・特記事項(自由記述)」と「各利用者の要支援度・要介護度」を分析対象とした。「ケース」項目は，それ以外の項目に含まれない記録を自由に入力できる(図 1 参照)．各データを収集した期間及び場所は以下のとおりである．

対象期間:2009 年 1 月 1 日～2017 年 12 月 15 日

収集場所:「カイポケ」の介護記録機能を使用している国内の介護事業所



図 1. 「カイポケ」アプリをタブレット PC 上で表示した際の，ケース実績入力画面例

3.2 ランダムサンプリング

介護利用者の状況を記述したテキストとして，「ケース」項目特記事項欄に入力されたテキストデータ(2,722,714 件)に対し，ランダムサンプリングを行った．オノマトペはさまざまな品詞形態としてテキスト中に出現するが，概ね動詞を修飾する副詞的用法(例:「パタパタと走る」)をされることが多い．テキストデータの理論的サンプリングにおける理論的飽和度を求めるシミュレーション[松村 11]によると，14,289 件のツイートデータであれば 5000 件(34.99%)のランダムサンプリングを行うことで飽和度が収束し，全体の 90%以上の形容詞が抽出されることがわかった．また，副詞はさらに少ないサンプリング数で収束を見せた．本研究のテキストデータは膨大であるため，同様にランダムサンプリングを行い，全体の 35%に該当する 952,949 件のデータを対象に解析を行うこととした．

3.3 少数サンプルからのオノマトペリスト作成

擬音語・擬態語辞書[小野 07]に掲載されているオノマトペは 2000 種類を超える一方で，本研究で扱うデータに含まれるオノマトペの種類は限られることが予測されるため，まず検索対象とするオノマトペリストを作成した．本研究で扱うデータにどのようなオノマトペが含まれるかを調べるため，テキストデータの 1% (9,529 件)に対して Text Mining Studio(株式会社 NTT データ数理システム製)を用いて分かち書きを行い，副詞を抽出した．オノマトペは副詞的用法をされる場合が多く，その場合分かち書き上でもオノマトペは副詞として判定されるためである．抽出された副詞の中からオノマトペを取り出した結果，190 件が選出された(ただし，ひらがな・カタカナの表記異なりは検索する際には異なるオノマトペとしてカウントしている)．これらのオノマトペを，本研究における分析対象として扱うこととする．

3.4 オノマトペを含む記述と要支援・介護度

3.3 において作成したオノマトペリストを用いて，ランダムサンプリングを行ったデータからオノマトペを含むテキストデータを抽出した．また，そのテキストデータに紐づけられている記録対象の要支援・介護度情報も同時に抽出した．そして，要支援・介護度別にデータを分類し，各要支援・介護度において特徴的なオノマトペがあるかどうかを検討した．なお，各支援・介護度においてデータ数に偏りがあったため，非オノマトペ副詞である「少し」の各支援・介護度における分布をベースラインとし，ベースラインを上回るオノマトペを「各支援・介護度において特徴的なオノマトペ」として選出した．

また，要支援(1-2)及び要介護度(1-5)の各段階を介護度「軽度(要支援)・中度(要介護 1-2)・重度(要介護 3-5)」の三カテゴリに分類し，各カテゴリにおいて出現しやすいオノマトペを分析した．なお，個々のオノマトペの出現回数の範囲は 1～29,834 件であり，個数による比較が困難であったため，各段階における割合によって比較することとした．また，全体での出現数が 100 件以下のオノマトペ 97 件は，出現数が少ないことから比較対象から除外した．

4. 結果

4.1 各カテゴリにおいて特徴的なオノマトペ

以下は，3. 4 において定義した 3 つの介護度カテゴリにおいてベースラインよりも多く含まれていたオノマトペのリストと，代表的なオノマトペを含む記述の実例である．また，表 1 は，各介護度カテゴリにおけるオノマトペの出現割合をベースライン「少し」(副詞)と比較したものである．

- 軽度:
  だんだん・どんどん・ブルブル・クラクラ・しっかり・すっきり・ふらふら・ホッと・ワイワイ・どんより・ドキドキ・パタパタ・にやり・テキパキ・ハラハラ

「どんどん」“意欲的にリハビリされていました．自身からどんどん進んでリハビリこなされる．今日は晴れたせいもあって調子がいいと言っていた．”(要支援 2)

表 1 各介護カテゴリのテキストデータに含まれるオノマトペの割合(%)．ベースラインを上回る数値は太文字で示している．

	軽度（要支援1-2）	中度(要介護1-2)	重度（要介護3-5）
ベースライン「少し」	6.21	24.22	13.04
ブルブル	**16.55**	**24.82**	5.76
クラクラ	**12.72**	**25.44**	7.89
どんどん	**11.98**	**24.63**	8.93
ホッと	**10.50**	24.02	10.32
だんだん	**10.38**	22.33	11.53
にやり	**8.81**	**27.86**	8.89
バタバタ	**7.98**	**27.70**	9.55
ワイワイ	**7.68**	**27.41**	9.94
しっかり	**7.66**	23.90	12.29
どんより	**7.14**	**28.75**	9.40
ふらふら	**6.91**	29.04	9.37
ハラハラ	**6.80**	**26.70**	11.00
すっきり	**6.31**	**24.26**	12.95
ドキドキ	**7.82**	**33.50**	5.78
すらすら	5.29	**32.69**	8.01
テキパキ	**8.29**	**30.94**	7.18
ポツポツ	5.94	**30.69**	8.91
すんなり	1.24	**29.19**	**13.05**
ブツブツ	1.76	**28.17**	**13.38**
きちんと	5.33	**28.17**	11.00
ギリギリ	**6.85**	**28.08**	10.05
じっくり	5.42	**27.85**	11.15
ムカムカ	5.99	**27.82**	10.80
いきいき	**6.92**	**26.67**	10.94
ニコッ	0.27	18.38	**30.06**
ごそごそ	0.12	17.78	**26.47**
ペロリ	2.36	20.87	**26.29**
ぐっすり	1.55	12.90	**23.70**
うろうろ	0.41	18.66	**20.62**
キョロキョロ	0.26	14.91	**20.53**
にっこり	1.12	19.10	**19.44**
うとうと	1.26	19.63	**19.41**
ぼんやり	3.18	22.93	**19.12**
じっと	2.08	21.13	**17.86**
にこにこ	2.29	21.44	**17.52**
そわそわ	0.84	**24.49**	**17.25**
のんびり	3.73	21.47	**16.53**
ぱっちり	0.00	4.66	**16.10**
スヤスヤ	0.00	10.86	**14.93**
ごろごろ	4.49	**23.24**	**14.84**

「クラクラ」“頭のクラクラはあるようでしたが，運動すると体調が良くなるので頑張って取り組むとの事でした．”（要支援2）

- 中度:
  すらすら・ドキドキ・テキパキ・ポツポツ・きちんと・いきいき・じっくり・ワイワイ・すんなり・どんより・ブツブツ・ごろごろ・ムカムカ・ギリギリ・ハラハラ

「すらすら」“本日もニコニコと参加され，ラダーの脳トレにもすらすらと答えていました．”（要介護 1）

「ドキドキ」“ジェンガに集中してドキドキしながら楽しまれる．”(要介護 1)

- 重度:
  ぐっすり・うろうろ・ごそごそ・ニコッ・ペロリ・うとうと・にこにこ・のんびり・じっと・そわそわ・ぼんやり．キョロキョロ・にっこり・ぱっちり・スヤスヤ

「ニコッ」“夕食前より，突然叫んだりされる．目を合わせるとニコッとされる．”（要介護 5）

「うろうろ」“少し不穏気味．フロアをウロウロされる．”（要介護 4）

表 1 が示すように，各介護カテゴリに同程度出現するオノマトペと，ある介護カテゴリにおいて頻出するオノマトペがあることがわかった．

5. 考察

5.1 本研究で得られたこと

本研究では，介護利用者の生活や，ケアの内容を記した介護記録の中から，自由記述テキスト部分に注目し，このテキストに含まれるオノマトペ表現と，各記録の対象者である介護利用者の要支援・介護度の情報を照らし合わせることにより，オノマトペを通して介護利用者の実態に迫ることを目的とした．

この目的のもと，テキストに含まれるオノマトペの分布を分析した結果，介護度軽度・中度・重度の 3 つのカテゴリにおいて，異なる性質をもったオノマトペがみられることがわかった．

5.2 オノマトペから見える介護利用者の生活

介護度が軽度である，要支援 1-2 に該当する介護利用者の記録には，「パタパタ・ふらふら」など，比較的速い動きを表すオノマトペがベースラインを上回る割合で出現していた．動きを表すオノマトペ以外にも，「どんどん・しっかり・ワイワイ」などの勢いの強い・賑やかな様子を表現するオノマトペが多くみられることから，このカテゴリに属する介護利用者は，比較的アクティブであることが伺える．要支援 1-2 に該当するのは，日常生活には支障がない人々であり，介護予防という目的からさまざまなアクティビティに参加することが多い．そのような中で，仲間と「ワイワイ」過ごしたり，「どんどん」物事を進めていることが推測される．

介護度が中度である要介護 1-2 に該当する介護利用者の記録には，介護度軽度のオノマトペに加えて。「じっくり・ギリギリ・ポツポツ」などのやや動きの遅い様子を表現するオノマトペが出現し始める．要介護 1-2 に該当する人々は，日常生活に必要な動作においても支援や見守りが必要である．そのような状況では，様々な動作が「じっくり」になりがちであることが推測される．また，「ドキドキ・ムカムカ・どんより・ブツブツ」などの不快感を示すオノマトペも頻度が増える．これらは，自らの「日常生活に必要な動作が自由に行えない状態」に苛立ちを感じたり，あるいは心身の不調を認識することが増えるためではないかと考えられる．

介護度が重度である要介護 3-5 に該当する介護利用者の記録に特徴的なのは「ぐっすり・スヤスヤ」などの睡眠状態を表すオノマトペや，「ぱっちり・ぼんやり・うとうと」などの覚醒度のレベルを示すオノマトペである．この結果は，このカテゴリの介護利用者は 24 時間体制の介護・看護を要しており，他の介護度カテゴリにはない夜間の状況の記録があるためであると考えられる．それ以外には「うろうろ・そわそわ・ごそごそ・キョロキョロ」など，落ち着かない状態を示すオノマトペが多数出現している．介護度が重度の方々は「全般的な理解の低下」がみられることが指摘されており[静岡市 15]，周囲の状況への理解が困難であるために，不穏な状態に陥りがちであることを示している可能性がある．また，「にこにこ・にっこり・ニコッ」という笑顔を表すオノマトペも出現している．これは，「特記事項」として笑顔が記録されていることをふまえると，通常時はそうではないことを物語っているのかもしれない．

また，各カテゴリに共通して 10%以上出現するオノマトペは「だんだん」と「ホッと」の 2 種類であった．「だんだん」は後続の語の意味を強める強意のオノマトペであり，汎用性が高いため，カテゴリを問わず一定割合以上出現していたと考えられる．対して「ホッと」は，「不安や恐怖が取り除かれ，息をついて安心でき

る状態になった」ことを表現しており，この表現が各カテゴリにおいて一定以上出現するということは，どの介護度にあってもケアを受けることで介護利用者は安心感を得ているのではないかと推測できる．

このように，各介護度カテゴリにおいて特徴的なオノマトペがそれぞれ存在し，それぞれの介護利用者の状態が鮮やかに表現されていることがわかった．

5.3 本研究における課題

本研究には，改善すべき課題が二点存在する．

一点目は，「本研究で分析対象とした自由記述の一部が介護利用者の状態を記述したものではなかった点」である．本研究の分析対象は，介護記録内「ケース実績」カテゴリの「特記事項（自由記述欄）」であった．この項目は，食事や排泄などの既存項目には当てはまらない「その他」の項目として設けられており，この項目にどのような内容を記入するかは，記録者に委ねられている．そのため，介護利用者の状態以外にもさまざまな内容が含まれていた．具体的には，「体温・血圧・心拍や身長・体重などの身体情報」「投薬情報」「食事やおやつのメニュー」「書類送付・次回予定などの連絡事項，季節の挨拶」である．

今回の分析では，これらを完全に除外できていないため，食事メニュー（例：はんなりおすまし）や季節の挨拶（例：じめじめした季節になりましたが…）に含まれるオノマトペが一部抽出されている可能性がある．詳細を分析する際はこれらのテキストをあらかじめ除外しておく必要がある．この点に関しては，通常テキストマイニングの初期段階で行うトピック分類を行い，テキストの内容を話題内容に沿って分類した後に，目的とする話題（介護利用者の様子）に限定してオノマトペに着目した分析をすることで解決可能であると考えられる．

二点目は，「目的に応じたオノマトペ表現を適切に抽出しきれていない点」である．テキスト内のオノマトペを分析する上での問題点として，様々な用法をされるために品詞が確定せず，品詞による抽出が不完全になってしまう点や，機械的に検索をすると非オノマトペも抽出される点[平田 11]が挙げられる．本研究では，介護利用者の様子を捉えるために副詞的用法のオノマトペに対象を限定し，分かち書き上副詞と判定された単語の中から，オノマトペを抽出した．また，オノマトペの特性である，助詞「と」を伴って出現しやすい傾向を利用して，埋もれてしまいやすい短いオノマトペは「と」を付与した形で検索するなどの工夫を行った．

しかしながら，「ブルブル（振動を与えるリハビリ器具）」や「ズンドコ・スーハー（体操）」など，オノマトペが名詞化された形で使用されるケースが多数観察された．「ワンワン」で「犬」を表現するような，オノマトペの名詞的用法は，子供向けのテキストや発話においては多く出現するが，フォーマルなテキストではまず見られない．介護記録テキストの特性との一つといえよう．これらのオノマトペに関しては，形態素解析時に適切な品詞を割り当てておくことが必要であるといえる．

5.4 展望

本研究では，自由記述の意味内容に関しては 5.3 で指摘したとおり，ほとんど分析を行っていない．単語頻度解析や意味内容に即した分類を行うことで，介護利用者全体の大まかな傾向を捉えることが可能であると考える．このような，全体の傾向を量的に捉えるための意味分析と比較すると，オノマトペに着目した本研究は，「介護利用者の様子を示す事例収集」に特化しているといえる．

本研究のような，オノマトペという特徴的な語を用いた事例収集的分析手法は，以下のような活用が可能である．例えば，「すんなり」という表現を使用しているテキストを抽出することで，「入浴を渋っていたが，○○という声掛けをすると『すんなり』入浴してくれた」といった，介護従事者が対峙しがちな難しい対応場面での，ケアのヒントとなるような事例を抽出することができる．このように，オノマトペを含めた様々な切り口から介護記録を解析することで，「介護記録に蓄積された集合知」を可視化することができると考える．

また，「現場の音を再現する」性質をもったオノマトペを通して，テキストである記録から現場の状況を再構築することも可能である．例えば，「ゴトン」というオノマトペを使用したテキストでは，その後介護利用者が転倒している記述が続く（”トイレ内より，『ゴトン』と音が聞こえたため，中に入ると床の上に転倒されていた．”）．このように，「ゴトン」というオノマトペを通して，テキスト内から「さまざまな転倒事例」を抽出することが可能である．また，転倒状況によって発する音に違いが出てくるため，対応するオノマトペを用いて異なる事例を検索し，効率的に過去の知見を参照する，という活用ができる．オノマトペというツールを用いて介護記録を切り取ることで，単なる記録にとどまらない利活用への道が開かれる可能性がある．

参考文献

[藤野 06] 藤野良孝・井上康生・吉川政夫・仁科エミ・山田恒夫: 運動学習のためのスポーツオノマトペデータベース， 日本教育工学会論文誌, 29(Suppl), pp. 5-8, 日本教育工学会, 2006.

[古市 17] 古市孝義: 特別養護老人ホームにおける介護の質の向上へ向けた介護記録の在り方, 人間関係学研究 : 大妻女子大学人間関係学部紀要, 18, pp. 49-58, 2017.

[平田 11] 平田佐智子・澤井大樹・藤井弘樹・喜多伸一: Twitter を用いたオノマトペ記述データの収集システム, 人工知能学会全国大会論文集, 人工知能学会, 2011.

[金竹 14] 金竹香織・小林一郎・橋田浩一: 介護支援システムにおける介護データの構造化と入力インタフェースの開発,情報処理学会第 76 回全国大会講演論文集, 情報処理学会, 2014.

[厚生労働省 03] 厚生労働省高齢者介護研究会 : 2015年の高齢者介護 ～高齢者の尊厳を支えるケアの確立に向けて～ , http://www.mhlw.go.jp/topics/kaigo/kentou/15kourei/sankou3.html (アクセス日時:2018 年 3 月 7 日)

[松村 11] 松村真宏: テキストデータの理論的サンプリング, http://mtmr. jp/tmp/text-sampling. pdf（アクセス日時:2018 年 3 月 1 日）

[小野 07] 小野正弘: 擬音語・擬態 4500 日本語オノマトペ辞典, 小学館, 2007.

[静岡市 15] 静岡市: 要介護度別の状態区分, http://www. city. shizuoka. jp/000055497. pdf（アクセス日時:2018 年 3 月 5 日）.

[内平 13] 内平直志: 音声つぶやきによる看護・介護サービスの記録・連携支援, 人工知能学会誌, 28(6), pp.893-898, 2013.

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

抽象絵画鑑賞における物語作成による文脈付与の効果

Effects of Context Creation Work in Impression of Abstract Paintings

只木 琴音[*1]
Kotone Tadaki

阿部 明典[*2]
Akinori Abe

[*1] 千葉大学大学院 人文公共学府
Chiba University,

[*2] 千葉大学・ドワンゴ人工知能研究所
Chiba University
DWANGO Artificial Intelligence Laboratory

When we divide paintings into two types which are abstract paintings and representational paintings, some researches showed that novice tends to have difficulties on appreciating abstract artworks. To overcome this difficulty, we suggested creating a context on abstract paintings. Since abstract paintings lack the forms which enable us to understand what is drawn on the painting, possibly, a novice could create their own imaginal forms of a particular scene on the paintings by creating context. We conducted the experiment for 29 participants to measure the effect of a worksheet with question that asking participants to create a story about the artwork. In this paper, we will focuse on a free descriptive question asking to write impressions about the artwork. We used the sentence length, number of artworks which each participant write their impressions on the worksheet and the content of written impression to measure the effect.

1. 序論

1.1 文脈

我々は日常的に完全に理解していない対象物に接し，それらを評価し判断している。しかし，ある対象物に対して不完全であっても情報を与えられるとき，我々はそれらの情報を「文脈」として理解した上で，それに基づいて評価および判断を下すことが可能になる。なお，これらは経済学において意思決定として研究が行われている行動であると考えられるが，本研究では経済学的な考察は行わない。

提供する側が客に理解可能と思われる情報をあらかじめ取捨選択することで文脈を商品に与え，受け取る側が，与えられた文脈を判断・評価の基準にする，という一連の行動は，多く行われている。美術館において展示されている作品を見る際も，同様のことが行われていると考えられる。美術館では，作品のタイトル，作者の名前と生没年，制作年，作品に用いられた材料などの情報を，多くの場合隣接した壁面などに掲示することで提供している。これらの情報に加えて，学芸員等による作品に対する短い解説文や，作家本人によるコメントが掲示されることもあり，キャプションと呼ばれている。何らかのテーマに沿った作品を展示する展覧会（企画展，特別展等）においては，作品の並び順や展覧会全体の趣旨説明のテキストも，作品についての情報になりうる。美術館が主催するガイドツアーが行われることも多い。これらの情報は，美術館あるいは学芸員から鑑賞者に提供される。美術館や学芸員は鑑賞者の理解のために事前に情報を取捨選択することで，鑑賞者のための文脈を用意していると言える。

一方で近年，美術館では，ワークシートの設置やワークショップの実施が盛んに行われている。これらはキャプションやガイドツアーとは異なり，情報を提供することを直接の目的としていないことが多い。例えば，東京国立近代美術館（2017 年 10 月 18 日訪問）において配布されていたワークシート「MOMAT コレクションこどもセルフガイド」には，東山魁夷《道》(1950)について「もし、あなたがこの道に立ったとしたら、どんな気持ちがするでしょうか。」という質問がある。この質問は，作品を制作するに至った作者の思いを考えさせる，つまり作者が作品に込めようとした文脈を意識させるという効果を狙ったものであると考えられる。

また，ワークショップにおいては，作家が用いた制作手法を追体験するようなものや，参加者どうしが感想を自由に伝えあうインタラクションを重視するもの，作品に親しみを持つためのものなどが存在している。上記の例から分かるように，ワークシートやワークショップにおいては，企画者が新しい情報を与えることは少ないため，トップダウン的に与える文脈は少ない。これは，通常は美術館や学芸員が行っていた情報の取捨選択つまり文脈の付与を，ある程度の補助を与えた上で，鑑賞者自身に行わせる活動であると考えられる。

1.2 具象画と抽象画の差異

本研究では，絵画を大きく具象画と抽象画の 2 種類に分類して考える。抽象画の定義は[岡田 1991]による「何が描かれているのかわからない絵画」を踏まえ，情報がないときに描かれている対象物が分からない作品とする。具象画とは情報がないときにも対象物が一見して見て取れるような作品と定義する。

2種類の絵画について、美術の専門教育を受けていない初心者を対象とした研究が行われている。[Schmidt 1989]は、初心者が絵画を理解する際には絵画の写実的側面に固執しがちであるということを、実験によって明らかにした。初心者による具象画に関する記述と抽象画に関する記述を比較すると、具象画に関する記述において、絵画の意味的内容（主題やシンボリズムなど）と絵から感じる気分・雰囲気についての記述が多いということが明らかになった。一方で、抽象画に関する記述においては、絵画の形式的要素（色や形や描線など）についての記述と、呈示された絵画に対するフラストレーションを表明した記述が多かった。

また、[岡田 1991]による同様に初心者を対象とした実験から、具象画と抽象画では鑑賞に伴う感情の評定が異なることが明らかになった。本実験は、Semantic Differential 法（SD 法）を用いて行われ、主に「芸術性」の評価要素について検討している。

連絡先：氏名，所属，住所，電話番号，Fax 番号，電子メイルアドレスなど
連絡先：kotonetadaki@yahoo.co.jp（只木）

芸術性の評価を行う際に用いられる各種要素のうち、具象画ではデッサンの正確性などを評価できるのに対し、抽象画ではバランスのみで評価が行われることを示唆した。[岡田 1991]は、抽象画の大きな特徴はフォルムの崩壊であるとした。

[岡田 1991]による考察と[O'hare 1976]による初心者は具象絵画を好む傾向にあるとする結果を踏まえ，[石橋 2010]は，フォルムの崩壊が絵画の好みに影響する現象を写実性制約と呼び，写実性制約が模写によってある程度緩和されることを示した。また，[田中 2013]は、構図解説を含んだ解説文と対象物解説を含んだ解説文を比較し，解説文に含まれる構図解説が写実性制約を緩和することを明らかにした。

1.3 仮説

[只木 2017a]による実験において，ジャン・フォートリエ《forest》(1995)の感想として，「(...)キャプションを見てから見ると一瞬森の精が見えた場面のように感じる。」という記述が得られた。《forest》は画面の縁を残して画面全体が緑色で塗られており，より濃い緑色のラフな描線が画面を斜めに覆っている。《forest》とタイトルにはあるものの，森などの具体的な物体を描いていると断定できるフォルムは存在しないことから，抽象画と言える。しかし，被験者は《forest》に描かれているシーンの物語（文脈）を想像することにより，「森の精」が描かれていると考えた。つまり，作品の抽象的な表現に「森」と「森の精」のフォルムを与えたと言える。この結果は，抽象画であっても物語を想像することで具象画的な鑑賞を行うことができることを示唆している。

これを踏まえて，本研究では，「物語を作って抽象画を鑑賞することによって，具象画的な鑑賞が起こる」を仮説とし，実験を行った。初心者にとって具象画の鑑賞の方が容易である[O'hare 1976]ため，抽象画を具象画的に鑑賞する方法を明確に示すことにより，ワークショップ等の開発に役立つ示唆が得られると考えられる。

2. 実験

2.1 目的

仮説「物語を作って抽象画を鑑賞することによって，具象画的な鑑賞が起こる」に基づき，物語を想像させる作業が作品に関する自由記述に及ぼす影響を検討することを目的とする。

2.2 方法

(1) 実験参加者

学生と大学教員等の 29 人を対象とした。実験の際に配布したアンケートで，義務教育と高校以外で美術制作を習ったことのある被験者と，プロのアーティストとして作品を制作・展示した経験がある被験者のデータは除いて分析した。

(2) 刺激・装置

実験には，1947 年から 2017 年に制作された 18 点の絵画作品を用いた。うち 12 点は抽象画であり，残りの 6 点は具象画である。作品は共著者の私物を借用した。作品は順路に沿って，具象画，抽象画の順で展示された。

各作品に解説パネルを作成し作品とともに掲示した。解説パネルには作品タイトル，制作年，作者名，作者の生没年，画材，解説文が含まれていた。解説文は，[田中 2013]で用いられた対象物解説と構図解説に関する情報に，実在のキャプションの傾向について調査を行った[只木 2017b]より作者略歴についての情報を加えた 200 字程度の文章とした。[只木 2017a, 只木 2017b]を参考に Adobe Illustrator を用いてデザインした。



図 1 展示風景（2017 年 12 月 23 日撮影）

実験参加者はワークシートに記入しながら鑑賞することが求められた。各作品について A4 サイズのアンケートを各 1 枚用意し，回答する作品のワークシートを選んで回答するように求めた。実験開始時に，協力のお願いと制作経験等についてのアンケートとともにワークシートをバインダーに挟んで，実験参加者に手渡した。

(3) 条件

同一の実験参加者が3条件すべてを行う被験者内要因の実験計画を用いた。条件は，(1)具象条件と(2)抽象条件と(3)物語条件の3条件だった。実験参加者は，順路に沿って具象画条件，抽象画条件，物語条件の順に鑑賞を行った。各条件にはそれぞれ 6 点の作品が含まれ，実験参加者は各条件で3点以上の作品についてワークシートに回答するように求められた。

まず，(1)具象条件で実験参加者は，具象画を鑑賞し，「Q1. この作品について感想を自由に述べてください。」と「Q2. この作品に対する印象を答えてください。」の2問が含まれるワークシートに回答した。Q2 に対する回答は，2対の単語対を提示し，どちらに近いかを 7 段階のスケールで回答する SD 法を用いた。単語対は[岡田 1991]で用いられた単語対と同様だった。(2)抽象条件では，抽象画を鑑賞し，具象画条件と同様のワークシートに回答した。(3)物語条件では，抽象画を鑑賞し，具象画条件・抽象画条件で用いたワークシートに問い「この作品の物語を作ってください。」を追加したワークシートを用いた。問いの文面が漠然としすぎている可能性があったため，解答欄に，「いつ どこで だれが なにをした」という発想のガイドになる文面をあらかじめ与えた。なお，本研究では感想の分析のみを行う。

3. 結果

本研究では，文字数，回答の収集率，回答の内容について検討した。物語に記入がない回答を除外して分析した。分析は R を用い、分散分析および Tukey の HSD 検定を行った。仮説が正しい場合，平均文字数において，(1)具象条件-(2)抽象条件間および(2)抽象条件-(3)物語条件間に有意な差がみられる。回答の収集率も同様に，(1)具象条件-(2)抽象条件間および(2)抽象条件-(3)物語条件間において，有意な差がみられると考えられる。回答の内容については，(1)具象条件と(3)物語条件において，[Schmidt 1989]で具象画鑑賞時に見られた傾向と同様に，絵画の意味的内容および絵から感じる気分・雰囲気についての記述が増え，一方，(2)抽象条件では，[Schmidt 1989]で抽象画鑑賞時に見られた傾向と同様に，絵画の形式的要素，呈示された絵画に対するフラストレーションが増加する。

3.1 文字数

Tukey の HSD 検定により，有意水準 5%のとき，(1)具象条件と(3)物語条件(p=4.86e-12)および(2)抽象条件と(3)物語条件(p=8.20e-08)において有意な差があった。

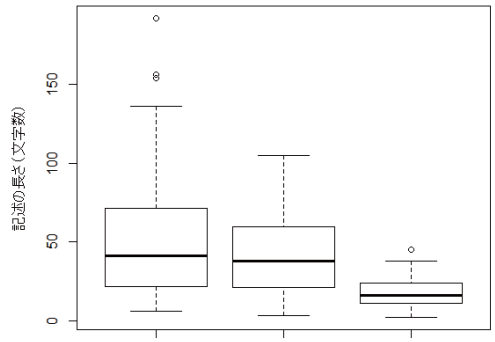


図 2 各条件での文字数

3.2 回答の収集率

分散分析により，いずれの群間にも差はみられなかった。なお，各条件 3 点以上に回答した場合収集率は 50%になるが，1 点のみの回答などもあったため，本実験の結果は必ずしも 50%以上になっていない。

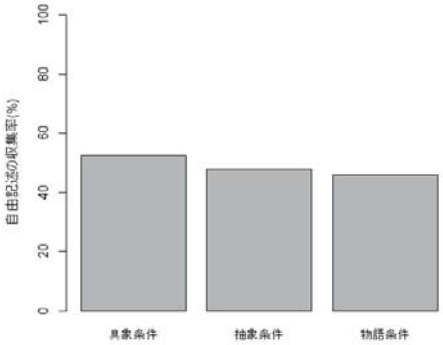


図 3 各条件での回答の収集率

3.3 記述の内容

記述内容については，各条件内で記述内容にどのような傾向があるかを検討することが目的であるため，条件間での比較ではなく，条件ごとに分析を行った。有意水準は 5%とした。

まず，(1)具象条件においては図 5 の通り，Tukey の HSD 検定により，気分・雰囲気-意味的内容間以外のすべての項目で有意な差が見られた。各要素間の p 値は，意味的内容-フラストレーションで p=0.00e+00，気分・雰囲気-フラストレーションで p=0.00e+00，形式的要素-フラストレーションで p=2.91e-10，気分・雰囲気-意味的内容で p=0.24，形式的要素-意味的内容で p=3.52e-06，形式的要素-気分・雰囲気で p=8.76e-11 であった。なお，R において p=0.00e+00 は表示できない小さい値を意味するため，p<0.05 として扱った。

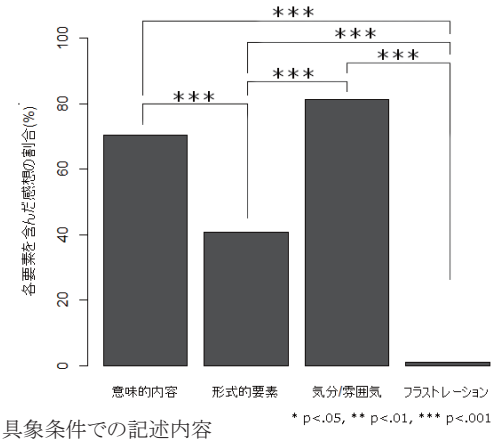


図 4 具象条件での記述内容

次に，(2)抽象条件においては図 6 の通り，Tukey の HSD 検定により，形式的要素-気分/雰囲気以外のすべての項目で有意な差が見られた。各要素間の p 値は，意味的内容-フラストレーションで p=7.96e-03，気分・雰囲気-フラストレーションで p=6.36e-12，形式的要素-フラストレーションで p=5.14e-08，気分・雰囲気-意味的内容で p=1.84e-04，形式的要素-意味的内容で p=0.036，形式的要素-気分・雰囲気で p=0.43 であった。

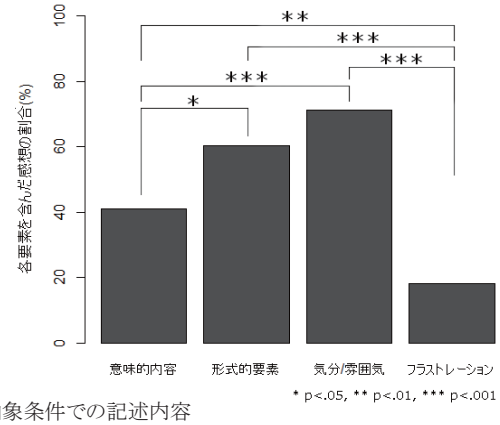


図 5 抽象条件での記述内容

(3)物語条件おいては図 7 の通り，Tukey の HSD 検定により，気分/雰囲気-意味的内容以外のすべての項目で有意な差が見られた。各要素間の p 値は，意味的内容-フラストレーションで p=2.94e-10，気分・雰囲気-フラストレーションで p=8.58e-12，形式的要素-フラストレーションで p=5.50e-03，気分・雰囲気-意味的内容で p=0.93，形式的要素-意味的内容で p=2.81e-03，形式的要素-気分・雰囲気で 3.06e-04 であった。

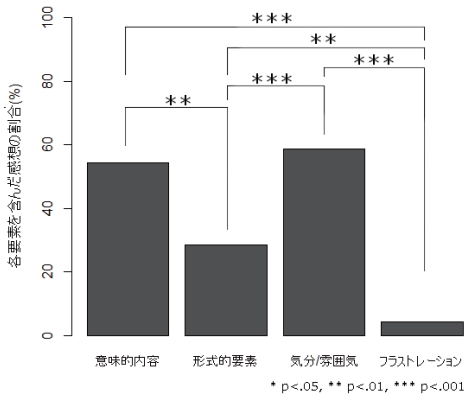


図 6 物語条件での記述内容

4. 考察

4.1 文字数

文字数については物語条件において他の条件よりも有意に文字数が少ないという結果が出た。(1)具象条件-(2)抽象条件間においては有意な差が見つからなかったものの，(2)抽象条件-(3)物語条件間に有意な差が確認されたため，仮説には一部一致した。

物語条件で用いたワークシートでは，問題数が増えた影響で感想を書ける範囲が狭まっており，それが強く影響したと考えられる。また，具象条件と抽象条件の間に差があることが予想されたが，本実験からは確認できなかった。これは，先行研究等の絵画を用いる実験と違い，網羅的に作品を収集している訳では

ない個人のコレクションから借用したため，コレクション全体として何かしらの傾向があったからであると考えられる。例えば[岡田 1991]は近現代の西洋画科の中からある表現方法を代表するような作品を選んでおり，[田中 2013]は近現代の著名画家の作品を用いていた。本研究で用いた作品は現代の作品が大部分であった。

4.2 回答の収集率

回答の収集率はどの条件間でも差が見られなかった。これは，前述の通り，各条件 3 点以上の作品についてワークシートに記入を求めたことが影響している可能性が高い。

この結果について，まず1つ目の可能性としては，「3 点以上に回答かつ記入が終わるまで次の条件に進めない」という制限を設けたことで，「3 点分のワークシートを終えたら次に進める」という認識が発生したことが考えられる。この認識の変化によって，最後まで課題を終えるという目的意識が強くなったと推測できる。この状況に類似した現象はミュージアムでも見られる。例えば，作品を見て回るスタンプラリーを用意したところ，スタンプラリーを完成させることが目的となってしまうという現象が起こることがある。明確な答えのないことが多い鑑賞と比較して，スタンプラリーは，すべてのスタンプを回った成果が，誰にでもわかる形で証明される。本実験で用いたワークシートも，決められた数の作品を見たという成果が，完成したワークシートという形で明確に見える。スタンプラリーあるいはワークシートによって鑑賞が疎外されているかは現時点で判断できないが，本研究のワークシートはある程度，成果を可視化したという意味でスタンプラリー的な効果を持ったと推測される。

別の可能性としては，疲れがある。有意差はみられなかったたが，傾向としては回答の収集率は具象条件，抽象条件，物語条件の順，つまり，呈示される順番が後になるほど回答の蒐集率が下がっている。椅子に座って記入していた実験参加者も見られたが，立ったまま記入する実験参加者が多かったため，最低限でも 9 作品という制約は負担が大きかった可能性がある。

また，回答の収集率に直接影響したことは考えづらいが，各条件 6 点のうち 3 点に回答としたことで，選択のプロセスが入ったことも考えられる。今回の結果では，特に多くの感想を集めた作品などは確認されなかったが，好きな作品や感想等が書きやすそうだと思われる作品を探して，ワークシートに回答していたとすると，すべての回答を比較するのが難しくなる可能性がある。

4.3 記述の内容

具象条件および抽象条件の結果は，具象画に関する記述には絵画の意味的内容と絵から感じる気分・雰囲気が多く含まれ，抽象画に関する記述には絵画の形式的要素と呈示された絵画に対するフラストレーションが多く含まれるという[Schmidt 1989]の先行研究と一致した結果となった。

物語条件での記述は，意味的内容と気分・雰囲気についての記述が多く含まれるという具象条件と似た傾向を示し，仮説「物語を作って抽象画を鑑賞することによって，具象画的な鑑賞が起こる」を支持した。

5. 結論

仮説「物語を作って抽象画を鑑賞することによって，具象画的な鑑賞が起こる」に基づき，文字数，回答の収集率，回答の内容について検討した。平均文字数においては一部仮説に沿った。回答の収集率についてはどの条件間でも差はみられなかった。回答の内容については，[Schmidt 1989]および仮説を強く支持する結果が得られた。

5.1 今後の課題

今後の課題としては，まずはワークシートに含まれていたすべての質問項目についての回答の分析を統合し，本実験全体に対する結論を出すことを目的とする。具象条件および抽象条件では，作品の感想を自由記述により求める質問と作品の印象を SD 法により問う質問の2問があった。物語条件では，これら2問に加え，物語を作ることを求める質問があった。印象を問う質問についてはすでに分析を終えており，各項目の SD 得点および各項目の得点の関連性（クラスタ分析による）において，仮説と全く正反対となる結果が得られた。これは，物語を作る行為が抽象画の鑑賞をより困難にすることを示唆した[只木 2017c]。[只木 2017c]は，おおむね仮説に沿う結果が出たと言える本稿の分析とは食い違うものである。

具体的な分析は行っていないが，作成された物語およびワークシート中の他の箇所での物語に関する言及から，実験に用いたワークシートでは物語を作ることが難しかった可能性もあると考えられる。「自分で物語を作った」という効力感が鑑賞に影響する可能性もあるため，物語を与える形での鑑賞との比較も行いたい。物語について今後も継続して分析を行うとともに，これまでの結果と統合し，総合的な結論を出すことを目指したい。

参考文献

[岡田 1991] 岡田守弘，井上純: 絵画鑑賞における芸術性評価要素に関する心理学的分析，横浜国立大学教育紀要，Vol.31, pp.45-66, 横浜国立大学, 1991.

[Schmidt 1989] Julie A. Schmidt, John P. McLaughlin and Patricia Leighten: Novice Strategies for Understanding Paintings , Applied Cognitive Psychology , Vol.3, pp.65-72 ,1989.

[O ’hare 1976] David O ’hare: Individual differences in perceived similarity and preference for visual art: A multidimensional scaling analysis , Perception & Psychophysics, Vol.20 (6), pp.445-452, 1976.

[石橋 2010] 石橋健太郎，岡田猛: 他者作品の模写による描画創造の促進，認知科学，Vol.17(1), pp.196-223, 2010.

[田中 2013] 田中吉史，松本彩季: 絵画鑑賞における認知的制約とその緩和，認知科学，Vol.20 (1), pp.130-151, 2013.

[只木 2017a] 只木琴音，阿部明典: ミュージアムにおける仕掛けの検討―美術館におけるキャプションを題材に―，The 31st Annual Conference of the Japanese Society for Artificial Intelligence, 2017.（4B1-OS-23a-5）

[只木 2017b] Kotone Tadaki and Akinori Abe : Museum Visitors' Behavioral Change Caused by Captions, The 2nd. International Workshop on Language Sense on Computer in IJCAI2017, pp.53-58, 2017.

[只木 2017c] Kotone Tadaki and Akinori Abe : The Influence of Story Writing Worksheets on Art Appreciation , OS17 Automated Content Generation and Cognitive Content Generation in ICAROB2018, 2017

(ICAROB 2018 ALife Robotics Corp. Ltd. (n.d) PROCEEDINGS OF THE 2018 INTERNATIONAL CONFERENCE ON ARTIFICIAL LIFE AND ROBOTICS. Retrieved March 6, 2018, from http://alife-robotics.co.jp/members2018/icarob/data/Proceedings.pdf. pp.687-690, 2018)

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

俳句生成への多重的アプローチの考察

A Consideration on a Multiple Approach for Haiku Generation

伊藤拓哉[*1] Takuya Ito
五十嵐広太[*1] Kota Igarashi
小方孝[*1] Takashi Ogata

[*1] 岩手県立大学
Iwate Prefectural University

The authors have been studying haiku generation by computer. A haiku composed of fragmentary words with, basically, only 17 syllables and haiku generation by computer is an interesting theme. Although there have been various approaches to haiku generation, in this paper, based on their previous haiku generation studies including the following two approaches or methods, the authors present a consideration on the possibility of a unified approach of the top-down generation methods using mainly symbol processing techniques and the bottom-up generation methods using chiefly neural processing such as deep learning techniques.

1. はじめに

俳句は世界最短の定型詩である．わずか十七音から成る俳句は，その形式ゆえに断片的な単語の集合である．今年で二十九回を数える「伊藤園お～いお茶新俳句大賞[1]」は累計で三千万句もの応募があり，今日の俳句人気をうかがうことができる．五音・七音・五音の組み合わせにより比較的に簡単にだれでも一句を詠むことができることが人気の一因のように考えられる．しかし一方で著名な俳諧たちの句作の逸話を聞けば，句を詠むために様々な技巧を凝らしており，一句を生み出すにも多くの工夫を必要とすることは想像に難くない．

高浜虚子は著作『俳句の作りよう』[高浜 2009a]において，句作における練習と経験の重要性を述べている．練習，あるいは経験は繰り返し行われる学習と考えられる．今日機械学習の技術が進歩し，様々な場面で活用事例が存在する．中でも深層学習の技術は画像認識において目覚しい成果を挙げ，その後も様々な分野での研究が日々行われている．

詩歌としての味わいなどの観点を抜きにして，ただ“俳句”を作るという目的のみを実現しようとするとき，満たさなければならない条件は限られている．例えば伊藤園の新俳句大賞が定義している「新俳句[2]」の条件は

- 五・七・五のリズムに乗せる
- 感じたこと，思ったことを表現する

である．また，より厳密に「俳句」の定義に習うのであれば，以下に示す[高浜 2009b]がまとめたような条件に従うこととなる．

- 五音，七音，五音の十七音から成る
- 情景を詠む
- 季語という季節を表す単語が含まれる
- 音と意味を調整するための切れ字を用いる

どちらの条件でも，ある対象を五・七・五の形式にあてはめて表現することは共通している．また「新俳句」よりも「俳句」の定義を重視するならば，五・七・五の形式に加えて季語と切れ字という条件が追加される．

このような条件に当てはめて俳句を詠もうと，あるいは作ろうとする時，その作成手順はある形式に従ったトップダウン的なものとなると考えられる．

一方で深層学習のアプローチは，個々の画像の集合などから画像の特徴を学習するように，ボトムアップ的なものである．テキスト生成に関する深層学習においても，[Martin 2017]らの研究のように，既存のテキストを学習データとして，テキストに含まれる事象の出現パターンを学習し，そのパターンに基づき入力の事象に対して後続の事象を生成するというボトムアップのアプローチが行われている．

記号処理のようにトップダウンのアプローチを行う俳句生成と，反対にボトムアップのアプローチを行う深層学習には，それぞれのメリットがあると考えられる．例えば，五・七・五の形式に当てはめて単語を組み合わせた場合，たとえその中に季語や切れ字が含まれていなかったとしても，それとなく俳句のような印象を受けてしまう．「俳句が一つの刻印であり，認識であり，思想である」と[山本 2000]が述べるように，十七音の形式に従ったトップダウンのアプローチをするとき，”俳句らしさ”が付与されるように考えられる．一方で既存の俳句を学習対象として深層学習によるアプローチを行う場合，学習対象の数にあわせて多様性が生まれ，実存の具体例から得られた統計情報により，瞬時に多量の，それも人間では考えもしないような斬新な俳句を生成できることが期待される．

本論文では，これまで筆者らが取り組んだ俳句生成の試みをまとめ，トップダウン的な俳句生成とボトムアップ的な深層学習の融合を検討する．

2. 記号処理としての俳句生成

前節で述べたように，俳句生成は形式の設定を行うことによりトップダウン的に行うことが可能である．この節では，これまで筆者らが取り組んだトップダウン的な俳句生成の試みを紹介する．

[1]第二十九回 伊藤園お～いお茶新俳句大賞作品応募開始（最終確認日 2018 年 3 月 8 日）
https://www.itoen.co.jp/news/detail/id=25019

[2]伊藤園お～いお茶新俳句大賞授業用教材資料日本語俳句高校生用（最終確認日 2018 年 3 月 8 日）
https://itoen-shinhaiku.jp/assets/pdf/high_school.pdf

連絡先：伊藤拓哉，岩手県立大学ソフトウェア情報学部，滝沢市巣子 152-52，g031n019@s.iwate-pu.ac.jp

2.1 品詞の遷移パターンに基づく俳句生成

[伊藤 2017]では俳句を品詞の集合と考え，句の中での品詞の遷移パターンを利用した俳句生成を行った．具体的には名詞と動詞のみの遷移パターンを用いた俳句生成である．

この研究において，形態素解析器には Yahoo! テキスト解析 Web API を利用した「みんなの知識ちょっと便利帳 日本語形態素解析[1]」を用いている．また，品詞の遷移パターンの獲得のための解析対象は松尾芭蕉らが詠んだ「おくのほそ道」[井本 2008]に掲載されている 63 句である．

まず解析対象の 63 句のそれぞれを形態素解析器にかけ，得られた品詞のうち，名詞と動詞のみに注目している．俳句は断片的な単語の集合であり，名詞と動詞が大半を占めると予測した上での試験的な取り組みである．この解析では，名詞と動詞の出現数にのみ注目しているため，最初に形容詞などの他の品詞が出現した場合はその句の中で出現した最初の名詞あるいは動詞から数え始めている．その解析の一例を表 1 に，解析結果をまとめたものを表 2 に示す．

表 1 名詞，動詞のみの品詞遷移解析結果の一例

俳句	草の戸も 住替る代ぞ 雛の家
品詞遷移	名詞→名詞→動詞→名詞→名詞→名詞
名詞	草，戸，代，雛，家
動詞	住替わる
品詞数	6

表 2 名詞，動詞の出現数

	1	**2**	**3**	**4**	**5**	**6**	**7**
名詞	59	51	32	42	33	14	1
動詞	4	12	30	17	6	0	0

表 1 の例では，名詞と動詞は合わせて 6 つあり，「草」が一番目，「戸」が二番目といったようにカウントされる．表 2 中の 1 から 7 は，ある句の中の 1 から 7 番目の名詞または動詞がいくつあるかを表している．例えば「おくのほそ道」の 63 句を前述の方法でカウントした場合，三番目が動詞である句は 30 句あるということを表している．この表から，「おくのほそ道」において，名詞と動詞は五個程度使われ，動詞が三番目に利用される可能性が高いと考えられた．この特徴をふまえ，筆者らは俳句生成用の型を作り生成を試みた．表 3 に生成用の型と生成例を示す．

表 3 名詞と動詞のパターンを利用した例

型	名詞(2)名詞(3) 動詞(3)名詞(3)切れ字(1) 名詞(3)切れ字(2)
生成例	俗モデル 化けるおやまや 討っ手かな
	嫁攻め手 見える飲み手へ 間抜けかな
	だれどっち 落ちるはとこか 野武士けり

型において，括弧の中の数字はそれぞれの文字数を表し，当てはめる単語の文字数をあらかじめ指定している．名詞と動詞は[Ogata 2016]が開発中の統合物語生成システムの名詞概念辞書と動詞概念辞書から該当する文字数のものをランダムで選択している．また、切れ字は 1 文字から 3 文字の切れ字をあらかじめ登録しておき，該当する文字数の切れ字をランダムで当てはめている．

なお，この取り組みでは形態素解析器によって得られる全品詞でのパターンの獲得も試みている．しかし，63 句だけではほとんどが違うパターンとなり，頻出するパターンの発見には至らなかった．大量の句を自動的に学習させるなど，深層学習の技術を用いることでの実現を目指したい．

2.2 共起情報に基づく俳句生成

[Itou 2017]では，統合物語生成システムの概念辞書中に登録されている概念同士の共起関係を利用し，概念を選択することによる俳句生成を試みた．この生成のステップを以下に示す．

1. 動詞概念辞書に登録されている動詞 A を一つ選択
2. 動詞 A と共起関係にある名詞二つ(名詞 B, C)を共起情報により選択
3. 名詞 B または名詞 C と共起関係にある名詞 D を追加
4. 動詞 A と名詞 B, C, D を並べる
5. 切れ字による調整

2 から 3 において，共起関係の強弱で概念を選択する．高共起の概念で俳句生成を行う場合，選択される名詞 B, C, D はいずれも対象とする概念と高い共起関係にある概念である．同様に低共起の場合はいずれも低い共起関係の概念が選択される．また，4 で各単語を並べるための型を決めた．以下の表 4 に生成のための型と動詞「食べる」による生成例を示す．

表 4 共起情報を用いた俳句生成の例

型	動詞 A かな 名詞 B 名詞 D 名詞 C 切れ字
高共起	食べるかな カフェテリア料理 硬水や
	食べるかな 銀ぶら先生 粳なり
低共起	食べるかな 今時早出 実験や
	食べるかな 島田コンビーフ 向う側や

この生成例では，3 のステップにおいて，名詞 B に関係する名詞 D を選択している．動詞 A のあとには切れ字「かな」をおき，名詞 C のあとでは名詞 C の文字数に応じて切れ字を追加している．また，中七音に関しては調整をかけておらず，選択された名詞をそのまま並べている．

高共起で生成した俳句は，動詞「食べる」に関連すると考えやすい名詞が選択されており，「食べる」という行為を含む光景がイメージしやすいように思われる．一方，低共起で生成を行った俳句は「食べる」に対して関係しにくそうな単語が選択されており，俳句単品から光景を想像するのは難しいように思われる．なお，この低共起の例の中で出現している「島田コンビーフ」という表現は，コンビーフの名前ではなく，髪型を表す「島田」と，「島田」と低い共起関係にある「コンビーフ」がたまたま選択された結果である．このような思いがけない表現が出来上がることは機械的な俳句生成の魅力の一つであると思われる．

この生成方法では，さらに概念の出現頻度の情報を利用することを検討している．出現頻度の操作によって，句の理解のしやすさを操作できるのではないかと考えている．

概念の共起・頻度情報を用いた俳句生成は，後述する[五十嵐 2017,2018]の単語レベルでの学習データを用いた俳句生成と強い関わりがあるように思われる．

[1] みんなの知識ちょっと便利帳 日本語形態素解析 (最終確認日 2018 年 3 月 8 日) http://www.benricho.org/moji_conv/japanese-analysis.php

3. 深層学習による俳句生成の試み

この節では深層学習を用いた俳句生成の試みとして[五十嵐 2017,2018]の研究を紹介する. 深層学習のフレームワークである Chainer[1]を用いて, 時系列の情報を学習させるための Long-Short Term Memory(以降 LSTM)[Sepp 1997]を構築することにより学習を行っている. LSTM は連続的な情報の学習に適したもので, 文章の学習などにも用いられる. 学習対象は「松尾芭蕉の旅 おくのほそ道[2]」に掲載されている 62 句である.

3.1 単語レベルの学習

学習対象の 62 句を形態素で分解し, 分解したデータを学習させ, そのデータを用いて俳句生成を行う方法である. 形態素解析器には MeCab[Kudo 2004]を用いている. [五十嵐 2018]では分解に用いる際の辞書として IPAdic と近世口語 UniDic の比較検討を行っているが, いずれの辞書でも断片的な単語の集合である俳句を意図したとおりに分割することは難しく, 主に IPAdic を用いて分割を行った.

分割した句の先頭に<BOS>, 末尾に<EOS>を付与し学習させた. 一万回学習の間に, 百回ごとの各段階の学習データを用いてに生成を行っている. 一つの生成は, <BOS>に続く単語を決定するところから始まり, <EOS>が出現するまでとしている. 以下の表 5 に生成例を示す.

表 5 一単語目をランダムに決定した場合の生成例

学習回数	生成例
100	うた早苗関かちかざしすゞ手萩更塚ぬかりのいづ伏の八のやぶら
	ん月のな
1000	笈も常も動け我泣声は秋ぞ
	象潟や料理世枕ふか草き
2000	木啄も庵は雪あきの巣
	石山の石より白し秋の風
5000	卯の花をかざしに関の晴着かな
	月清し遊行のもてる砂の上

学習回数が千回未満の場合, 表 5 の学習回数 100 の生成例のように十七音とはかけ離れた生成結果となった. 学習回数が千回を超えると次第に俳句らしい形式で安定し始め, 二千回を超えるとほぼ十七音程度の生成結果となった. そして徐々に出力結果は入力の俳句と同一のものになっていき, 五千回程度の学習を行うと, ほぼすべての出力が入力のものと同一となった. 上記の結果から, この実験では二千回から五千回の間の学習データが, 新規の俳句を生成できると考えられる.

3.2 文字レベルの学習

3.1 節の方法よりもさらに俳句を細かく分割し, 俳句の一文字ずつ文字の並びを学習させた. 3.1 節と同様に先頭に<BOS>, 末尾に<EOS>を付与し, 一万回学習させる過程で, 百回ごとの各段階の学習データを用いて生成を行った. 表 6 にその生成例を示す.

表 6 一文字目をランダムに決定した場合の生成例

学習回数	生成例
100	掃 越むのて
	風ぶ定 衣もの れにか初
1000	蛤の ふたみにわかれ 行秋風
	荒海や 須ふに 身も撫よん な
2000	世の人の 見付ぬ花や 軒の栗
	桜より 分松は二木を 三月越し
5000	五月雨を あつめて早し 最上川
	木啄も 庵はやぶらず 夏木立

こちらの方法でも, 千回程度の学習から, 十七音に近い形式で出力されるようになり, 二千回程度から徐々に入力データと同一の俳句が生成され始めた. そして学習回数が五千回超えるとほとんどの生成結果が入力と同一の俳句となった. [五十嵐 2018]では三文字ずつに分割した場合の学習も実験しており, その場合, 二千回程度での学習で生成結果のほとんどが元の学習データの句と同一のものとなった. 3.1 節での単語レベルでの学習の結果と比較して考えると, 単語の並びとして俳句を学習させるより, 単なる文字の並びとして学習させたほうが, 学習の効率は良いと考えられる. しかし生成の観点で考えれば, より早くに多様性がなくなってしまっていると考えられる.

3.3 季語を用いた生成

3.1 節と 3.2 節の学習方法を組み合わせ, より俳句らしい生成を目指した. 季語を持たせることを目的とし, 俳句中の季語のみを単語で, それ以外の部分を一文字ずつに分割した. この方法では, 俳句の表記をすべて平仮名にしている. 学習方法は先の二つと同様であるが, 生成方法は一万回学習のうちの各学習段階で生成させ, 出力が十七文字になるように条件を付けている. また, 季語を特定の位置に固定している. この方法による生成例を表 7 に示す.

表 7 一単語目に単語を指定して十七文字で固定した場合の生成例

学習回数	生成例
100	わせべびよ はがむにしきよ げつふてす
	わせぎをわ よがかしらなみ やうまのに
1500	わせのかや わけいんをねぶ あしずしざ
	わせのかや わけるてけさゝ さぎををよ
3500	わせのかや わけいるみぎか さはみぐく
	わせのかや わけいるみぎは あをよこに

表 7 に示した例では, 季語「わせ」を俳句の最初に固定し, 学習データを用いて後続の文字列を生成している. 初期の学習段階では, 単語を生成するに至らず, 意味不明な文字列が出力されている. 千回程度から徐々に単語が生成され始め, 三千五百回を超えたころでは解釈が(強引には)可能なレベルになっている. なお[五十嵐 2017]では単語レベルの学習データを用いて, 最初の単語を季語で固定し生成させるという実験を行っている. この時は文字数の固定などを行っておらず, 一万学習を行ったデータを用いても生成は成功していない.

[1] Chainer: A flexible framework for neural networks. (最終確認日 2018 年 3 月 8 日) https://chainer.org/

[2] 松尾芭蕉の旅 おくのほそ道 おくのほそ道 資料 全発句集 (最終確認日 2018 年 3 月 8 日) http://www.bashouan.com/Database/Kikou/Okunohosomichi_hokku.htm

4. 俳句生成と深層学習の融合に向けて

これまでの内容を踏まえ，俳句生成と深層学習の技術の融合に関して検討する．

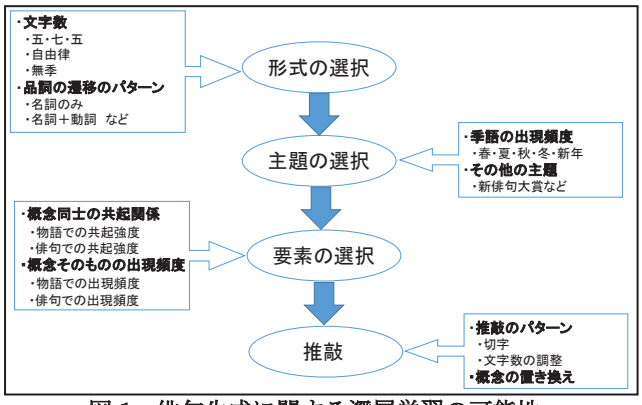


図 1　俳句生成に関する深層学習の可能性

図 1 に俳句生成のステップと，それらに関して適応できると考えられる深層学習の手法を示す．今回は俳句生成自体を「形式の選択」「主題の選択」「要素の選択」「推敲」の四つのステップで考えている．それぞれの詳細を以下に示す．

- **形式の選択：**多くの場合俳句は五音，七音，五音の十七音からなり，季語を含む．しかし，これらの形式に囚われず十七音でない俳句や季語を含まない俳句も存在する．このような俳句の形式そのものも出現確率として統計的に処理することは可能なように考えられる．また[伊藤 2017]のように，品詞の遷移のパターンの利用も考えられる．
- **主題の選択：**多くの俳句には．主題が存在する．何らかのイベントやモノを対象とするが，それらは多くの場合特定の季節を象徴する季語として扱われる．季語の出現確率などから，主題を決定することが可能であると考えられる．また，伊藤園の新俳句大賞をはじめとする現代の俳句は季語が絶対の制約となっていはいない．そのため季語辞典などに載っていないような事物も主題となっている可能性がある．新規の主題の収集などの観点からも学習が行えると考えられる．
- **要素の選択：**主題に対して，どのように他の要素を絡めていくかは俳句を詠む上で欠かせない技法のひとつである．要素の組み合わせ方で，斬新な句や趣深い句が生まれる．まず考えられるのは主題に対して共起関係にある単語を選択することである．[五十嵐 2017]のように，ある単語と共起関係にある単語の情報を学習データとして扱うことができれば，その出現確率の強弱を，そのまま[Itou 2017]の俳句生成のように利用できると考えられる．[Itou 2017]で利用した共起情報は青空文庫中の文章から計測しているが，[五十嵐 2017]は俳句中の単語の共起の確率を計測していると考えられる．この場合，俳句ならではの単語の利用方法を統計的に処理できるのではなだろうか．また，単語の出現頻度の情報も同様に利用できると考えられる．
- **推敲：**俳句の推敲過程には様々な方法が存在する．例えば切れ字の使い方一つにしても，句の切れ目や心情を表現するために多様な方法が存在する．本来高度な表現技法である切れ字を機械学習の手法によって利用する一つの方法として，形式的に切れ字の出現する位置を学習した上で，該当箇所にランダムで切れ字を当てはめてみるような方法が考えられる．また，俳句は五・七・五の形式ゆえに単語の一部のみを利用したり，異なる言葉によって間接的に表現したりする場合もある．このような俳句特有の単語の利用方法の学習も検討したい．

ここまで俳句生成の様々な場面で深層学習のアプローチを関連させる方法の考察を行った．しかしボトムアップ的に具体的なデータを収集し利用するだけで俳句生成の質が向上するかは疑問である．単に単語の組み合わせで俳句生成を行った場合，例えば複数の季語が入ってしまう可能性が容易に考えられる．果たして春の季語と秋の季語が並んだものを「俳句」と呼べるのだろうか．このような場合，もう一度できた句を形式と照らし合わせるなど，トップダウン的なアプローチを再度取り入れる必要があると考えられる．

5. おわりに

本論文では，筆者らのこれまでの俳句生成の試みをまとめた．また，「俳句らしさ」のための形式を重視したトップダウンのアプローチと，生成の多様性のためのボトムアップのアプローチによる多重的なアプローチを提案した．今後，実践を試みたい．

参考文献

[Itou 2017] Itou, T. & Ogata, T.: Haiku Generation Using Appearance Frequency and Co-occurrence of Concepts and Words , *Proc. of the 11th International Conference on Cognitive Science*, Presentation Number：121.03, 2017.

[Kudo 2004] Kudo, T., Yamamoto, K. and Matsumoto Y.: Applying Conditional Random Fields to Japanese Morphological Analysis, Proceedings of the 2004 Conference on Empirical Methods in Natural Language Processing (EMNLP-2004), 230-237, 2004.

[Martin 2017] Martin, L. J., Ammanabrolu, P., Hancock, W., Singh, S., Harrison, B. & Riedl, M. O.: Event representations for automated story generation with deep neural nets , *Proceedings of KDD 2017 Workshop on Machine Learning for Creativity*, 2017.

[Ogata 2016] Ogata, T.: Computational and Cognitive Approaches to Narratology from the Perspective of Narrative Generation in Ogata, T., & Akimoto, T. (eds.), Computational and Cognitive Approaches to Narratology, IGI Global, pp.1-74, 2016.

[Sepp 1997] Sepp, H. & Jurgen, S.: LONG SHORT-TERM MEMORY, *Neural Computation*, Vol.9, No.8, pp.1735-1780, 1997.

[五十嵐 2017] 五十嵐広太・伊藤拓哉・小方孝: 単語・文字をベースとした深層学習を用いた俳句生成，ことば工学研究会(第 56 回)資料，pp.33-34, 2017.

[五十嵐 2018] 五十嵐広太・伊藤拓哉・小方孝: 深層学習による俳句生成の試み，ことば工学研究会(第 57 回)資料，pp.35-37, 2018.

[伊藤 2017] 伊藤拓哉・小方孝: 俳句における品詞の遷移の分析―俳句生成での利用に向けて―，日本認知科学会第 34 回大会論文集，P2-48, 2017.

[井本 2008] 井本農一，久富哲雄，堀信夫，山下一海，丸山一彦: 日本の古典をよむ 20 おくのほそ道 芭蕉・蕪村・一茶名句集，小学館，2008.

[高浜 2009a] 高浜虚子: 俳句の作りよう，KADOKAWA，2009.

[高浜 2009b] 高浜虚子: 俳句とはどんなものか，角川学芸出版，2009.

[山本 2000] 山本健吉: 俳句とは何か，KADOKAWA , 2000.

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

細胞力を高める身心一体科学(1):触覚が生み出す体幹制御とオートポイエーシス能の発達

Body-Mind Integrative Science to increase cellular power (1) : Development of tactile-generated trunk control and autopoiesis

跡見順子[*1]　清水美穂[*1]　東　芳一[*1],　藤田恵理[*1]
Yoriko Atomi　Miho Shimizu,　Yoshiiti Higashi　Eri Fujita
[*1] 東京農工大学工学部材料健康科学講座
Tokyo University of Agriculture & Technology, Faculty of Technol, Material Health Science, Cell to Body & Mind Dynamics Laboratory
跡見友章[*2],　田中和哉[*2]　高田　勇
Tomoaki Atomi　Kazuya Tanaka　Yu Takada
[*2] 帝京科学大学　医療科学部　理学療法学　宇野病院
Teikyo University of Science, Department of Physical Therapy　Uno Hospital

"Body-Mind Integrative Science" describes cells of their own "body" from the cell life adaptive science and brain science as the range of cells that control the center of gravity that was developed in the gravitational field. At the same time, it is a "new science (education / research)" field that uses my own body, observes and evaluates it, makes it language including including awareness. In autonomous body science, autonomous control model of cells is the microtubule dynamics of cells responsible for autonomous center of gravity control between centrosome and adhesion points which can be said to be typical of autopoiesis. Using both hands in the recumbent posture, touch the abdomen, push it, push it back, feel it across the abdomen. Thirty people in their 30s and 80s age carried out for a week, and the permeation of daily living behavior was seen with improving exercise capacity such as sitting up.

1. はじめに

超高齢社会を円熟した人間の社会に成長させるには、一人ひとりが自らのいのちを知り生かすための科学と実践プログラムが必要である。とくに加齢とともに減退するバランス能力に対処するために立位時の重心制御能はすべての活動の基盤となるが研究が少ない。

「身心一体科学」は、重力場で創発した重心制御する細胞を範とし、自分自身の「からだ」を、細胞**生命適応科学**や脳科学から説明し、同時に**「自身のからだを使って、やってみて観察・評価し、気づきも含めて言語化する新しい科学（教育・研究)」領域**である。2015(平成 27)年度科学技術分野の文部科学大臣表彰 理解増進部門受賞した功績が、「いのちを知り生かす身心一体科学の普及啓発」である。

昨年までの「知の身体性」の OS においては、諏訪正樹のモノゴト四階層の視点で、細胞から身体までを俯瞰して自己言及的な創発単位である細胞を駆動している細胞骨格･微小管がもつ希有な能力と、その駆動の持続に必要な分子シャペロンの誘導に「わたし」の努力が必要であり、その努力は報われることに、知の身体性を洞察し、実際に教育プログラムとして導入しての効果について報告してきた[跡見 12;, 諏訪 13, 跡見 16, 跡見 17]。

本年からも引き続き、身心一体科学の原理解明とともに身心一体科学において、最も重要な「細胞から成る身」とその身を俯瞰するだけでなく、内部に棲む細胞の正しい力学応答を誘導する「わたしの心」を創発させるために、両者(身心)にとっての「触覚」の意味を物理化学的、認知的な側面など多方面から考えるとともに、触覚が成立するために内包される「運動」や「ダイナミクス」についても関係性を探ろうと思う。また、両レベルで「触覚」を生み出す生命機構､皮膚のみならず、骨格筋や腱･靱帯などの張力発揮と伝達に特化した組織をつくる細胞と、それらの「触覚」の分子細胞メカニズムについても調査しながら、健康な身心や有効な人間にとっての動作･所作・身体運動･スポーツ等についても言及してみたい。

2．体幹と触覚と細胞

あらゆる動作や運動で安全でかつ合理的な動きを生み出すための人間システムの幹である「体幹」のコントロール機能をアップさせるための方法を紹介したい。本学会では、以前触覚に働きかけて身体バランスを改善する機能性ウェアに関する報告を行っている[跡見 11]が、これは、太極拳の動作の学習により身体動作のコントロールの鍵が体幹にあることを理解したオートポイエーシス[マトゥラーナとヴァレラ 91]的経験が基となっている。後に紹介するが、多細胞動物を構成する細胞は基本的に接着性であり、分裂期を除く細胞周期において、細胞はほぼ重心に近いと考えられる微小管の中心体を核に、アクチン細胞骨格とともにやりとりしながら形の制御を行っている。中心体ではγチューブリンから成る微小管でが直交座標を創っている。多細胞動物が進化してから 10 億年だとされるが、細胞もまた重力場において基盤に接着し形態を制御している。その構造をつくるチューブリン-微小管がもつ動的不安定性は、オートポイエーシスの原型であると考えている。

体幹制御の重要性は知られていると思われるが、科学として展開するのが難しい。それ故、身体レベルではアジアの身体技法において重視される、立位の重心とほぼ一致する「臍下丹田の制御」（人間の認知行動系が学習してきた暗黙知ととらえる）と、上述の細胞の微小管システムを、そして科学するための範例として自らの体験をできるだけ言語化しながら研究を行っている。

3．臥位での体幹エクササイズ

生理学的には体幹を構成する深部筋の制御であると捉えられている。第一著者は、若い頃に腰痛を体験しており、カイエの提唱する腰痛体操を学び、身体運動の指導にも導

入してきた。しかし日常生活における油断から 3 年前に腰痛を再発した。その折に理学療法士から指導された臥位での体幹リハビリテーションエクササイズを、発展させた**「臥位体幹体操」**（+αの臥位での体操）は、365 日の毎朝の日課となっており、きわめて快適な身体感覚が生み出されることから、触覚を用いた身体チェックはもとより様々な行動変容効果、オートポイエーシス効果を生み出す有効な処方となりうると考え、少人数を対象としたプログラムで主に運動能力からその効果を評価してきた。その中でも有意にアップする「上体起こし」は、高齢者を対象とした QOL 向上に対して、重要な一を占める[村田 10]。

４．臥位を発見した体幹エクササイズにおける触覚

自身の身体動作を誘導する触覚だけではなく、身体システムを認知的に理解し、「体幹」を発見する道具としての触覚を提起する。身体を定位させるための自重を担う支持基底面となる背部の触覚と**「外に出た脳である手」**［河本 07］を用いた腹部への触覚刺激を用いて、認知系に上りにくい体幹が暗黙知として機能するようになり、実際の立位における生活の中でのスムースな動作を引き出す効果が得られているので紹介する。オートポイエーシス［マトゥラーナとヴァレラ 91］の訳者であり、その後、オートポイエーシスの第三世代[河本 95]から、第 4 領域[河本 06]、拡張［河本 10］まで発展させ触覚こそオートポイエーシスの中核的な感覚として活動している河本英夫は、**「手は外に出た脳であり、身体は外に出た脳の容器である**。--頭蓋骨の中に収まっているのは、脳の構造部材であり、この構造部材を有効に活用するためには、外に出た脳に有効なエクササイズを課すしかない」という［河本 07］。実際の人の体幹の皮膚面積はきわめて広いが、脳の体性感覚野における部位は狭い[ペンフィールド 11]。直立二足歩行を獲得した人においては、体幹部は抗重力的に機能しており、実際脊柱起立筋は他の四足動物と比較して遅筋の比率が高い。通常の生活ではほとんど触覚も含めてどの感覚モダリティーも知覚されない体幹の背部に注目する。

人は臥位で眠るので、背部は、「平らな平面」を知っている（河本英夫）が、自分の背中には手さえ十分には機能しない。つまり目が届かない。しかし、臥位という体位においては腹部皮膚への触覚を介した認知から誘導する腹筋群の緊張とともに誘導する脊椎の繊細な動きの誘導により背部と脊柱が認知されるようになる。さらに臥位は、支持基底面が広く、立位時にはなにがしかの歪みがある身体の歪みを顕在化させず脊柱周辺の 400 個もある感覚センサーとしての筋紡錘を豊かに含む大小様々な筋群の緊張を除くことが可能となる。臥位という姿勢は、我々ヒトを含む脊椎動物は元来生まれたときの体位である。水中で生まれた脊椎動物は、脊椎を重力と平地させ、それにより身体の形態を生み出すだけでなく推進力を発生している。人にとっても臥位は懐かしい体勢なのである。

５．物質システムから考える細胞と身体と触覚

5-1 Stretching is good for a cell [Ruoslahti 97]

細胞は基盤から解離するとアポトーシスに陥る。接着は細胞にとって生存のための第一要因である。

5-2. 細胞の分子生物学からの身体と運動と触覚

細胞において接触は接着という。細胞の生存原理と身体の関係について触覚を考慮してまとめておく。

1）人間は、多細胞動物である

2）身体は、37 兆個の細胞［文献］と、細胞が分泌した細胞外基質(ECM)から成る（うち 26 兆個は、赤血球）

3）赤血球を除く 11 兆個の細胞は、接着性であり、基質や他の細胞に接着して、形を作り張力を発揮する。自分の環境と化学的応答だけでなくメカニカル応答する

4）人間は動物なので、身体は動くようにできている. 動きには支点が必要で触覚と用いている。

5）故に、**身体運動は，細胞へのメカニカル刺激(ストレス)**となり、身体−細胞の両レベルで触覚−接着が基幹となる。

6）人間は，重力場で生きている多細胞脊椎動物である

7）細胞は、細胞の重心をダイナミックに制御する（やわらかい）**タンパク質力学応答システム「細胞骨格−細胞接着分子−細胞外基質」**をもち、生存の基盤と成している。

8）「細胞と身体を直接、力学的につなぐ運動は、細胞の生きる刺激となる」［Ruoslahti 97］と同時に、「力学的にまちがった運動は膝や腰の関節に障害を与える」

9）故に人間は、重力場で「力学的に正しい体の使い方」を学ぶ必要がある(多関節可変構造から成る脊椎はやわらかく不安定であり、重心となる体幹制御がポイント)

10)やわらかい細胞とタンパク質のかたちのお世話をするストレスタンパク質(分子シャペロン)が適応の鍵である。

参考文献

［跡見 12］跡見順子, 清水美穂, 跡見友章, 廣瀬 昇: 細胞・身体の不安定性の二階層と制御要求性から探る「知の身体性」基盤, 第26回人工知能学会全国大会論文集, 3E2-OS-16-11 (2012)

[諏訪 13]. 諏訪正樹, 跡見順子, モノゴト四階層で生の営みをみる. 第27 回人工知能学会大会論文集, 3G4-OS-12b-6 (2013)

［跡見 16］跡見順子, 清水美穂, 藤田恵理, 跡見友章, 廣瀬昇, 田中和哉, 長谷川克也, いのちを知り生かす身心一体科学(その一) : 人間の二重のいのち(細胞と身体)をコネクトする物質に観る「知の身体性」, 第 30 回人工知能学会大会論文集, 2L4-OS-26b-2 (2016)

［跡見 17］跡見順子, 東芳一, 清水美穂, 藤田恵理, 跡見友章, 田中和哉, 長谷川克也, いのちを知り生かす身心一体科学(その二)第 31 回人工知能学会大会論文集, 2L4-OS-26b-2 (2017)

［跡見 11］ 跡見順子跡見友章, 廣瀬 昇, 清水美穂, 桜井隆史, 身体知を引き出すアンダーウェアの開発～触覚が引き出す姿勢制御, 第25 回人工知能学会大会論文集, 3D2-OS8-11 (2011)

［マトゥラーナとヴァレラ 91］ H.R. マトゥラーナ/E.J.ヴァレラ「オートポイエーシス˜生命システムとは何か」国分社, (1991)

[村田 10] 村田伸等, 地域在住高齢者の上体起こし可否と身体および心理機能との関連, 理学療法科学, 25(1)115-119 (2010)

[河本 95] 河本英夫. 第三世代オートポイエーシス

[河本 10] 河本英夫.オートポイエーシスの拡張. 青土社(2010)

[河本 07] 河本英夫. 哲学、脳を揺さぶる。日経 BP.(2007)

[河本 06] システム現象学オートポイエーシスの第四領域.新曜社(2006).

[河本 17]河本英夫+稲垣諭.現象学のパースペクティヴ.晃洋書房(2017).

[ペンフィールド 11] 脳と心の神秘.W. ペンフィールド. 法政大学出版局(2011).

[Ruoslahti 97] Ruoslahti E. : Stretching is good for a cell: *Science*, 276, 1345-1346 (1997)

Oral presentation | Organized Session | [Organized Session] OS-22

[3B2-OS-22b] [Organized Session] OS-22

Thu. Jun 7, 2018 3:50 PM - 5:30 PM Room B (4F Moon Light)

[3B2-OS-22b-01] Is the expression of taste abstract or representational?

○Akinori Abe[1] （1. Chiba University）

3:50 PM - 4:10 PM

[3B2-OS-22b-02] Analysis of Taste Expressions Similarity of Japanese Sake

○Junichi Fukumoto[1] （1. Ritsumeikan University）

4:10 PM - 4:30 PM

[3B2-OS-22b-03] Multi-layered Taste Representation with Shapes and Adjectives

○Kazunori Miyamoto[1], Hiroki Fukushima[1] （1. Kyushu Women's University）

4:30 PM - 4:50 PM

[3B2-OS-22b-04] Invited Lecture

○Yuki Watanabe[1], Takashi Okamoto[1] （1. SENSY Inc.）

4:50 PM - 5:30 PM

©The Japanese Society for Artificial Intelligence

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

味のことばは具象か? 抽象か?

Is the expression of taste abstract or representational?

阿部 明典 *1
Akinori Abe

*1千葉大学 文学部 人文学科 行動科学コース/ドワンゴ人工知能研究所
Division of Behavioral Science, Faculty of Letters, Chiba University/Dwango Artificial Intelligence Laboratory

Recently we have been discussing how to express the taste of Japanese sake. During describing the taste of Japanese sake, we found a question whether the expression of the taste is abstract or representational. Previously, I discussed the effect of drawing the taste. The drawings can be regarded both abstract and representational. Because they were drawn because it was quite difficult to express the taste by words. Accordingly they may be abstract. However, if we chenge the viewpoint, it can also be regarded representational. Because they described the taete which we could not see.

1. はじめに: (酒の) 味は、抽象? 具象?

私の学生の只木に OS「身体と触覚の重層的な認知」に投稿を (やや無理やり) 勧めているときに、彼女が言ったことが、「絵を言葉で表現するのが抽象画と具象画で違いそうとこみたいな話かなぁ... という程度しか決まってない」であった。それに関して、オーガナイザの福島氏と、

阿部: 個人的には、形のない酒は抽象画かなぁ...
福島: 個人的には酒は視覚刺激ではないですが感覚を描いているのでかなり具象です

という話をした。全く対立している意見が出たのである。しかし、どっちも正しそうである。私は味には (液体としても) 形がなく、表象的ではないので、抽象に入るのかなと単純に思った。しかし、湖や海のような水の光景を描いた絵は具象と考えられている。例えば、国立西洋美術館の Gustave Courbet の「波」は岩以外はほぼ水と空が描かれている。空、波の形象もあり、具象といえよう。しかし、水面をテーマとした絵はやや微妙かなという感じである。波紋はあり、具象といえば具象と言えるが、見方によっては、抽象かもしれない。例えば、Ai Shah の作品 (`http://news.rabbitalk.com/archives/real-minamo-aburae-ai-shah.html`) は、展覧会の説明によれば、「あらゆる外的要因によって水面に生まれる静かな波紋。その一瞬を写実的に描いた作品」であり、基本的には、具象画であろうが、その精密さ故、抽象画にも見えるのである。日本酒自体を絵で描く訳ではないが、味を表現する時には頭の中に "味の絵" を描いているはずである。それは、具象であろうか? 抽象であろうか? 本論文は、それに対する一つの答えを出そうとするものである。

2. 日本酒の味の表現

2.1 日本酒の表現は少ない?

以前も書いたが、日本酒にはワインのような味の辞書は余りない。せいぜい、福島の作成した「日本酒味わい事典」[Fukushima, 2013a] くらいであると思う。従って、日本酒の味を記述するときはライターの夫々の感性で描くことになる。ワインであれば、BC Liquor Stores, Vol. 19, Issue 2 (summer 2017) に Quail's Gate Pinot Noir (2015) に就いて以下のような記述がある。

> Elegant and sophisticated, this Burgundian-style Pinot Noir expresses bright strawberry, red cherry and spice with hints of forest floor and earth. Medium-bodied with fine tannins, this will pair well with salmon.

[Abe, 2017b] に次のように書いたのだが、"In fact, "hints of forest floor" is frequently used phrase for nice wines. In addition, "forest floor" is used for matured wine. A forest floor is defined as the above-ground layer of a forest made up of tree roots, soil and decaying matter (Collins English Dictionary). Thus the taste of wine can be imagined as a *soil and decaying* (matured) taste and flavour. The richly organic layer of soil and debris is a characteristic of forested land. This will also be a characteristic of the wine. This phrase can become a type of a good metaphor." 基本的に、記述だけで涎が出るような味を感じることができる。英語というやや論理的な言語のせいかも知れないが。日本の場合、味以外に作った人の個性なども書かれていることがある。畑の土が固いなどの情報はブドウの生成に対して影響を与えると思うが、「御年 79 歳のフェルナンデスさんの人生をかけた *1」などの記述があると、最近、売れゆきをよくするために、商品に物語を付けるとよい [Jensen, 1999] ということ指摘されているとはいえ、このような根性/人生物語は日本的なのかなと思う。

日本酒の場合、以前の論文でも紹介したが、「LOVE ♡ 日本酒!, 2014, 2 Gakken」の場合、以下のような記述がある:

- 醸し人九平次 Eau Du Desir 2012

  口にした瞬間は果実のフレーバーが強く感じるものの、適度な熟成を経ると蜂蜜やバニラの香を覚えます。旨味は

連絡先: 阿部 明典, 千葉大学 文学部 人文学科 行動科学コース, 〒 263-8522 千葉市稲毛区弥生町 1-33, ave@ultimaVI.arc.net.my, ave@chiba-u.jp

*1 El Vinclo 2010 に対して「Real Wine Guide 第 52 号 (2016, Winter), リアルワインガイド 2015 年旨安ワイン」に書かれていた。

華やかな酸を軸に広がりますが、ミネラル感が下支えするため全体的には立体的な味に。....

- 而今 純米吟醸 八反錦

  口に含んだ瞬間、その芳醇な味わいに驚かされます。また酸と旨みのバランスも絶妙! さらには切れの良さも感じられるので、女性でもスイスイと飲めるはず。....

「醸し人九平次」に関しては、味を具体的に描いているが、「而今」に関しては、余り具体性はない。ワインのような辞書がないせいであろうか?

おいしさの表現辞典 [Kawabata and Fuchigami, 2016] という本がある。この本は、様々な文献から味に関する記述を集めている本である。7-2 嗜好飲料類の項目にお酒に関する記述が集められている。日本酒に関しては、あまり多くない。ソムリエ田崎の本と「おいしんぼ」からの記述が多い。更に、それ以外は、味の記述ではなく、酒を飲んでいるといった情景の描写が多い。小説に酒の味を事細かく書いても仕方ないので、書かないのかもしれないが...

酒屋の記述はどうであろうか? 筆者の大学のそばにあって、よく使っている「酒舗にしうら」の facebook (`https://www.facebook.com/syuhonishiura/`) にある記述をお借りする。「鳴海 特別純米 直詰め生【白】」に関しての記述 (2018 年 1 月 27 日) である。「甘みのある米の旨みと酸のバランスがとても良いです。黄色い柑橘や白い果肉の果実のジューシィさの後に麹の香ばしさを感じます。ガス感もきめ細かくチリチリと口の中を刺激して、キレ良くフェイドアウト。程よくふくらみのある旨口のやや辛口です。」かなり具体的な味の記述をしていると思う。この酒は入手しているが、原稿を書いている時点ではまだ飲んでいない... が、鳴海の味作りに近い味の表現だと思う。「ジューシィさ」、「チリチリ」、「フェイドアウト」というカタカナことばでも表現しているが、表現に冷たさや固さは感じない。それどころか、新酒のまだ不安定な味をうまく表現できているのではないかと思う。酒屋なりの表現ではないであろうか? 更に、「この酒は、社長君塚が冬場に日々魂を込めて作り出す麹と、千葉県独自の食米「ふさこがね」のポテンシャルを最大限に引き出す発酵技術により生まれたハイパー旨口酒です。」といった、日本人好みの「魂を込めて」という物語も付け加えられている。

2.2 日本酒の表現を形で?

上記したものは、味のメタファー的な記述である。味そのものは、普通には、目に見えない。従って、目で見たとしたらの譬え話になる。例えば、瀬戸は「味ことば」を、メタファ、メトノミー、シネクドキを中心にして、共感覚表現 (双方向性を持つ) から説明している。つまり、味は比喩のようなもので表現出来るし、触覚・嗅覚・視覚・聴覚を用いて味覚を表現していると示している [Seto, 2003]。例えば、「チャック・マサラはガラン・マサラの辛味に黄色い唐辛子の丸みのある辛さが足される」のように、視覚が味を表現するために使われるのである。この場合、辛いという感覚は突き刺すようなので、尖ったという視覚を伴うと思われるが、余り辛くないという感覚は、尖ったものが無くなったという意味で、丸いという視覚が使われているのである。

日本以外では、Velasco が、roundness/angularity という形と基本的な味の関係を実験した研究がある [Velasco et al., 2015]。その結果から、Velasco は、人間は味のことばを無矛盾に形に当てはめることが出来ると結論づけている。そして、この結果から以下のように言えるとしている。"...there was a distinction between sweetness which was matched to roundness, and other tastes (bitter, salty, and sour) which were matched to angularity instead." なんとなく、この指摘は我々の直観と合っているように思われる。苦かったり、酸っぱかったりすると、尖っているのである。この実験では、辛いが入っていないが、辛いも尖っているはずである。例えば、[McQuaid, 2015] では、「トウガラシの辛さは痛みを伴うが、快楽ももたらしてくれる」と書かれている。余りに当たり前すぎて Velasco は、実験しなかったのであろうか? ちなみに、Velasco の実験で使われている絵は、綺麗な正方形や丸もあるが、それ以外は落書きのような絵である。味のイメージとしては使えるが、味の記述としては雑かも知れないし、決して味を表してはいないと思う。ちなみに、ここで使われている絵は、抽象画と言われれば、抽象画とも言えるかも知れない。

絵といえば、日本酒のラベルにも絵が描かれている。日本酒×作家創作プロジェクトの「日本酒ものがたり」 (`http://sakemono.com/`) 日本酒に宿る物語を、作家が描き出すという意向で行われている。「華姫桜 しずく媛 無濾過純米吟醸原酒」のラベルにつけられている絵が 図 1 に示すものである。アニメチックな絵である。



図 1: 華姫桜 しずく媛 無濾過純米吟醸原酒」のラベル

この酒は、無濾過純米吟醸原酒なのであるが、味は、期待と反して熟成感満載であった。ホームページを見ると、137 歳というキャラ設定があるので、熟成なのかも知れない。しかし、ラベルの女性と実際の味は釣り合わないと思った。少なくともこのラベルと見た時に期待した味ではなかった。この絵は、蔵としてのお酒のイメージを表しているかも知れないが、味は表していないような感じである。具象画が描かれているが、味を全く表現していないので、本論文で議論している絵とは違っている。ちなみに、アイドル好きにこの酒を売るのなら、成功かも知れない。

IJCAI2017 で開いたワークショップでも示したが、味を表現する時に全てことばで記述するのは難しい。もしかしたら、後でゆっくり考えると表現できるかも知れない。しかし、限られた時間で描くとなるとことばが思いつかない、口に出てこないことが多い。大塚、諏訪、山口が行っているようなオノマトペ [Otsuka, Suwa, and Yamaguchi, 2015] なら、すぐ出るのかも知れない。しかし、再現性は、私には難しいと思われる。従って、私が表現するときはどうしても絵の助けを求めることが多い。それは味の位置であったり、形であったり、動きで

あったりする。最終的には電子文字に書き起こししないといけないので、この絵を頼りに、飲んだ時の記憶を辿りながら文字起こしもするのである。

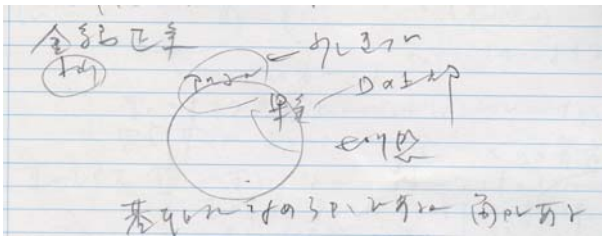


図 2: 酒の味を表現する時に描いた絵 (味の位置)

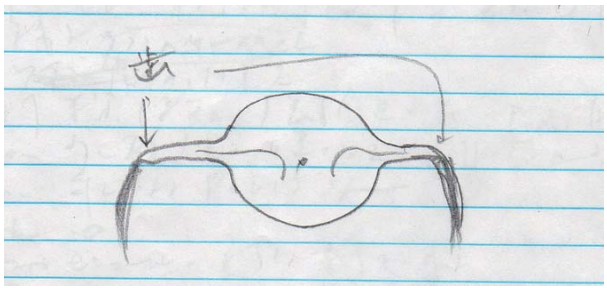


図 3: 酒の味を表現する時に描いた絵 (味の存在感)

例えば、図 2 は、金鶏正宗 京仕込特別純米生原酒の味の記述であるが、この絵では、味の位置を示している。恐らく、味が色々な場所に点在しており、それをまとめて書くことが出来なかったので、このような絵を描いたのだと思う。図 3 は、自然郷 セブンの味の記述であるが、この絵では、味の動きなど、口の中での存在感、味の流れる形を描いている。この場合、味の動きを文字でうまく書けず、絵を追加したのだと思う。この絵では使っていないが、矢印で味の流れる方向を描いている場合もある。この場合、正確に味の流れる方向がわかる図 2 は、見方によっては、設計図のように見えるので、具象かも知れないし、対象を映しているわけではないので、抽象かもしれない。図 3 は、何となく形が分かるという意味では、具象なのかも知れないが、抽象とも言えるかも知れない。図 2 に対しては、「アルコールが少しきついのがてっぺんに感じる。口の上部には果実味がするが、その外側にはピリ感がある。基本的に滑らかであるが、角がある。」のような記述になる。説明っぽい記述になるので、具象と考えていいのではないだろうか? 図 3 に対しては、「口に含んだ時はおっいけるという感じ。しかし、そのあと、舌の横から水が漏れるように味が消えてゆく。最初の酒の味は広がらず、水のような味が舌を抜けて歯の間から逃げてゆく。“面白い” 味。」という記述になるが、やや詩的ではないかと思う。上下などの位置情報を書いておらず、歯のような身体の位置で場所を示している。メタファー的に記述しているので、正確には情景を映しておらず、抽象と考えていいのではないだろうか? 二つだけ例を出したが、経験的には、やや表現しづらい味に関しては、表現は、抽象になる傾向があり、きちんと説明できる味に関しては、具象になるのではないかと思う。上記の例では、まだ表現しやすかったが、更に表現しづらい味もある。その場合は、完全に抽象になるというか、表現の仕方に苦労する。

3. 抽象と具象の狭間で

偶然であるが、2018 年の 2 月頃に都内の 2 か所で、抽象と具体を対比、融合させた展覧会が開催されていた。府中市美術館で開催されている「絵画の現在」(https://www.city.fuchu.tokyo.jp/art/kikakuten/kikakuitiran/kaiganogenzai.html) と損保ジャパン日本興亜美術館で開催されている「クインテット IV — 五つ星の作家たち」(http://www.sjnk-museum.org/program/past/5165.html) である。

府中市美術館では、直接対決のような書き方はしていないが、ちらしには、「風景に人物、抽象表現に立体が少し...」と書かれている。風景には津上みゆきの絵が含まれているのだと思われるが、ここでの表記上は抽象と区別しているように思われる。彼女は「風景画は、そこに在る、存在する自然、自然現象、人工物も含む自然の状態のすべてを観察し、そこらを平面に置き換え、色や線・形を配置し、そこから風景を連想させることで、初めて成立するトリッキーなものである。」と記している [Kamiyama, 2018]。彼女の絵では、「View, Tokyo Merry-go-round, Winter, 2017」と具体的な場所と季節がタイトルに書かれている。しかし、彼女の絵には実在する風景が描かれているのだが、白内障の手術をした Monet の絵以上に抽象と言えるのではないだろうか?

損保ジャパン日本興亜美術館の方は、ちらしの中で「具象と抽象の狭間の深い闇の中で光を求めて彷徨い続けているのが現代作家たちであり、私たち自身でもあるのです...」と具象と抽象の間で彷徨うをテーマにしている。五十嵐は、「彼女らは理知的な線・形態と感覚的な色彩を組み合わせて、自然を写す (自然主義) ことと自己世界を表出 (表現主義) する振幅の中で制作している。....「具象」と「抽象」というカテゴリーの存在さえ意識しないほど、彼女らの制作は自然体であり、また「平面」と「立体」のボーダーにも拘泥していない。」と指摘している [Igarashi, 2018]。実際、田中みぎわは墨絵で、なんとなく風景が見える具象画のように見えるが、室井公美子の作品は、Monet の水連のように一瞬見えながらも、所謂抽象画である。彼女は、「具体的な「形のかけら」を画面に散りばめていますが、このように見て欲しいというよりも、見る人のそれぞれの記憶によって別の世界が見えてくれればいいなあと考えています。... 画面とのやり取りの中で偶然できた形や色、絵具の厚みや滴りなどを展開してゆき、私が知らない何かをそこでみたいな、そんなことを繰り返している感じです。」と展覧会のカタログで述べている。実際、ある場所を描いているようなタイトルもあるが、抽象っぽい絵画である。このように、現在は、作家たちは、抽象と具象を区別しないで、というか、出来ないで表現をしていると思える。というか、今や、抽象と具象を区別すること自体が意味ないのかも知れない。実際、“the difference between Representational and Abstract Art is the Subject of the art work and we know that subject is a matter of choice. Supporters of Representational Art, while still holding some internal preferences, would not totally discard the choice of a landscape as a subject versus a figurative work or a still life. So, why would we discard a different choice of subject, a non-objective one, as long as the Elements of Art and the Principles of Art are executed with mastery?

Representational and Abstract Art do not exclude each other. They both present the basic properties of a work of art to be perceived through our senses.” という指摘

[Brooks, 2013] もある。絵という表現形態では、具象と抽象は分け難いということになりそうである。但し、ここまで至るまでに、Kashimir Malewitch の提言した suprematism (絶対主義) という考えもあった。それは、現実とのあらゆる対応関係を排除した絶対的な抽象を志向したもので、白黒の円や正方形のみを構成要素とする「無対象」絵画を描くものであった。彼は、写実的な絵画のような従来の芸術を、具象としての自然を単に模写したものとして斥け、芸術はそれ自体が自然から独立したものであるべきだと唱えた *2 [Malewitsch, 1927]。酒の味を表現する時は、「無対象」を描く訳ではないし、人間にとって、行動するときに現実とのあらゆる対応関係を排除することはありえないので、この考えは、面白いが、使わない。更に書くと、スターリン体制下になると一転してこれらのロシア・アヴァンギャルド芸術は、絵画だけではなく、全て弾圧を受けることとなったので、結局、最後は具象絵画に戻った。社会体制の所為なので、決して抽象絵画 $\leq$ 具象絵画という意味ではないと思う。従って、上記したように、現在の絵画で具象、抽象を区別することは意味がないことなのかも知れない。

4. まとめ: 酒の味を記述することの耐え難い難しさ

本研究は、まず、日本酒の味の表現できることばが少ないという現実から始まり、更に、昨年の人工知能学会全国大会 [Abe, 2017a] や IJCAI2017 のワークショップ [Abe, 2017b] で議論した味の表現の仕方に就いて絵を用いることで、表現が拡張できるという話につながっていく。

味は、形が見えない? 表現はするが.... それは、メタファーの場合もあるし、絵で描くこともある。一方、絵画は conceputual art 以外はメタファーでは恐らく表現しない。図式的には、

味 —- 絵 (形) —- 抽象画/具象画

となるが、前節で現在の絵画で具象、抽象を区別することは意味がないと指摘したようにここで、味を表現する絵が抽象画 or 具象画であるかを決定することは意味がないかも知れない。更に言うと、Malewitch の提言したような、白黒の円や正方形のみを構成要素とする「無対象」絵画を描く suprematism (絶対主義) は酒の味の表現ではありえないとと思う。確かに、ことばでの表現も形の組み合わせと言えるかも知れないが、偶々形の組み合わせになっただけで、形のみを構成要素と限定はできないと思う。ことばでの表現が難しい時に、形でことばの表現を補うだけである。

ワインの表現では、 “hints of forest floor and earth” のように実際の物質ではあるが、それそのものではなく、ある風景を示唆することも行う。しかし、決して風景を描写している訳ではない。そこから得られるイメージを描いているのである。そういう意味で、津上みゆきの絵に近いかも知れない。日本酒でもこのような描き方はできるかも知れない。

ここで、最初の問いに戻る。日本酒自体を絵で描く訳ではないが、味を表現する時には頭の中に “味の絵” を描いているはずである。それは、具象であろうか? 抽象であろうか? ここまでの議論では、区別することに意味はないとなってしまうのである。現在の絵がそのようになってきているので。味の表現は、津上みゆきのような表現でいいのではないかと思う。わずかに、具象的な要素を残しながらも抽象的表現を行う。いずれにせよ、当初の目標である、日本酒の辞書を作ることは早くしないといけないと思う。そこに含まれることばは、具象でもあり、抽象でもあることばになると思う。

*2 Unter Suprematismus verstehe ich die Suprematie der reinen Empfindung in der bildenden Kunst. Vom Standpunkte des Suprematisten sind die Erscheinungen der gegenständliehen Natur an sich bedeutungslos; wesentlich ist die Empfindung — als solche, ganz unabhängig von der Umgebung, in der sie hervorgerufen wurde.

参考文献

[Abe, 2016] 阿部 明典: 味覚の表現, *2016* 年度 人工知能学会全国大会 *(*第 *30* 回*), 3M3-OS-20a-1* (2016)

[Abe, 2017a] 阿部 明典: 味ことばの表現に関して —手書き/電子化入力, *2017* 年度 人工知能学会全国大会 *(*第 *31* 回*), 2P3-OS-18b-2* (2017)

[Abe, 2017b] Akinori Abe: About the better expression of taste, *Proc. of the 2nd. Int'l Workshop on Language Sense on Computer in IJCAI2017, pp. 28–34* (2017)

[Brooks, 2013] Hebe Brooks: Representational versus Abstract Art, `https://noapsblog.com/2013/08/12/representational-versus-abstract-art/` (Posted on August 12, 2013)

[Fukushima, 2013a] 福島 宙輝: 日本酒味わい事典, 慶應義塾大学 (2013)

[Igarashi, 2018] 五十嵐 卓: 『クインテット IV』出品作家たちの視座: 具象と抽象の狭間, クインテット IV — 五つ星の作家たち, 損保ジャパン日本興亜美術館, *pp. 7–9* (2018)

[Jensen, 1999] Jensen R.: *The Dream Society: How the Coming Shift from Information to Imagination Will Transform Your Business*, Mcgraw Hill (1999)

[Kamiyama, 2018] 神山 亮子 編集: 絵画の現在, 府中市美術館 (2018)

[Kawabata and Fuchigami, 2016] 川端 晶子、渕上 匠子 編: おいしさの表現辞典 新装版, 東京堂出版 (2016)

[Malewitsch, 1927] Kasimir Malewitsch: *Die gegenstandslose Welt*, BAUHAUSBÜCHER ()

[McQuaid, 2015] John McQuaid: *Tasty: The Art and Science of What We Eat*, Scribner (2015) (中里 京子訳: おいしさの人類史, 河出書房出版社 (2016))

[Otsuka, Suwa, and Yamaguchi, 2015] 大塚 裕子, 諏訪 正樹, 山口 健吾: 創作オノマトペによる日本酒を味わう表現の研究, 2015 年度 人工知能学会全国大会 (第 29 回), *2N5-OS-16b-5* (2015)

[Seto, 2003] 瀬戸 賢一 編著: ことばは味を越える 美味しい表現の探求, 海鳴社 (2003)

[Velasco et al., 2015] Carlos Velasco, Andy T. Woods, Ophelia Deroyc, and Charles Spence: Hedonic mediation of the crossmodal correspondence between taste and shape, *Food Quality and Preference, Vol. 41, pp 151–158* (2015)

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

日本酒味表現の類似性の分析

Analysis of Taste Expressions Similarity of Japanese Sake

福本 淳一 *1
Junichi Fukumoto

*1立命館大学 情報理工学部
Faculty of Information Science and Engineering, Ritsumeikan University

Taste of Japanese sake is frequently expressed with the expression “Karakuchi (dry taste).” However, there are many kinds of taste and flavor in Japanese sake. We have analyzed monthly sake reports delivered from Nishimura sake shop at Kyoto, which include various kinds of expressions of sake taste such as flavor, sweet taste, bitter taste, sour taste and so on. We tried to analyze similarity between sakes in terms of several points of taste expression using syntax analyzer CaboCha. As the results, some similar taste Sakes were extracted based on this method, but it will be necessary to use more information such as word similarity of Sake taste expressions.

1. はじめに

日本酒の銘柄を選ぶ場合, そのお酒の味の説明や日本酒度や使用米, 酵母などの情報を参考にすることがある. 日本酒度については, “辛口” を好む場合, プラスの高いものが選ばれている. 日本酒の味の表現については, 日本酒辞典 [長谷川 2014] にあるように “香り” の表現方法として, 梅, レモン, りんご, 花, 果実, 木, 鉱物, ナッツで例える比喩表現が用いられている. また, さらさらした, シャープな, 強い, 弱い, 深みのある, 切れのある, などさまざまな表現があり, これらが組み合わせることでも表現されており, それらの情報をもとに好みのものを探す場合もある.

日本酒の味表見に関するこれまでの研究として, 大塚ら [大塚 2015] は, 日本酒の味表現についてオノマトペを使った表現方法の研究がある. ここでは個人的な味の感じ方を言語化するプロセスについてオノマトペに注目し, その表現から味の感じ方の違いについて共通性と個別性について分析している. 福島ら [福島 2015] は, 雑誌や書籍から日本酒の味わい表現を抜き出し, 基本味の表現と音象徴語の共起関係の分析を行っている.

これまでに行ってきた日本酒の味表現方法の分析 [福本 2016][福本 2017] では, 蔵元から提供される日本酒度などスペック情報が味表現とどのような関連があるのかについて分析を試みた. また, 日本酒の色々な味覚表現として特に比喩表現 [桝井 2006] に注目し, 比喩対象とスペックとの関連について分析を行ってきた. 今回は味表現の類似性を計算することにより, 同様の味を持つものを探索ことを目的として実験を行った.

2. 日本酒味表現データ

本研究に利用した日本酒の味表現のデータは, これまでと同様, 京都北白川の「にしむら酒店」から毎月配送さている「一酒一会の会だより」メール版に記載されている日本酒の説明文をデータとして利用させて頂いた. 今回使用したデータは, 2011 年 11 月から 2018 年 2 月までのものから, 54ヶ月分 (途中いくつか抜けがある), 1516 銘柄のデータを用いた. このうち日本酒情報のみを用いた. 図 1 にその例を示す.

27BY 大治郎 生もと純米＜山田錦＞生酒（滋賀）

日本酒度：+5、使用米：山田錦 72 %、渡船六号 28 %
（滋賀県呑百笑の会生産）、精米歩合：60 %、酸度：2.4、
使用酵母：協会 7 号、総米 800k 仕込、
アルコール度数：17.5 %、

大治郎君が三年の構想期間を経て初めて生もと造りのお酒を醸しました！そして初めてとは思えない完成度、とにかくピュアでしっかりとした生もとらしい酸味が特徴！木の実、紅茶の葉、甘草などの微香、酸味を感じる酸っぱい香り、和のハーブナンテンの果実感があり、濃度を感じる旨味と甘み、柿皮の苦み、 生もとの素直な味わいときれいで温かい酸味、大治郎に相応しい生もとです !!

図 1: にしむら酒店日本酒データ例

この例では「27BY 大治郎 生もと純米＜山田錦＞生酒」という銘柄名とともに, 日本酒度, 使用米, 精米歩合, 酸度, 使用酵母, アルコール度数といったお酒に関するスペック情報が記載されている. 次に, その酒の味の特徴の説明として, 香りに関する記述, 旨味, 甘み, 酸味などの記述がなされている. これらの記述を “。”, “！” で文の区切りを判定することにより, 日本酒の味の説明文として, 1516 銘柄 (同じ銘柄の酒造年度違いも含まれる) の説明文から 6318 文 (総異なり数 5170 文, 平均文長 44.4 文字) を分析対象として利用した.

3. 日本酒味表現データの係り受け解析

日本酒味表現データの味表現の類似性を判定するため, 日本酒の基本的味表現に関連する部分の類似性を表現毎に計算し，その合計で類似性を判定することにした. これまでの分析 [福本 2016] から, 基本的味表現を表す語としては以下のものを用いた.

データより以上の味表現の単語を修飾する表現を抽出し, それらの比較により判定する. そのため, 味表現の説明文を CaboCha を用いて構文解析し, 基本的味表現を修飾する部分を抽出する. その際, 形態素解析器 MeCab の辞書としては mecab-ipadic-NEologd を用いた. 係り受け解析により, 表 1 示す基本的味表現の語句と係り受け関係にある語句を味表現

連絡先: 福本淳一, 立命館大学情報理工学部, 滋賀県草津市野路東 1-1-1, junichif@is.ritsumei.ac.jp

表 1: 基本的味と味表現

基本的味	味表現
香り	吟醸香, 香味, 香り, 吟香, 風香, 微香, 熟成香, 熟成香, 果実香, 熟柿香, 麹香, 芳香
甘み	甘, 甘味, 甘み, 甘露, 甘口
酸味	酸味, 酸, 乳酸, 酢酸, 酸度, カプロン酸, リンゴ酸, イノシン酸
旨味	うまい, うまみ, うま味, 旨, 旨味, 旨み
苦味	苦, 苦味, 苦い, 苦味, 苦渋
渋味	渋, 渋味, 渋み, 渋味, 渋味
含み	含み, ふくみ, 含有
余韻	余韻
キレ	キレ, 切れ

と関連する語として抽出した. 係り受け解析の味表現に掛かる語句としては, 味表現に掛かっている自立語を対象とし, 味表現が掛かる語句としては, 味表現で助詞「は」「が」を伴っているものが掛かっている自立語を対象とした. 抽出する語は, 品詞が「名詞」「動詞」「形容詞」「副詞」「感動詞」であるもので, 名詞については, 細分類が「サ変接続」「ナイ形容詞語幹」「一般」「形容動詞語幹」「固有名詞」「数」「代名詞」「副詞可能」であるものを抽出した. 以下にその例を示す. 各例において, 下線で示された語が味表現で ( ) 内の各単語が味表現と修飾関係にあるとして抽出された語である.

A 味表現を修飾する表現の例

A-1 すでに淡い茶黄色を帯びて、マスクメロンとおはぎのようなまったりとした香り、
(すでに, 淡い, 茶, 黄色, 帯びる, マスクメロン, おはぎ, まったり, する)

A-2 乾燥したフルーツや切りたての青ブドウの種子のビターな香り、
(乾燥, する, フルーツ, 切り, ブドウ, 種子, ビター)

A-3 リンゴのような果物の香り、
(リンゴ, 果物)

A-4 白桃系のフレッシュな香り
(白桃, フレッシュ)

B 味表現が修飾する表現の例

B-1 香りは控えめですが
(控えめ)

B-2 香りが混じり合います。
(混じる, 合う)

B-3 煎った香りが僅かにあり、
(ある)

以上の例の中の A-1, A-2, B-3 の構文解析結果を図 2 に示す.

以上の手法により各味表現について係り受け関係にある語を抽出した. いずれかの味表現が説明文中に存在したものが 1516 銘柄の説明文から 1123 銘柄について係り受け関係を得ることができた.

```
すでに-D
    淡い-D                  <例文 A-1>
  茶黄色を-D
      帯びて、-------D
   マスクメロンと-D    |
    おはぎのような-D |
        まったりと-D
              した-D
              香り、-----D

  乾燥した---D
  フルーツや-D              <例文 A-2>
    切りたての-D
      青ブドウの-D
          種子の---D
          ビターな-D
              香り、-----D

  煎った-D
    香りが---D              <例文 B-3>
      僅かに-D
        あり、------
```

図 2: 構文解析結果

4. 味表現の類似性の分析

係り受け関係が得られた各銘柄データについて, 味表現の類似性として各味表現において係り受け関係のあるすべての語のうち共通の語がある件数を合計することで各銘柄の味の類似性を計算した.

類似性として共通の語の頻度が 6 以上のものについては, 同一銘柄の年度違いに加えて, 同じ銘柄の仕込み違い, 熟成の有無, 若干の精米方法の違い, 無濾過であるかどうか, 中取りかどうか, などによるものであった. 実際, 説明文を見るとほぼ同じ説明が行われているものであり, 基本的な味の説明文には同じものが使われており, 年度違いなどで多少の補足的な説明がされているものが多かったためである. 図 3 にその例を示す. 例に示す通り, 同じ銘柄 (旦) の 27BY と 25BY が類似しているものとして得られているが, 25BY の説明文の 1 行目と最後の部分を除いたものが 27BY の説明文となっている.

4.1 説明文の類似ポイントの例

異なる銘柄で類似したと判断された説明文の類似ポイントとして, まず「香り」に関するものとして, その語と説明文 (一部) を以下に示す.

a) 白 (名詞, 一般)

- a-1 ビターな白皮を思わす香り
- a-2 グレープフルーツの白皮や水菓子の香り
- a-3 白麹の芳ばしい香り

b) 木の実 (名詞, 一般)

- b-1 黄色い木の実、枇杷を思わすフルーティーで素朴な香り
- b-2 胡桃や木の実の様な心地よい香り
- b-3 香木や木の実、クミンや和のハーブの様な心地よい香り
- b-4 黄色い木の実のまろやかな香り
- b-5 マロンや木の実の香り

[○ 25BY「旦・DAN」純米 無濾過生原酒 タンク 19 号 (山梨県・笹一酒造)]
この「旦」は、昨年蔵元に出向いたおり試飲した中で、際立った味わいを持った仕込 19 号をそのまま瓶詰めして貰ったものです！黄色い木の実、枇杷を思わすフルーティーで素朴な香り、暖かなカステラを思わす甘い含み香、味わいは白小豆、枇杷果汁、白餡の甘み、カスタードクリームの後に柔らかな酸味と白麹の苦味が心地よく調和し、芳ばしくて円やかな旨口酒。和食はもちろんの事、特にカキフライなどに◎一年熟成。

[○ 27BY 旦 (だん) 純米 無濾過生原酒 (山梨県・笹一酒造)]
黄色い木の実、枇杷を思わすフルーティーで素朴な香り、暖かなカステラを思わす甘い含み香、味わいは白小豆、枇杷果汁、白餡の甘み、カスタードクリームの後に柔らかな酸味と白麹の苦味が心地よく調和し、芳ばしくて円やかな旨口酒。和食はもちろんの事、特にカキフライなどに◎

図 3: 同一銘柄の年度違いの説明文の例

c) フルーツ (名詞, 一般)

- c-1 フルーツの赤皮や浅漬けのような酸味を感じる香り
- c-2 穏やかなフルーツの白皮の心地よい香り

d) 枇杷 (名詞, 一般)

- d-1 枇杷を思わすフルーティーで素朴な香り
- d-2 フレッシュで枇杷や黄桃などフルーツ、花弁を感じる香り

e) 爽やか (名詞, 形容動詞語幹)

- e-1 フレッシュでラフランス系の爽やかな吟香
- e-2 切りたての梨のような生酒の爽やかな香り

f) ビター (名詞, 形容動詞語幹)

- f-1 ビターな白皮を思わす香り
- f-2 フレッシュで少し黒麹のようなビターな香り

g) 麹 (名詞, 一般) | シュガー (名詞, 一般) | シロップ (名詞, 一般)

- g-1 白い麹、ほうずき、木の実、シュガーシロップの香り
- g-2 ヨーグルトやシュガーシロップ、白麹の芳ばしい香り

今回の手法である係り受け関係にある単語のマッチングのみでは, 一致する単語が少なかった. 例えば, b) の例では「木の実」, c) では「フルーツ」, d) では「枇杷」の 1 単語のみの一致であるが, 実際には他の語も存在し, それらの類似性も考慮する必要がある. しかしながら,「木の実」「フルーツ」「枇杷」など香りに特徴のあるものや, 「爽やか」「ビター」などの程度を表す修飾語の一致による類似性の判定に有効であると考えられる. 形態素解析に関連するものとして, a) の例では「白」という単語の一致であるが, 例を見ても分かる通り, 「白皮」「白麹」が分割され, 一部の一致により類似していると判断されている. このような名詞連続の問題について他の例でもいくつか存在し, この点についても類似性の判断で考慮する必要がある.

次に「酸味」に関する例を示す.

h) 山 (名詞, 一般), 廃 (名詞, サ変接続)

- h-1 山廃でありながら酸味が出しゃばらず
- h-2 山廃でありながら締まった酸味が

i) 綺麗 (名詞, 形容動詞語幹)

- i-1 綺麗、上品かつボリュームのある酸味

j) 滑らか (名詞, 形容動詞語幹)

- j-1 山廃独自の滑らかな酸味

「香り」と同様に, 形態素解析によるものとして「山廃」が 2 単語に分割され, それぞれが「酸味」と関連するものとして計算されている. また,「綺麗」「滑らか」などの程度を表す形容動詞が「酸味」を修飾するものとして係り受け関係にあるものが特徴として得られた.

次に「旨味」に関するものを示す.

k) 吟 (名詞, 固有名詞), 吹雪 (名詞, 固有名詞)

- k-1 吟吹雪の良さを味わって
- k-2 吟吹雪米を綺麗で豊満な旨口に

l) 味わい (名詞, 一般)

- l-1 穏やかな味わいの旨口酒
- l-2 きれいな味わいで柔らかな旨味

m) 小豆 (名詞, 一般)

- m-1 丸く濃醇な小豆のような旨味
- m-2 ナンテンや漉し小豆のような素朴な旨味

「旨み」の表現についても同様に少ない単語の一致で類似度が計算されている. k) の例では「吟吹雪」が分割されてそれぞれカウントされている. また, 「味わい」という旨みに関連する表現や「小豆」が日本酒の旨みを表現する対象として用いられており, 旨みに関連する語の意味的な類似性を捉えることで類似度を判定の精度を上げることができると考えられる.

最後に「渋味」に関するものを示す.

n) 葡萄 (名詞, 一般)

- n-1 葡萄の種の様な渋み
- n-2 マスカット葡萄の皮の様なビターな苦み

o) 皮 (名詞, 一般)

- o-1 白葡萄の皮のような渋味

「渋味」については数は少なく, 主に「葡萄」「種」「皮」の表現が修飾表現として用いられ, 類似性が判定されている. 「葡萄の種」や「葡萄の皮」などが用いられている表現であるが, これらが単語分割され, 各単語が類似性の判定に用いられている. 係り受け関係にある語句の全体としての類似度計算の手法を検討する必要がある.

4.2 類似性の高い日本酒ペアの例

今回の手法である各味表現と係り受け関係にある単語の一致により, 全体として類似した味表現として得られた異なる銘柄のペア 3 種類とそれらのお酒の説明文を以下に示す. 今回の類似度計算では低い値であったが, 類似度上位のペアとして得られたものである. 類似ポイントとなった単語を下線で示している. 複雑な味表現中の一部の語句のみの一致により類似した味であると判断されていることが分かる.

例 1) 大治郎　純米吟醸 | 辰泉≪ 夢の香≫ 特別純米

- 香りは控えめですが複雑で、アロエの様な青い揮発性の香り、白 葡萄の果皮のビターな香りの中に僅かに白麹や求肥の様な柔らかな香りが混じり合います。クリーミィーさがありイチジクの白皮の上立ち香、梨やグァバの果汁に白小豆の様な旨味、酸味には厚みがあり、ザクロフルーツの様な爽やかな苦みが味わいをひきたてています。余韻も柔らかで軽やかに引いていきます。この先豊かさを増す熟成が楽しみな濃潤旨口です。[29BY 大治郎　純米吟醸 うすにごり生酒（滋賀）]

- 無濾過中取りの原酒を春先に瓶火入れし、低温 (3 ℃) 貯蔵で熟成させた限定酒。地元会津産の酒造好適米「夢の香」を 100%使用し (うつくしま夢酵母) で醸しました。柔らかな白餡、シュガーシロップ、白 葡萄の種を思わすビターな香り、綺麗で豊潤そして、よく溶け込んだ穀物系の滑らかな旨みと口中でフルーツの上品な広がり、余韻に心地よいミネラル感があり福島県の自然を思わせる透明感のある特別限定酒！[22BY 辰泉 (たついずみ) ≪ 夢の香≫ 特別純米 中取・瓶囲い（福島県）]

例 2) 喜楽長 純米吟醸 | 竹生嶋 ヨキトギ 純米吟醸

- 滋賀県産吟 吹雪100 %で醸した喜多酒造初めての無濾過生原酒 (直汲み）です。固めの白桃や白い穀物を思わすシンプルな香り、含むととてもスムースな旨味が味わえてストレートに美味しさを感じます。焼きたての食パンの滑らかな白生地のような素朴な旨味があり、木の実や白枇杷の風味を感じる上品な吟 吹雪らしい味わいで、とても心地よく柔らかなスタイルの芳醇旨口酒です。是非、吟吹雪の良さを味わって下さい！[NEW27 ＢＹ（3 番）喜楽長　純米吟醸　無濾過生原酒 直汲み]

- 新酒時から味乗りの良い「吟 吹雪」の純米吟醸を直汲み。うっすらと雪の様に白い滓が絡んでいます。口に含むと発酵による微炭酸がフレッシュで爽やかに、心地よく広がり、白桃を思わす微香、枇杷や上新粉を使った白い蒸し菓子のようなと旨味、余韻は白葡萄の皮のような渋味が乳酸と一緒に長く残ります。甘重な味わいになりがちな吟米を綺麗で豊満な旨口に仕上げた吉田酒造ならではの旨酒！[26BY 竹生嶋 ヨキトギ　純米吟醸　直汲み生原酒（おりがらみ）]

例 3) 菊鷹˜ 菊花˜ 純米 | 喜楽長 純米吟醸 < 渡船 >

- 山本克明杜氏の菊鷹就任 3 期目のお酒がのりにのっています。今年は仕込も増えて、冷蔵コンテナも導入され、今回は一回火入れが入荷しました。もちろん瓶燗無濾過原酒です。若水は群馬県の蔵元が多く使用していますが、本来は愛知県発祥のお米です。五百万石から交配され 1983 年に推奨となりました。心白が大きいのが特徴で (発現率高く割れやすい)、軟質で水を吸いすぎることから近年愛知では作付が減少しておりますが実に個性的な味わいのお酒となります。固いメロンの皮、柿の実、シトロンの香りに綿菓子のような甘い香り、含みは少し揮発油的でミントなどのハーブの口中香、若水の味わいは例えば最初は少し甘みを感じ枇杷饅頭の皮の様なまったりとした旨味にきっちりと苦みと渋みがまざりあった後からゆっくりと辛さを感じる味わいです。煮物、焚物、練り物などと合わせてみたくなる濃醇旨口酒。[26BY 菊鷹 (きくたか)˜ 菊花 (きっか)˜ 純米 火入れ酒（若水）(愛知県)]

- 環境こだわり米、滋賀県産 < 渡船 6 号 > を 55%まで削り、9 号酵母で丁寧に醸した純米吟醸。割った枇杷の実や柿の実の様なフルーツの香りの中にワッフルやホワイトチョコの様な香りが僅かに感じられ、味わいはマンダリンやネーブルの皮の様な甘い柑橘系、白豆や蒸した饅頭の旨みが心地よい苦みの中にふくらみます。余韻は以外にドライな豊満旨口。低温熟成でより滑らかで豊満な味わいに！[< 熟成 >27BY（10 番）喜楽長　純米吟醸 < 渡船 > 無濾過生原酒直汲]

5. おわりに

本稿では, 日本酒の味の類似性の計算のため, 日本酒の説明文の構文解析結果から, 基本的味表現を示す用語と係り受け関係にある語のリストの類似性を判定することで類似した味表現を持つ銘柄の日本酒の獲得を目指した. 味表現として類似したものとして得られたものが各味表現で得られたものでも 1,2 単語のみで類似性が判定されており, 係り受け関係のみではなく, 単語の類似性なども扱いながら拡張するべできあると考えられる. しかしながら, 単純に類似性を学習するなどの方法では形や色などの類似性についても考量してしまう可能性があるためその点について考慮する必要がある. また, 現在までに獲得したデータについてもさらに拡張するなどしてデータの充実を図っていく予定である.

謝辞

本研究を進めるにあたり, 日本酒データの利用を快くご快諾いただいた京都北白川にしむら酒店様に感謝いたします.

参考文献

[福本 2016] 福本 淳一: “日本酒の味表現の分析,” 第 30 回人工知能学会全国大会, Vol.30, 3M4-OS-20b-3, pp.1–4, 2016.

[福本 2017] 福本 淳一: “日本酒味表現の比喩構造の分析,” 第 31 回人工知能学会全国大会, Vol.31, 2P2-OS-18a-1, pp.1–4, 2017.

[大塚 2015] 大塚 裕子, 諏訪 正樹, 山口 健吾: “創作オノマトペによる日本酒を味わう表現の研究,” 第 29 回人工知能学会全国大会, Vol.29, pp.1–4, 2015.

[福島 2015] 福島 宙輝, 永野 千音: “味覚における音象徴語の機能分析究,” 第 29 回人工知能学会全国大会, Vol.29, pp.1–4, 2015.

[田崎 2016] 田崎 真也: No1 ソムリエが語る新しい日本酒の味わい方, SB クリエイティブ, 2016.

[長谷川 2014] 長谷川 浩一 監修: 日本酒辞典, 学研パブリッシング, 2014.

[桝井 2006] 桝井 文人, 福本 淳一, 荒木 健治: “比喩解釈を目的とする World Wide Web を利用した属性値の適合性判定手法とそのフィードバック,” 電子情報通信学会論文誌, Vol.J89-D, No.4, pp.860–870, 2006.

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

図形と形容詞による嗜好品の重層表現の分析手法
Multi-layered Taste Representation with Shapes and Adjectives

宮本和典[*1]
Kazunori Miyamoto

福島宙輝[*1]
Hiroki Fukushima

[*1] 九州女子大学
Kyushu Women's University

In this paper, the authors propose a method for asking the multi-layered representation of the domain of taste. Amongst a lot of aspects or domains of the representations for taste, we pick up the domain of shape and the domain of adjectives (i.e., language). The experiment consists of two parts; the shape choosing part and the adjective choosing part. In the shape choosing part, 25 choices which randomly selected from 100 shapes set were given in a single task. Likewise, 25 adjectives from 100 adjectives set were given in every task. Multiple-choice or no-choice is allowed in both parts. The experiment is undergoing: thus the author will give the results of this method in the annual conference.

1. はじめに

1.1 味覚・嗅覚の言語表現に関する国外の研究動向

味覚あるいは嗅覚の言語化に関する研究は，書籍としては "*Olfaction, taste, and cognition*" [Rouby 2002]が興味深い．フランス語における香りの表現を分析したデイヴィッドの章[David 2002]では，フランス語では香りが物理的な実体として表現されることは少なく，主体によって経験される，対象の属性として表現されていることを巧緻に論じている．

西欧諸語における傾向と同様，日本語においても味そのものを表す表現は，基本五味に「辛い」や「渋い」などの刺激味，あるいは「コク」などの複合語を考慮に入れてもその数はせいぜい 20 語に満たず，視覚的属性の表現である色の表現とくらべてみると，味を直接に指摘する表現はかなり限定的である．

一方，味わいの表現が自然言語においては限定的であるという通説に関して，マジッドらの研究グループは，文化人類学的な研究から，通説の反例とみなすことのできる事例の報告も行っている[Majid 2014]．たとえば，インドネシアの狩猟採集民 Jahai を対象とした実験を行い，色と同レベルで香りをカテゴライズできることを示している．この事例は，人間の香りの認知能力は決して限定的なものではないことを示すものとして注目できる．

熟達，あるいはプロフェッショナルの言語化に関する研究としては，コーヒーとワインのプロフェッショナル及び一般被験者を対象とした言語化実験から，プロフェッショナルの言語化能力は特定のドメイン（ソムリエであればワインのみ）においてのみ有効であることを主張している[Croijmans 2016]．また，プロフェッショナルがソース・ベースドの（比喩的な）表現を特徴とする一方で，一般被験者は形容詞を用いて評価表現（好き，おいしいなど）としての言語化が特徴的であることなど，興味深い結果をいくつか導いている．

1.2 味と形の感覚間対応研究の動向

近年の味と形の感覚間対応(crossmodal correspondences)の研究は，デロイらの研究[Deroy 2011]をその始点とみることができる．デロイらは，フランス人被験者を対象として，3 種類のビール飲料をブラインドで提示し，丸みや尖りを特徴とする 2 次元図形と 3 次元図形，計 34 種の中から選択させ，同時に単語で味の特徴を報告させるという実験を行った．その結果として，苦味が尖り図形(angular shape)と親和性が高く，甘味が丸み図形(round shape)と親和性が高いことを示した．

このように，デロイらを嚆矢として活発となった形と味の感覚間対応に関する実験心理学的研究においては，いわゆるブーバ・キキ効果の実験に用いられるような，角張った図形と丸みを基調とする図形から味の印象に沿うものを選択させるという強制選択式の実験が主に行われている．

味と形の感覚間対応の研究は，その普遍性の議論として，文化人類学的な広がりをもみせている．ブレムナーらの研究では，ナミビアのヒンバ族での調査によって，苦味や炭酸のテクスチャが丸い形として表象されることが示されるなど，これまでの西洋言語話者の一般的傾向とは対立する表象傾向が報告されている[Bremner 2013]．

以上のような味と形の感覚間対応について，現段階のレビュー論文としては，食品パッケージデザインへの応用を目指したヴェラスコらのレビュー論文[Velasco 2016]に詳しい．レビューにおいては，多くの実験で甘味と丸い形が，苦味と酸味に尖った形が対応するということが示唆されている．

福島は，従来のブーバ・キキ・テスト形式の強制選択式課題による味と形の象徴性の実験に対して，以下の 3 点の欠点を示した[Fukushima 2018]．すなわち

1. 形のどの部分と味のどの要素が対応しているのかが不明であること
2. 対応づけの根拠，動機が不明であること
3. 実際の飲料ではなく，例えば甘味であれば糖の水溶液を用いる実験が多い

というものである．その上で福島は，選択式ではなく被験者に味わいの印象の描画スケッチをさせる生成式の課題による実験手法を提案している．

1.3 実験方略のパターン

福島の描画生成式の実験手法は，スケッチによる味の記述ののち，被験者にその味を言語によって記述させるフェイズを導入している．スケッチと言語による複相的な記述によって，味と形の関係性を内省的報告から明らかにすることが特徴である．

連絡先：宮本和典，九州女子大学，北九州市八幡西区自由ヶ丘 1−1，miyamoto ＠kwuc.ac.jp

しかし一方で，味わいを描画スケッチにした上で言語化もさせるという実験手法は難易度が高く，より多くの被験者に対して実行することが困難という短所をもつ．

したがって味と形の関係性を問う実験手法には，ブレムナーらの手法のように尖り図形と丸み図形の 2 者から択一させる方略，デロイらの手法のように，より多くの記号から選択させる方略，そして描画生成式の方略というように，幾つかのグラデーショナルな実験パターンが考えられる．

2. 実験手法

2.1 実験の目的

本実験の目的は，味わいの表象を図形と形容詞という複数のアスペクトから問い，その後に両相の表象構造に関連性があるかを分析することである．

2.2 提案手法

本実験は，1 度の試行は以下の 3 つのフェイズからなる．

1. 嗜好品飲料を飲む
2. タブレットに表示された図形群からイメージにあうものを選択する
3. タブレットに表示された形容詞群からイメージにあうものを選択する

本実験ではこの 3 フェイズを 1 セットとし，実験試料の種類の回数だけ繰り返し実行する．各試料間には 2 分間のインターバルを設け，水で口をすすぐことによって味嗅覚の馴化を防ぐ．

実験に用いる図形群および形容詞群の詳細は以下の通りである．

(1) 図形群の詳細

味と形の感覚間対応の実験に用いられる実験刺激としての図形は，ブーバ・キキ・テストにおける丸みと尖りのように，対立する特徴を持つ図形のペアを用いることが一般的である．丸みと尖りの他には，シンメトリ／アシンメトリ，2D／3D のような対立軸を設定した研究が多く見られる．

実験刺激の数については，ブーバ・キキの二者択一式が一般的である．先述のデロイら[Deroy 2011]のように 32 の図形群（16 種の図形をそれぞれ 2D と 3D の 2 パターンで提示）を一覧させて刺激として用いているものは，比較的多数の図形を用いている例である．

本実験においては，自由描画生成式課題へのグラデーションを意図して，より多くの図形群から選択する自由度の高い実験をデザインする．実験で用いるのは 2D の図形 100 種であり，このうち 1 度の刺激（1 種の飲料に対する刺激）としてはランダムに 25 種をタブレットに表示して提示する．被験者はこの 25 種の図形から，飲料のイメージに合致するものを選択する．この際，選択をしないことや複数種の図形を選択することを妨げない旨を事前に教示する．

(2) 形容詞群の詳細

本実験では，[Croijmans 2016]の研究を踏まえ，形容詞群による飲料の主観的な印象評定を実施する．

形容詞群は『味覚・嗅覚表現データベース 1.0』[福島 2018]における高頻度形容詞を使用し，味覚・嗅覚の表現に頻出する形容詞 100 語からランダムに 25 語をタブレット上に提示する．なおこの際，25 の形容詞のうち毎回固定の選択肢として，形容詞の形式で「甘い」「苦い」のような基本味表現を提示する．

この基本味表現の評定は，味と形の感覚間対応の分析を可能にするためのものである．味と形の感覚間対応の実験においては，味を定義するために，糖やグルタミン酸などの味物質の水溶液を用いることで味を定義するか，あるいは実際の飲料を用いる場合には味覚センサの計測値によって味を定義するかという手法が考えられる．これに対し本手法では，被験者が「甘い」を選択することを「甘味」として定義する．こうした主観的な報告を基軸とした手法のために，基本味表現を形容詞形式で毎回提示するものとする．

3. 結び

本稿では味覚・嗅覚の言語表現に関する研究および形と味の感覚間対応関係の研究動向を国外の研究を中心に概観し，図形と形容詞の多肢選択課題による味覚表象の重層的構造を問う実験手法の提案を行った．本実験は九州女子大学研究倫理委員会の承認手続きの後，予備実験までを完了させ，全国大会の口頭発表において実験の結果および分析の手法を提示するものとする．

参考文献

[Bremner 2013] Bremner, A. J., Caparos, S., Davidoff, J., de Fockert, J., Linnell, K. J., & Spence, C: “Bouba” and “Kiki” in Namibia? A remote culture make similar shape–sound matches, but different shape–taste matches to Westerners, *Cognition*, *126*(2), 165–172, 2013

[Croijmans 2016] Croijmans, I., & Majid, A: Not all flavor expertise is equal: The language of wine and coffee experts. *PloS One*, *11*(6), 2016

[David 2002] David, S: Linguistic expressions for odors in French. *Olfaction, Taste and Cognition*, 82–99, 2002

[Deroy 2011] Deroy, O., & Valentin, D: Tasting liquid shapes: investigating the sensory basis of cross-modal correspondences. *Chemosensory Perception*, 2011

[Fukushima 2018] Fukushima, H: A Phenomenological Model for Generating the Tasting Description of Japanese Sake. In T. Ogata (Ed.), *Content Generation Through Narrative Communication and Simulation*. IGI Grobal, 2018

[Majid 2014] Majid, A., & Burenhult, N: Odors are expressible in language, as long as you speak the right language. *Cognition*, *130*(2), 266–270, 2014

[Rouby 2002] Rouby, C., Schaal, B., Dubois, D., Gervais, R., & Holley, A: *Olfaction, taste, and cognition*. Cambridge University Press, 2002

[Velasco 2016] Velasco, C., Woods, A. T., Petit, O., Cheok, A. D., & Spence, C: Crossmodal correspondences between taste and shape , and their implications for product packaging : A review. *Food Quality and Preference*, *52*(4), 17–26, 2016

4:50 PM - 5:30 PM (Thu. Jun 7, 2018 3:50 PM - 5:30 PM Room B)

[3B2-OS-22b-04] Invited Lecture

○Yuki Watanabe[1], Takashi Okamoto[1] （1. SENSY Inc.）

Keywords: Sense

本セッションでは， SENSY株式会社の代表取締役渡辺佑樹氏と同社取締役岡本卓氏の2名による招待講演を実施します．

©The Japanese Society for Artificial Intelligence

Oral presentation | Organized Session | [Organized Session] OS-14

[3C1-OS-14a] [Organized Session] OS-14

Thu. Jun 7, 2018 1:50 PM - 3:10 PM Room C (4F Orchid)

[3C1-OS-14a-01] Analysis of the effect of agent's embodiment and gaze amount on personality perception

TAKUTO ISHIOH[1], ○TOMOKO KODA[1] （1. Osaka Institute of Technology）

1:50 PM - 2:10 PM

[3C1-OS-14a-02] Evaluation of active listening in psychotherapy

○Ryoko Hanada[1], Ryutaro Nakajima[2], Masashi Inoue[3], Nobuhiro Furuyama[4], Toshio Irino[5] （1. Tokyo Woman's Christian University, 2. Graduate school of the University of Tokyo, 3. Tohoku Institute of Technology, 4. Waseda University, 5. Wakayama University）

2:10 PM - 2:30 PM

[3C1-OS-14a-03] Predicting Important Utterance based on Fusing Verbal and Nonverbal Information

○Fumio Nihei[1], Yukiko Nakano[2], Yutaka Takase[2] （1. Graduate school of Seikei University, 2. Seikei University）

2:30 PM - 2:50 PM

[3C1-OS-14a-04] Monitoring walking condition by wearable devices and sensor attached trekking stock

○Kenichi Sakaguchi[1], Kanako Nakayama[1], Yu Kudo[1] （1. Technosolution Co., Ltd.）

2:50 PM - 3:10 PM

©The Japanese Society for Artificial Intelligence

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

エージェントの実体性と凝視量が性格特性認知に与える影響分析

Analysis of the effect of agent's embodiment and gaze amount on personality perception

石王 拓斗[*1] 神田 智子[*1*2]
Takuto Ishio Tomoko Koda

[*1]大阪工業大学大学院情報科学研究科 [*2]大阪工業大学情報科学部情報メディア学科
Graduate School of Information Science and Technology, Osaka Institute of Technology[*1]
Faculty of Information Science and Technology, Osaka Institute of Technology[*2]

In this study, we implemented a gaze model, based on human gaze behavior analysis, on an eyeball manipulable robot and CG agent. Then we analyzed the effects of agent embodiment and change in gaze amount on agents' personality perception. The results suggested that it is possible to express extrovertedness and confidence of the agent by changing the gaze amount from the agent regardless of agent's embodiment. In addition, the levels of perceived extrovertedness as increase in gaze amount differ depending on the embodiment of the agents. The CG agent's perceived extrovertedness increased in proportion to increase in its gaze amount, while the robot's extrovertedness increased logarithmically to increase in its gaze amount.

1. はじめに

視線行動は，人間同士のコミュニケーションにおいて，会話の開始合図や，発話権の移譲・要求に加え，意思表示や感情表現等の重要な役割を持つことが知られている．そのため，視線行動は性格特性認知においても重要な役割を担っている．視線行動の中でも，相手を見つめる時間の割合（凝視量）が，多くなるほどに力量に関する印象が高くなり，凝視量が中程度のときに最も相手から好意的な印象を持たれることを報告されている[1]．また，CG エージェントにおいても凝視量を操作することで，人間と同様に，視線によって性格特性を表出できることが示されている[2].

視線行動による性格特性の表出ができることは，ロボットにおいても研究されており，人間の視線行動の分析に基づいた注視のタイミングによって性格特性である外向性を表出し，ユーザの性格とロボットの表出する性格が一致することでモチベーション向上等の効果を得られることが示されている[3].

しかし，これまでのロボットに視線行動を実装した研究は，CG エージェントの視線研究とは異なり，頭部の動作によって視線行動を模倣する形で行われてきた．CG エージェントと同様に，人間の視線行動の分析に基づいた視線を実装した研究は，我々の知る限りこれまでに行われていない．また，エージェントは実体性によって異なる印象がもたれることが報告され，エージェントの実体性が高いほど，エージェントが社会的で，信頼でき，有能であると評価されることを示されている[4]．そのため，ロボットに人間の視線行動に基づいた視線モデルを実装し，凝視量を操作した場合，人間や CG エージェントと同様に性格特性を表出可能か検証する必要がある．

そこで本研究では，CG エージェントとロボットの視線行動から受ける印象を統制し，同じ人間の視線行動の分析に基づく視線状態遷移モデルを実装したうえで，凝視量を操作した場合，「凝視量操作によって，ロボットにおいても CG エージェントと同様に，外向性や自信などの性格特性を表出できる．」と仮説を立て，検証を行う．

連絡先：石王拓斗，神田智子，大阪工業大学大学院情報科学研究科，
〒573-0196 大阪府枚方市北山 1-79-1, Tel: 072-866-5182,
email: m1m16a03@st.oit.ac.jp , tomoko.koda@oit.ac.jp

2. エージェントデザイン

本研究では CG エージェントを Unity と C#で，ロボットを RaspberryPi と Java を用いて制御した．図 1 に示すロボット(左)と CG エージェント（右）に対して，「アイコンタクト」「あいまい注視」「視線回避」の 3 種類の視線行動を実装した画像を，図 2,3 に示す．ロボットに実装する視線行動を，CG エージェントと同じ角度で実装した場合，被注視感が異なった．実体性による印象の違いを明確にするためには，視線行動により表出される印象の違いを統一する必要がある．そこで，ロボットには CG エージェントの各視線行動から受ける印象と，ロボットの各視線行動から受ける印象が同程度となるように，日本人大学生 8 名による妥当性チェックを行い，「CG エージェントの視線行動との類似性」と「振る舞いの自然さ」の評価が最も高いものを実装した．



図 1. 実験で用いたエージェント
（左：ロボット，右：CG エージェント）



図 2.視線行動を行うエージェント
（上：ロボット，下：CG エージェント）
（左：アイコンタクト，右：あいまい注視）



図 3. 視線回避を行うエージェント
（上：ロボット，下：CG エージェント）

3. 評価実験

評価実験では，凝視量の違いにより表出される性格特性が異なることを検証するため，「非凝視」，「低凝視」，「高凝視」，「全凝視」の凝視量の異なる 4 条件を設定した．そして，性格特性を測る指標である日本語版 Ten Item Personality Inventory (TIPI-J)により，表出される性格特性を測り，対話相手としてのエージェントとのインタラクションを印象評価アンケートで測った．

日本人の対話行動の分析に基づいて提案された視線モデル[5]を基に，凝視量を操作するために各視線行動の時間を固定して使用した．高凝視条件時の視線モデルを図 4 に示す．アイコンタクト（以降 EC）を行う時間の割合のみを凝視量とし，凝視量が 50%程度となるように実装した．低凝視条件では，これを基に EC の時間を 3.0 秒から 1.5 秒に，あいまい注視の時間を 2.0 秒から 3.0 秒とし，凝視量が 25%程度となるように実装した．全凝視条件は凝視量が 100%，非凝視条件は視線回避のみを行い，凝視量が 0%となるよう実装した．

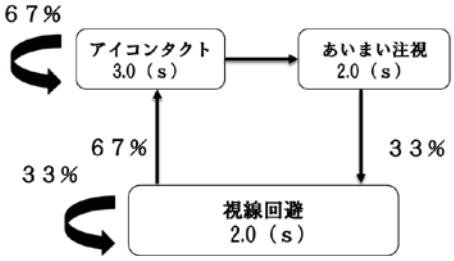


図 4. 高凝視条件時の視線モデル

実験はエージェントがある雑学（例：お寿司の正しい食べ方）について質問をし，実験参加者がそれに回答する形式の対話を行った．実験参加者は 21-24 歳の日本人大学生 39 名（男性 30 名，女性 9 名）である．実験参加者には，音声対話エージェントの受答えに対する評価の実体性間比較のための実験であると教示し，視線の研究であるとは明示せずに実験を行った．実験では，順序効果を考慮してエージェントの提示順はランダムとし，視線条件とエージェントの組み合わせもランダムとして，計 8 回の対話を行った．実験参加者は対話を行う都度，TIPI を含む印象評価アンケートに回答した．

4. 結果と考察

実験の結果，「凝視量を操作することによって，ロボットにおいても CG エージェントと同様に，外向性や自信などの性格特性を表出できる．」とした仮説は支持された．図 5 に示した TIPI の外向性項目において，ロボット及び CG エージェントともに凝視量が多くなるほど，外向性が高く表出されることが示された．しかし，凝視量の増加に伴う外向性の表出傾向は異なった．これは，図 6 に示した，印象評価アンケートにおいて測った，「見かけの自信」に関する項目でも同様の結果が見られた．CG エージェントの場合は，これまでの人間同士の研究同様に，凝視量の増加に比例して外向性の評価が高くなった．しかし，ロボットは，凝視量の増加に伴い，表出される外向性が対数的な増加傾向となることが示唆された．すなわち，ロボットと CG エージェントの低凝視条件において有意差が見られることから，ロボットは凝視量が少なくても，EC を行うことによって外向性等の性格特性を表出可能だと考える．この理由のひとつとして，CG エージェントよりもロボットの方がメンタルモデルを構築しやすいことが示唆されていることから[6]，ロボットの方が性格特性も認知されやすかったと考えられる．また，図 7 に示したように，視線行動による印象が同程度となるように実装していても，低凝視条件時にエージェントから感じる威圧感は，ロボットの方が有意に高かった．このことから，実体性があることでロボットは CG エージェントよりも視線を意識されやすかったと考えられる．我々は，これらの相乗効果によりロボットは EC を行うことで，CG エージェントよりも低い凝視量であっても外向性があると認知された可能性があると解釈している．

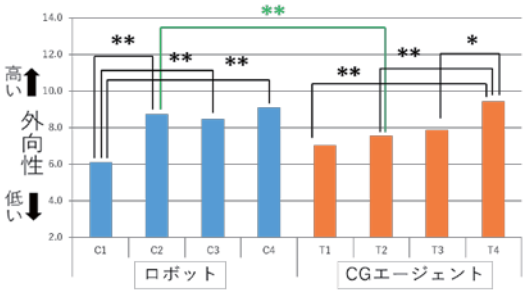


図 5. TIPI の外向性項目における多重比較の結果
（左：ロボット，右：CG エージェント）

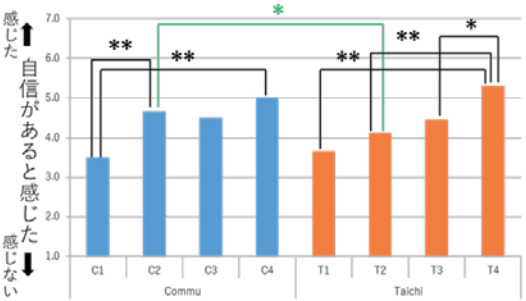


図 6.「見かけの自信」に関する多重比較の結果
（左：ロボット，右：CG エージェント）

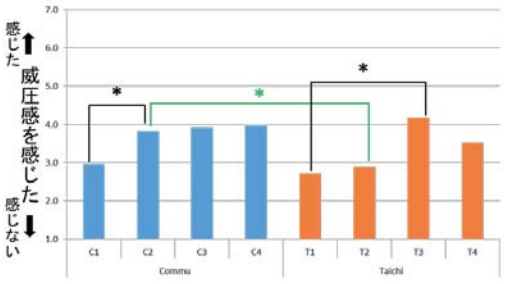


図 7.「エージェントからの威圧感」に関する多重比較の結果
（左：ロボット，右：CG エージェント）

次に，対話相手としてのエージェントの印象評価において，エージェントの見かけの対話スキルに注目し，話し手としての方かを「話し慣れている」，聞き手としての評価を「傾聴感がある」という質問によって評価した．図 8 に示す「話し慣れている」の評価は，凝視量が多い程，高くなった．この理由として，藤本らに

よれば，自分の考えをうまく表現する能力は，外向性と正の相関が強いことが示されている[7]. 本研究においては，凝視量が多い程に外向性の評価が高くなることが確認されており，それに伴って，「話し慣れている」の評価が上昇したのだと考える. これにより，対話相手の傾聴意欲を向上させる効果が期待できると考える.

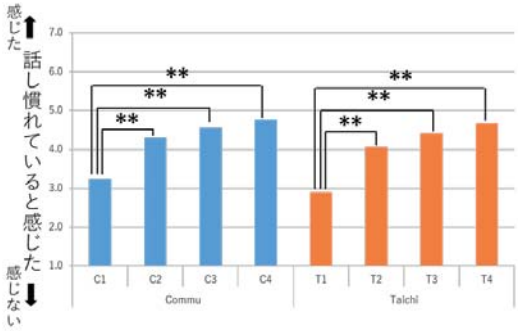


図 8.「話し慣れている」に関する多重比較の結果
（左：ロボット，右：CG エージェント）

しかし，図 9 に示す，「傾聴感がある」に関する評価においては，高凝視条件の評価が最も高かった. この理由として，深山らにより凝視量が中程度のときに「付き合いやすい」，「あたたかい」，「友人になりたい」，「親密な」の語を含む友好的因子の評価が高いことが示されている[2]. このことから，人間の視線行動の分析に基づいた自然な視線行動で，50%程度の凝視量であった高凝視条件は友好的因子が高くなり，傾聴感が高まる一つの要因となったと考える. 傾聴感が高いことによって，対話相手の発話意欲を向上させる効果が期待できると考えている. また，ロボットの傾聴感は，凝視量の違いによる差は小さかったが，CG エージェントと同様の傾向が見られた.

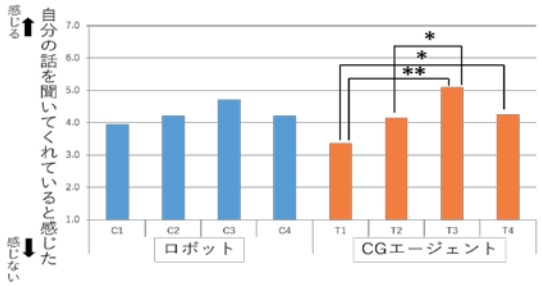


図 9.「傾聴感がある」に関する多重比較の結果
（左：ロボット，右：CG エージェント）

本研究の結果から，人間の視線行動の分析に基づいた自然な視線行動を実装したエージェントは，凝視量を高凝視条件同様に 50%程度に設定することで，性格特性が付与でき，ユーザの傾聴意欲及び発話意欲の向上などの効果を期待できるのではないかと考える.

5. 結論

本研究では，ロボット及び CG エージェントに人間の視線行動の分析に基づいた視線モデルを実装し，凝視量を操作した場合，ロボットと CG エージェントとも人間同様に，凝視量の増加に伴い，外向性が上昇したが，上昇傾向が実体性によって異なることが示唆された. また，エージェントの凝視量を 50%程度にすることで，対話相手の発話意欲向上が期待でき，インタラクションの向上ができる可能性を示した. 本研究では，ロボットのインタラクションの向上のために，人間同様の視線行動の実装が有効であることを示し，今後のロボットの行動設計に寄与できたと考える.

謝辞

本研究の一部は，科研費「基盤(C)JP26330236，基盤(C)JP17K00287」の交付を受けて実施した.

参考文献

[1] Cook, M. and Smith, M.C.: The Role of Gaze in Impression Formation, Br. J. Clin. Psych., Vol.14, pp.19–25 (1975).

[2] 深山篤，大野健彦，武川直樹，澤木美奈子，萩田紀博. 擬人化エージェントの印象操作のための視線制御方法. 情報処理学会論文誌，43(12), 3596-3606，(2002).

[3] Andrist, S., Mutlu, B., & Tapus, A. Look like me: matching robot personality via gaze to increase motivation. In Proceedings of the 33rd annual ACM conference on human factors in computing systems , pp. 3603-3612. ACM, (2015)

[4] Powers, A., Kiesler, S., Fussell, S., & Torrey, C. Comparing a computer agent with a humanoid robot. In Human-Robot Interaction (HRI), 2007 2nd ACM/IEEE International Conference on (pp. 145-152), IEEE. (2007).

[5] 石井亮，宮島俊光,藤田欣也. “アバタ音声チャットシステムにおける会話促進のための注視制御.” ヒューマンインタフェース学会論文誌 10(1), pp.87-94, (2008).

[6] Kidd, C., Breazeal, C.: Effect of a robot on user perceptions. In Proceedings of the 2004 IEEE/RSJ International Conference on Intelligent Robots and Systems, pp. 3559 – 3564 (2004)

[7] 藤本学，& 大坊郁夫.“コミュニケーション・スキルに関する諸因子の階層構造への統合の試み. ”パーソナリティ研究，15(3), 347-361，(2007).

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

臨床心理面接における傾聴度変化の評価ー臨床心理士と初学者の比較ー

Evaluation of active listening in psychotherapy: Comparison of clinical psychologists and students

花田里欧子[*1] 中島隆太郎[*2] 井上 雅史[*3] 古山 宣洋[*4] 入野 俊夫[*5]
Ryoko Hanada[*1], Ryutaro Nakajima[*2], Masashi Inoue[*3], Nobuhiro Furuyama[*4], Toshio Irino[*5]

[*1] 東京女子大学 [*2] 東京大学大学院 [*3] 東北工業大学 [*4] 早稲田大学 [*5] 和歌山大学
[*1]Tokyo Woman's Christian University, [*2]Graduate school of the University of Tokyo, [*3]Tohoku Institute of Technology, [*4]Waseda University, [*5]Wakayama University

Active listening is one of the indispensable axes in evaluating the dialogue of psychotherapy. Although there have been discussions about it in the area of clinical psychology, the method for evaluating active listening has been missing. It is thus necessary to establish it to improve the quality of listening in the interview. The authors have proposed a measurement method of the degree of active listening with a device we originally developed to evaluate emotion (EMO system). This paper reports on the experiment conducted to compare the evaluations of a psychotherapy by expert clinical psychologists with those by undergraduate students as one of the coursework tasks for a clinical psychology course. A new experimental setup was proposed including a multiresolutional analysis to detect the change of active listening evaluation.

1. はじめに

臨床心理面接という対話の評価において，傾聴は欠くことのできない重要な軸の一つである．これまで傾聴を構成する要素に関する知見はあるが[アイビイ 1985]，面接全体として傾聴が真に成立したかどうかについて評価測定するための手法は，まだ十分確立していない．特に傾聴に際してそうしているつもりでも相手はそう感じていないといったすれ違いがつきまとうことはこの課題をいっそう困難にしている．しかし面接の質の把握や向上のためには，傾聴の評価測定をすすめていく必要がある．

本研究ではそのためのひとつのアプローチとして次の手順で実験を実施し，評価の実際と課題について明らかにする．(1)第三者の臨床心理士が面接ビデオを視聴し，感情評価値入力手法により傾聴度を時系列入力，(2)傾聴度時系列データの変化点（上昇／下降）を多重解像度分析によって自動検出，(3) 同じ臨床心理士によって，なぜ変化点をそのように評価したのかの記述，(4) その変化点が上昇か下降かの判断を初学者の集団で実験，(5)両者の評価の比較と統計的分析．

2. 実験設定

臨床面接における傾聴の度合いを判断する際，臨床心理士と心理コースを受講する学生においてどのような違いがあるかを調べるため，傾聴評価変化点に着目して実験を企画した．ここでは，臨床心理面接コーパス，実験使用データ，傾聴度評価，変化点自動抽出について説明し，それを元にした実験設定について述べる．

2.1 臨床心理面接コーパス

我々は臨床心理面接における，対話音声・身振り・表情といった社会的信号から，その特性に迫るために 44 対話からなる臨床心理面接コーパスを構築している[Inoue2012]．このコーパスは，生データとトランスクリプト及びアノテーションからなる．生データは，(1) 音声付き対話ビデオ，口元マイクによる高品位音声，頭部加速度データ等の生データ，(2) 発話内容の書き下しと ELAN による時間対応づけ，感情推移観測システム(EMO)による「傾聴度」評価データ(2.3 節参照)[花田 2017a]，コンプリメントラベル[井上 2018]，マイクロカウンセリングラベル[花田 2017b]等，多様なアノテーションが付与されている．現在も進行中でまだ全てが終了しているわけではないが，さらに必要に応じ別のアノテーション付与にも対応できる柔軟性を持たせてある．なお，このコーパス作成にあたっては，参加者から自身が記録されたビデオ映像・音声・身体動作データを，研究目的で分析し発表することへの同意を得ている．

2.2 実験刺激となる面接映像

臨床心理面接コーパスから，カール・ロジャーズによる「Miss Mun」[ロジャーズ 2007]の内容を元に模擬面接を行った 9 対話のうちランダムに一つを選出し実験に使用した(図 1，付録参照)．面接にはクライエント(Cl)として臨床心理士養成大学院に所属する 20 代女子大学院生 1 名が参加した．Cl の大学院生は臨床心理学の実習の一環として参加を希望した．これに対し，心理臨床歴 5 年の 30 代男性臨床心理士(Th)1 名が面接担当した．なお Th の面接における流派は家族療法／短期療法である．



図 1 評定対象の面接ビデオと，同時進行で入力される傾聴度評定値の表示．傾聴度は 100～-100 の値で保存．

連絡先：花田里欧子，東京女子大学現代教養学部，〒167-8585 東京都杉並区善福寺 2-6-1，電話番号&Fax 番号 03-5382-6419，hanada@lab.twcu.ac.jp

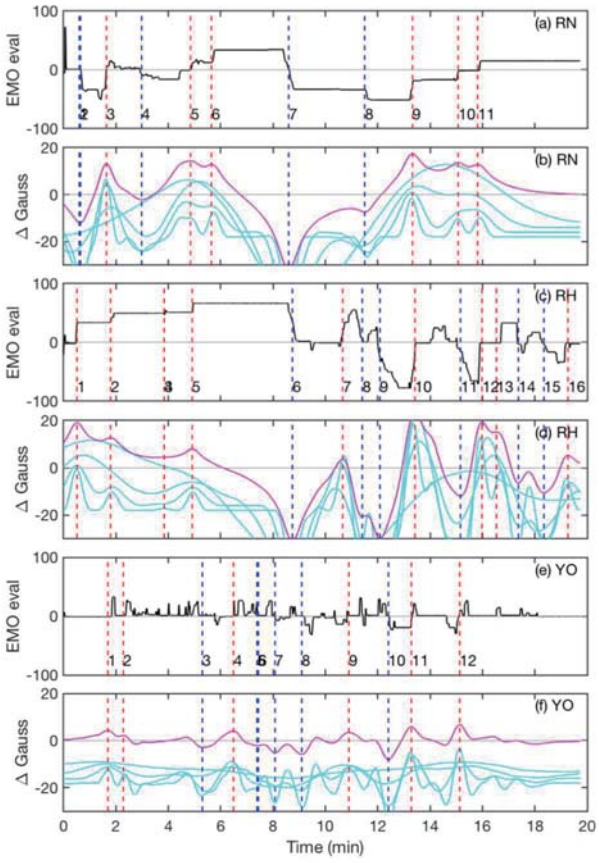


図 2 EMO による傾聴評価時系列データ (a)(c)(e)（黒線）と，変化点検出のための多重解像度分析結果(b)(d)(f)（マジェンタ:統合結果．シアン:解像度ごと）．横軸はビデオの時間．縦破線は検出された上昇変化点(赤)，下降変化点(青)．数字は変化点番号．

2.3 傾聴度評価

音声付き対話ビデオデータから傾聴度評価を行なった．まず，異なる臨床経験（5 年，10 年，5 年）を持つ 3 名の臨床心理士（RN, RH, YO）が，対象のビデオを見ながら，面接を行なっている臨床心理士(Th)がどの程度クライエント(Cl)に「傾聴」しているかを，第三者評価した．

このため，感情推移観測システム(EMO system)[八木 2013]を用いて，ビデオ映像と同期して評定値を時系列データとして入力した．EMO は，ハードウェアとして Arduino に接続したスライド抵抗のインターフェースを持ち，Processing で処理することにより，その時点ごとのつまみ位置に対応した評定値を図 1 のようにビデオ画面の右側に実時間で表示するシステムである．臨床心理士は，Th の傾聴度を判断し，中央をニュートラルとして傾聴～不傾聴の値をスライドバーの位置で入力する．この値は 100～-100 の間の数字で保存される．表示には，程度が分かるように正負両方に「非常に」，「かなり」，「やや」の補助語が入れてある．それぞれ(±100，± 66，± 33)の値に相当する．

図 2(a)(c)(e)に，それぞれ RN, RH, YO が付けた EMO 評価時系列データを示す．これを見ても分かるように，臨床心理士により評定の仕方が異なることが分かる．RN, RH は一定のところから大きく変動する場合が多く，YO はおそらく発話単位ごとに評定をしているようである．このようにお互いの傾向が異なることから，評定を平均化するのではなく，特定の評定者を基準として分析を行うことと，3 人のアノテータの時系列の生データから何らかの共通点／相違点を抽出することが必要となる．ここでは，傾聴評価値の変動が，対話の転換点等重要な質的変化と関連性があると仮定して，その変化点に着目することとした．

表 1 図 2(a)の RN の変化点の時間ならびに上昇(↑) 下降(↓)と変動理由

#	時間	上下	変動理由
1	0’36”	↓	うなずきが小さすぎる上に途中からしなくなる．かつ視線が下を向いており聞いているのか分かりにくい上に寝ているようにも見える．
2	0’39”	↓	うなずきが小さすぎる上に途中からしなくなる．かつ視線が下を向いており聞いているのか分かりにくい上に寝ているようにも見える(2 と同じ理由)
3	1’38”	↑	目を見てジェスチャーを交えながら相手の発言に則して話そうとする様子から，話を受け取って返そうとする様子がうかがえる．
4	2’59”	↓	うなずきが曖昧で声が小さすぎる様が CL の発言を受け取っている様子に見えがたい．うなずきも CL の発言のペースに合っていないように感じる．
5	4’51”	↑	徐々にうなずきが CL の発言のタイミングと一致し始め，自身の発言では明瞭な語り口調で展開される様子から CL へ向き合う態度がうかがえる．
6	5’39”	↑	質問の中で CL が母親に対する対応について要約ができており，それを正確に伝え返していたため傾聴していた様子がうかがえる．
7	8’36”	↓	一方的に具体的なところまで介入の方針が展開されてしまい，もう少し「母親との間にリミットを設ける」という事に対してまず CL が行動していきたいのか，それを踏まえて展開した方が良かったのではないか．
8	11’30”	↓	回数が少なくて「焦る」ということは言っているが，時間かかるか否かは特に CL は言っておらず，「時間かかるだろうから焦る」というニュアンスで伝え返して質問してしまい一方的な問題意識が展開されてしまう．
9	13’20”	↑	CL が Th の発言に対して同意の言葉を述べ(確かに)，話が展開する様子から，ちゃんと Th が Cl の意図を汲めていたようにうかがえた．
10	15’04”	↑	リミットを設ける頻度について，CL が決めても良いし，Th との話し合いで決めても良いといった感じに決定における自由を保証してくれたことが良かった．
11	15’49”	↑	CL の問題意識を要約して今後の方針に結びつけて提案している様子が傾聴的な態度を感じさせた．

2.4 変化点自動検出

変動の解像度が事前には明確でない時系列データからの変化点検出のために，多重解像度分析を行った．ここでは，ガウス関数 G を一回微分した ΔG を，wavelet フィルタの母関数とした．このフィルタを EMO 評価時系列データに畳み込み，中心周波数ごとの平滑化微分を行なった．ここで，ΔG-wavelet 長を 64 秒，128 秒，256 秒，512 秒の 4 解像度とし， 1 分から 8 分程度の変動を抽出できるようにした．これは，傾聴評価時の時間遅れや過去の経緯による判断を含めて大局的な変化が見られるようにしたためである．64 秒より短い解像度を含めることも試したが，変化点の数が多くなりすぎてしまい，実験や評価の枠組に乗らないと判断した．

図 2(b)(d)(f)に各臨床心理士の ΔG-wavelet フィルタ出力を示す．シアン色が各解像度の出力で，それらを加算した結果がマジェンタの曲線である．この統合曲線の局所最大時刻を上昇変化点(赤破線)，局所最小時刻を下降変化点(青破線)に対応するとした．この結果，図 2 (a)(c)の目視で分かる特徴的な変化点を精度良く検出できていることが分かる．また，図 2 (e)では，傾聴評価入力値は細かく変化しているが，この多重解像度分析によって大局的な評価変動を取れているものと考えられる．

2.5 実験の目的と対象設定

前節の手順で，臨床心理士がつけた傾聴評価時系列データから自動抽出された変動の方向を，初学者がどのように判断す

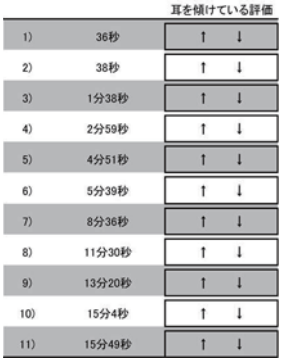


図 3 質問紙

るかを調べることが，今回の実験の目的である．また，この際，第三者の EMO 時系列データ作成者が，なぜそのように評価を変動させたのかの情報とも対比して検討したい．そこで，今回は表 1 のようにその理由の記述が得られた図 2(a)の RN の変化点に関して実験を行うことにした．変化の方向は上昇が 6 箇所(3,5,6,9,10,11)で下降が 5 箇所(1,2,4,7,8)であった．1,2 は時間の開きが比較的短く違いが見られないため変動理由は同じとなる．

2.6 実験方法

首都圏の女子大学心理系学科における臨床心理の授業の一環として，学部 2 年生 73 名(以下，初学者)を対象に実験を行なった．教室前方のスクリーンに，今回分析した動画(図 1)を再生し，質問紙(図 3)を用いて図 2(a)の変化点番号 1～11 の箇所で，上昇「↑」か下降「↓」で傾聴の変化方向の評定を求めた．この際，変化点時刻より 30 秒後ろまで再生したところで一時停止を行ない，評定時間を確保した．変化点番号(1～11)と時刻が記されており，その次に評定の選択肢が用意されている．上昇の場合は「↑」，下降の場合は「↓」に○をつけて評定する．

3. 実験結果

臨床心理士と初学者の評定の比較を行い(表 2)，2.6 節で得られた初学者の評定結果をクラスタ分析によって分類，デンドログラムを表示し(図 4)，類似変動があるかどうか図 2 と対比する．

3.1 臨床心理士と初学者の評定の比較

臨床心理士と初学者による評定を示す(表 2)．2.4 節で述べた，変化点の自動検出によって割り出された時刻の前 15 秒間から後 15 秒間にかけてどのように評定値が変動したかを臨床心理士による変動の方向性として定義した．また，上昇する際には前 15 秒間の中から最低値を，後 15 秒間の中から最高値を，下降する際には最低値と最高値を逆にして参照した．

初学者による評定について，該当箇所の 1～11 で上昇を選んだのは全回答中平均 63%(min=25%, max=87%)，下降を選んだのは全回答中平均 37%(min=13%, max=75%)であり，上昇の割合が高かったのは 11 問中 8 問(4, 5, 6, 7, 8, 9, 10, 11)だった．このことから全体的に比較的上昇を選ぶ傾向にあることが分かった．なお，上昇と評定される割合が高かった変化点は，1 位から順に 4(87%)，10(80%)，6(79%)，下降と評定される割合が高かった変化点は，1 位から順に 1(77%)，2(68%)，3(51%)と，前半部分で下降を選ぶ割合が比較的高いことが分かった．

臨床心理士が評定した変化の方向と，初学者の過半数の評定結果が一致したものは 1,2,5,6,9,10,11 で，一致する割合が高いのは順に 10(↑，80%)，6(↑，79%)，5(↑，76%)であった．逆

表 2 臨床心理士と初学者による評定まとめ

		臨床心理士				初学者	
設問	時間	前	後	差分	変動	↑ a)	↓ a)
1	0'36"	1	-37	-37	↓	25 b)	75 b)
2	0'39"	1	-37	-37	↓	32	68
3	1'38"	-50	15	66	↑	49	51
4	2'59	4	-10	-14	↓	87	13
5	4'51"	-1	17	18	↑	76	24
6	5'39"	12	34	21	↑	79	21
7	8'36"	35	-33	-68	↓	67	33
8	11'30"	-34	-51	-17	↓	56	44
9	13'20"	-51	-18	33	↑	67	33
10	15'04"	-18	-1	17	↑	80	20
11	15'49"	-1	15	16	↑	73	24

a) ↑: 上昇，↓:下降 b) 単位は%

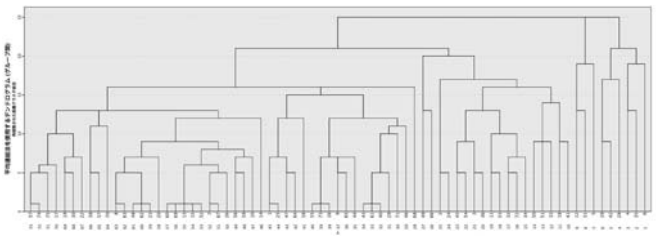


図 4 グループ間平均連結法によるデンドログラム．横軸は初学者，縦軸は評定パターン．

に過半数が不一致だったものは 3,4,7,8 で，不一致になった割合が高いのは順に 4(↓，87%)，7(↓，67%)，8(↓，56%)であった(カッコ内の矢印は臨床心理士による評定)．一致率が高いものはいずれも上昇であり，低いものはいずれも下降であった．

3.2 初学者のクラスタリング結果

初学者 73 名の全 11 問の評定をグループ間平均連結法によりクラスタリングし，おおよそどのような評定のパターンが見られるか検証し，さらに臨床心理士の評定がどれに類似するか比較する．なお，欠損値のある 1 名は分析から除いた．SPSS を使用してデンドログラムを作成し，距離 24 を閾値とすると，3 つのクラスタが得られたが，12,31,5 を含むクラスタと 39,42,28,4,35,6 を含むクラスタは人数が少ないため一つのクラスタに統合し，2 つのクラスタを得た(図 4)．第 1 クラスタは 64 名，第 2 クラスタは 9 名の初学者が含まれた．人数比の偏りを見るために χ^2 検定を行った．結果，有意な人数比の偏りが見られた(χ^2=41.44, df=1, p<.01)．

得られた 2 つのクラスタにおける評定の特徴を見るために，χ^2 検定と残差分析を用いて各設問における評定の偏りを検証した．結果，1(χ^2=4.65, df=1, p<.05)，2(χ^2=5.31, df=1, p<.05)，4(χ^2=5.27, df=1, p<.05)，6(χ^2=6.79, df=1, p<.01)，7(χ^2=14.59, df=1, p<.01)，9(χ^2=4.79, df=1, p<.05)，10(χ^2=7.71, df=1, p<.01)，11(χ^2=22.80, df=1, p<.01)で有意な差が見られたため，2 つのクラスタの特徴は以上の設問で検討した．

各クラスタにおける評定の特徴を人数比の偏りから見た残差分析の結果と，臨床心理士の評定を表 3 に示す．

表 3 臨床心理士と初学者クラスタにおける評定の傾向まとめ

設問	臨床心理士	初学者	
		第 1 クラスタ	第 2 クラスタ
1	↓	↓*	↑*
2	↓	↓*	↑*
4	↓	↑*	↑*
6	↑	↑**	↓**
7	↓	↑**	↓**
9	↑	↑*	↓*
10	↑	↑**	↓**
11	↑	↑**	↓**

※ ↑: 上昇, ↓: 下降, **: $p<.01$, *: $p<.05$

第 1,2 クラスタ間で差は 4 以外で見られた. 第 1 クラスタは 1,2 で下降し, 6,7,9,10,11 で上昇した. 第 2 クラスタは逆に 1,2 で上昇し, 6,7,9,10,11 で下降した. 臨床心理士の結果は第 1 クラスタに近く, 一致する設問がより多いことが分かった (1,2,6,9,10,11).

3.3 臨床心理士同士での相違

RN の変化点は, 第 1 クラスタのパターンと比較的類似していた. 初学者のほとんどが第 1 クラスタに含まれていたことからも (73 名中 64 名), このパターンは本面接の傾聴評価としておおまかな特徴のひとつを捉えているものと考えられる. 一方一定のところから大きく変動するという点では RN と共通する場合が多い RH については, 本実験では扱っていないために初学者との比較はただちにできないが, RN の変化点とおおよそ同位置の RN1-RH1, RN10-RH11 について見てみると, 評定結果は真逆になっている. つまり, 第 2 クラスタは RN とは反対の評定であるが, RH とは傾向が一致する.

このように専門家間でも評価はばらついている. 質的な理由の一つは, 面接を行なった Th との心理的距離もあるかもしれない. RH は指導的な立場にいた者で, RN は一度も直接会ったことがない者である. RH は Th の言動に対し, より積極的に「このようにすれば良いのに…」という内的な評価が働いた可能性がある. 面接終盤 RN は RN11 以降フラットに評定しているが, RH は所々下降させている. 傾聴に関して理論的, 技法的側面では一定の評価軸を持っていると想定される臨床心理士においても内的な影響を受ければ実際の評定はぶれてくる.

4. 本研究の成果と課題

本研究は, 臨床心理面接における傾聴度変化の評価における臨床心理士と初学者の比較を行った. このため, 従来に無い新しい手法を開発した. 実験の結果, 2 つの初学者の評定パターンが得られ, そのうち一方は臨床心理士との類似点が示された. 本結果は一人の臨床心理士による評定との差異を検討したものであり, 他の臨床心理士も同様ではない. このように, 傾聴評価の場合でも単純ではなく, 予測等の社会的信号処理を行う場合も, 表層的ないわゆる信号だけではなく, 内的な状態を定式化することは必須であろう. そのため今後, 基準となる評価者を複数人設定した比較検討が必要である. 感情評価は主観的であり, 社会的信号処理をする際, 参照する知識体系が異なる. たとえば本研究が示すように, 臨床心理面接の熟練のみが評価を一義的に規定するものではなく, それは正解を定めにくいということである. 感情評価の観点からエージェントを検討するにあたっては(たとえば傾聴対話エージェント[石田 2018]等), 振る舞いの個人差を考慮した上ですすめていく必要がある.

謝辞

本研究は JSPS 科研費 26380925, 15K13143, 16K00202, 人工知能研究振興財団および電気通信普及財団の助成を受けたものです.

参考文献

[アイビイ 1985] アレン・E・アイビイ, 福原真知子, 椙山喜代子, 国分久子, & 楡木満生(訳編): マイクロカウンセリング―“学ぶ-使う-教える”技法の統合, 川島書店, 1985.

[花田 2017a] 花田里欧子, 入野俊夫, 古山宣洋, 井上雅史, & 中島隆太郎: 臨床心理面接コーパスと感情推移観測システム(EMO system)を用いた傾聴学習支援, 信学技報, 116(436), 5-10, Jan. 2017.

[花田 2017b] 花田里欧子, 入野俊夫, 古山宣洋, 井上雅史, & 中島隆太郎: 感情推移観測システム(EMO system)による傾聴評価とマイクロカウンセリングのタグ付けとの関連, 信学技報, 116(524), 113-118, Mar. 2017.

[Inoue2012] M. Inoue, R. Hanada, N. Furuyama, T. Irino, T. Ichinomiya, & H. Massaki: Multimodal corpus for psychotherapeutic situation, The 8th Workshop on multimodal corpora LREC workshop on multimodal corpora for machine learning: How should multimodal corpora deal with the situation?, pp.18-21, Istanbul, Turkey, May 2012.

[井上 2018] 井上雅史, 中島隆太郎, 花田里欧子, 古山宣洋, & 入野俊夫: コンプリメントのアノテーション, 信学技報, 117(509), 11-15, Mar. 2018.

[石田 2018] 石田信也, 井上昂治, 中村静, 高梨克也, 河原達也:共感表出と発話促進のための聞き手応答を生成する傾聴対話システム, 人工知能学会研究会資料 SIG-SLUD-B509, pp. 7-12, Mar. 2018.

[ロジャーズ 2007] カール・ロジャーズ, 加藤久子 & 東口千津子(共訳), 畠瀬稔(監修): ロジャーズのカウンセリング(個人セラピー)の実際, コスモス・ライブラリー, 星雲社 , 2007.

[八木 2013] 八木みゆき, 森田礼子, 中井正人, 西村竜一, 河原英紀, & 入野俊夫: 説明対話における韻律情報および頭部運動と感情評価値の間連性分析の試み, 電子情報通信学会／音響学会音声研究会, SP2013-67, pp.15-20, Sept. 2013.

付録:面接の概要

面接の進行と対応する変化点(表 1)を()内に示す. Cl が人の期待に応えることについて, 自分のできないことはやらないよう「リミット」を設けた方が良いのではないかという気づきが語られ, Th は小さく頷きながら聞き始める(1,2). Th が「リミット」についてさらに説明を求めると(3), Cl の具体例を交えた説明を再び小さく頷きながら聞き始める(4). Cl の発言にタイミングを合わせて頷き初め明瞭な口調でまとめ返し(5), さらに Cl が語った母親との「リミット」に関するエピソードをまとめながらその実現可能性の是非を問う(6). Th から「リミット」を設ける頻度について助言がありつつ(7), そのためには時間がかかることへの懸念も Th が口にする(8). 急に「リミット」を設けて行動様式を変えることへの危惧を Th が語ると Cl はそれに同調し(9), そのあり方を Cl だけでも Th との話し合いでも決めるのはどちらでも良いという決定の自由を Th が伝え(10), 最後にそれを方針に面接を進める旨を共有する(11).

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

言語・非言語情報の融合に基づく重要発言の推定

Predicting Important Utterance based on Fusing Verbal and Nonverbal Information

二瓶 芙巳雄[*1] 中野 有紀子[*2] 高瀬 裕[*2]
Nihei Fumio Nakano Yukiko Takase Yutaka

[*1] 成蹊大学大学院理工学研究科 Graduate School of Science and Technology, Seikei University
[*2] 成蹊大学理工学部 Faculty of Science and Technology, Seikei University

Automatic meeting summarization would reduce the cost of producing minutes during or after a meeting. With the goal of establishing a method for extractive meeting summarization, we propose a multimodal fusion model that identifies the important utterances that should be included in meeting extracts of group discussions. The proposed multimodal model fuses audio, visual, motion, and linguistic unimodal models that are trained by employing a convolutional neural network approach. The performance of the verbal and nonverbal fusion model presented an F-measure of 0.827. We also discuss the characteristics of verbal and nonverbal models and demonstrate that they complement each other.

1. はじめに

グループ議論は意思決定や新規アイデアの創出に役立つ. しかしながら, 議論で上がった意見を共有するため, また議論を振り返るためには, 議論の重要な点を議事録として要約する必要がある. 議論を自動で要約することができれば, 議事録作成のための作業を削減することができる.

自然言語処理の研究領域で発展した文書要約生成[Saggion 13, Spärck Jones 07]の技術は, 会議の要約のためにも使用されている. また会議はマルチモーダルインタラクションの側面を持つことから, テキスト情報以外にも, 会議の参加者の非言語情報も利用することができる. 多くの研究が要約に含めるべき重要発言の推定に, 文の長さや tf*idf などの言語情報に加え, 音声特徴量などの非言語情報も使用したモデルを提案している[Murray 06, Xie 09].

しかし以上の研究は, マルチモーダル情報の共起関係までを考慮したものではなかった. 例えば, 大きな声での発声は大きな身体動作と共起するといえ, そしてそれは重要発言を特徴づける行動と考えられる. さらには, グループ会議では個人の行動間の共起に加え, 複数人の行動間の共起関係も考慮する必要がある. 例えば, 他者からよく注視された発言はグループから重要だと認知されていると考えられる.

だがスピーチ, ジェスチャ, 表情, そして言語行動といった単一モダリティを表現する特徴量を定義した上で, 複数モダリティ間の共起関係を表す特徴量や, 複数の参加者にまたがる行動データの共起関係を表す特徴量を手作業で定義することは現実的でない. ここで深層学習には, 音声や画像からその特徴表現を自動で獲得できる[Golik 15, Pan 16]ことから, 単一モダリティの特徴表現だけでなく, 複数モダリティ間の特徴表現, さらには参加者間の特徴表現も自動で獲得することが期待できる.

以上の議論より本研究では, 複数参加者にまたがるマルチモーダル情報を深層学習によりフュージョンさせた, 高性能な重要発言推定モデルを提案する. さらには, 得られたフュージョンモデルの特性や性能向上の要因も調査する. そのためまず, 言語情報を使用するモデルや, スピーチや頭部動作に基づく非言語情報モデルを作成する. 非言語情報モデルは[Nihei 17]の研究成果を利用する. つぎに, 両者をフュージョンさせたモデルを作成し, 言語, 非言語, 言語・非言語フュージョンの 3 種類のモデルの推定性能を比較する. さらに, 本研究で提案する言語情報モデルと非言語情報モデルそれぞれがとらえる重要発言の特徴を調査し, さらに言語情報と非言語情報のフュージョンによる改善点についても議論する.

連絡先: 二瓶 芙巳雄, 成蹊大学大学院, 0422-37-3756, dd166201@cc.seikei.ac.jp

2. データ

本研究では MATRICS マルチモーダル議論コーパスを使用した[林 15]. これには, 4 人から形成される 9 つのグループによる, 計 16 回の対話が収録されている. 議論グループは意思決定型のタスクについて, 約 20 分間議論した.

収集データは, 会話参加者ごとのスピーチ, 顔映像, そして頭部動作データである. スピーチはヘッドセットマイクにより収録した. 顔映像は web カメラにより記録された. 頭部動作は議論参加者の後頭部に装着された加速度センサにより計測された. またスピーチから発話を認定した. 発話はアノテータがアノテーションツール上で, 音声波形を確認しながら認定した. 発話の区切りは, 所与の有声区間の前後に合計 300ms 以上の無音区間が生じた場合とした. そして各発話に対して, 発話内容を人手により書き起こした. 分析データの詳細は 3 章で説明する.

コーパス内の発話の重要度を評価するため, 5 名のアノテータが 16 の対話ビデオに含まれる 8,939 発話から, 議論の抜粋として採用すべきかという観点における重要発言を選択した. この 5 名のアノテータ間には相互に高い評価者間信頼性が確認されている(κ 係数 > 0.4). その後, 5 名のうち 3 名から重要発言と選択された発話を重要発言と定義した. 結果として, 3,789 発話が重要発言となった.

3. モデル

4 つの非言語情報ユニモーダルモデルと, 1 つの言語情報モデルを作成する(図 1). そしてこれらユニモーダルモデルの出力を統合し, マルチモーダルフュージョンモデルを作成する.

作成した全てのモデルは, 与えられた入力ベクトルが重要発言として選択されるべきか否かを判断するように訓練された.

3.1 非言語情報ユニモーダルモデル

先行研究[Nihei 17]において提案した, 3 次元データに対する畳み込み演算を行う軽量な CNN(図 1 左側)を, 非言語情報

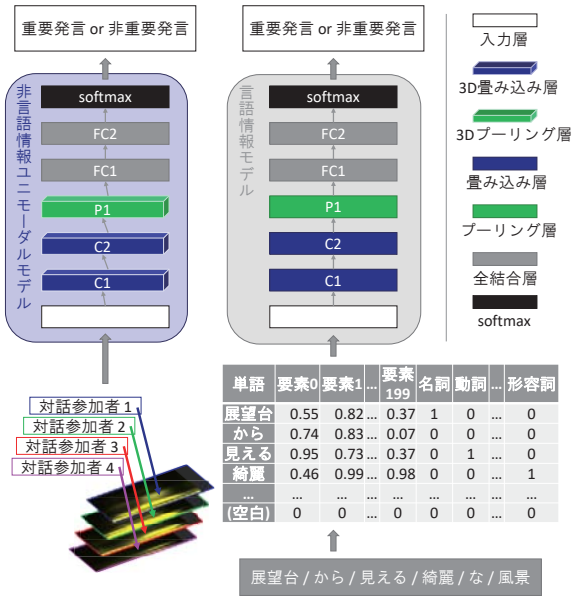


図 1 ユニモーダルモデルのネットワーク構造

ユニモーダルモデルとして使用する. このネットワークは, 2 層の 3 次元畳み込み層と 3 次元プーリング層, 2 層の全結合層, そして分類のための softmax 層からなる. このネットワークは議論参加者を畳み込み演算の要素として扱うこと, また膨大な量のデータが使用できない場合に多層ネットワークに引き起こされる過学習を回避することをねらったものである.

非言語情報ユニモーダルモデルのネットワーク構成を表 1 に示す. 収集されたセンサデータのサンプリング周波数がモダリティによって異なるため, 入力ベクトルのサイズはモダリティにより異なる. また, ネットワークへの入力となる発話の時間長をすべて 15 秒に統一するために, 時間長が短い発話には空白のデータを追加した. したがって, 入力ベクトルの幅はサンプリング周波数×15 になる. 全ての非言語情報ユニモーダルモデルは, SGD(AdaDelta, ミニバッチサイズ 32)で訓練した. エポック回数は 30 であり, 全ての全結合層と畳み込み層における活性化関数は ReLu を用いた. 図 1 における全結合層のユニット数は FC1, FC2 いずれも 128 である. 畳み込みカーネルの数は, C1, C2 ともに 32 である. P1 層と FC1 層間のドロップアウト率は 0.25 であり, FC1-FC2 間, また FC2-softmax 間は 0.5 である.

モデルの入力ベクトルとして使用するモダリティは, 頭部動作スペクトログラム, スピーチスペクトログラム, スピーチインテンシティ, 頭部姿勢である. 以降では各入力ベクトルの表現とネットワークの構成ついて詳細を説明する.

(1) 頭部動作スペクトログラムモデル (HS model)

加速度センサは各議論参加者の後頭部に取り付けられ, 30fps で 3 軸の角速度を出力する. 角速度を以下の式(1)に適用することで, 各議論参加者の頭部合成角速度を算出した. ここでx_i, y_i, z_iはそれぞれ, iフレーム目におけるx, y, z軸の角速度である.

$$HMA_i = \sqrt{x_i^2 + y_i^2 + z_i^2} \quad \cdots (1)$$

時系列の頭部合成角速度データを, フーリエ変換を用いて, 時間, 周波数成分, そして振幅の大きさを表すスペクトログラムとして表現した. フーリエ変換のウィンドウ幅は 30 フレーム, スライド幅は 1 フレームとした. スペクトログラムは各発話区間に対して, 4 人の各議論参加者について作成される. 従って表 1 に示すように, 4 人の議論参加者から得られる頭部動作データは,

表 1 各ユニモーダルモデルに対する, 入力・畳み込みカーネル・プーリングフィルタそれぞれのサイズ

ユニモーダルモデル	入力サイズ	畳み込みカーネルサイズ	プーリングフィルタサイズ
HS model	450, 15, 4, 1	3, 3, 4	2, 2, 1
SS model	750, 32, 4, 1	5, 3, 4	
SI model	1500, 1, 4, 1	10, 1, 4	
HP model	450, 3, 4, 2	3, 3, 4	
V model	48, 219, 1	48, 1	2, 1

450(発話時間長=30fps× 15sec)×15(周波数分解能)×4(議論参加者数)×1(チャネル数)のサイズとなる. これをネットワークに対する入力とする.

畳み込み層のカーネルサイズは 3×3×4 であり, プーリングサイズは 2×2×1 である.

(2) スピーチスペクトログラムモデル (SS model)

各議論参加者に装着したヘッドセットマイクからサンプリング周波数 44.1kHz の音声を記録し, そこからスペクトログラムを作成した. フーリエ変換のウィンドウ幅は約 1.5 秒($2^{16} = 65{,}536$フレーム), スライド幅は 1 フレームとした. 従って, 観測できる最大周波数は約 32kHz となる. またフーリエ変換したのちのサンプルを 50fps になるようにダウンサンプルした. 加えて最大で約 32kHz 観測できる周波数成分を 32 区間に分割した. そして, 分割された各区間における周波数の強度の総和をデータポイントとした. 頭部動作モデルと同様に, スペクトログラムは各発話区間に対して, 4 人の各議論参加者について作成される. 従って 750(発話時間長=50fps× 15sec)×32(周波数分解能)×4(議論参加者数)×1(チャネル数)のサイズとなる. 畳み込み演算のためのカーネルサイズとプーリングサイズは表 1 に示す.

(3) スピーチインテンシティモデル (SI model)

各発話について, スピーチインテンシティを音声分析ツール [1] により 100fps で計測し, 1500(発話時間長=100fps×15sec)×1(次元数)×4(議論参加者数)×1(チャネル数)のサイズのデータを作成した. ネットワークの詳細な設定は表 1 に示す.

(4) 頭部姿勢モデル (HP model)

議論参加者の顔面を記録した映像に対して, 画像処理による顔検出器 [2] を適用することにより, x,y,z 軸における頭部位置と回転角を 30fps で計測した. それぞれは, 450(発話時間長=30fps×15sec)×3(x,y,z それぞれ)×4(議論参加者数)×2(チャネル数, 位置と回転角)のデータに変形された. 詳細なネットワーク設定は表 1 に示す.

3.2 言語情報モデル (V model)

言語情報モデルは各発話区間の発話内容を入力とするため, ネットワークへの入力は一人の 1 発話の言語情報となる. そのため, ここで作成するネットワークは, 非言語情報ユニモーダルモデルで行った 3 次元的な畳み込み演算ではなく, 2 次元的な畳み込み演算を行う CNN となる. ネットワークの構造は図 1 に示すように, 非言語情報ユニモーダルモデルと同様であるが, 3 次元畳み込み層と 3 次元プーリング層がそれぞれ, 2 次元畳み込み層と2次元プーリング層に置き換わる. 訓練に使用したハイパーパラメタは全て, 非言語情報ユニモーダルモデルと同一である.

各発話区間の発話内容を単語に分割し, 各単語を skip-gram モデルによりベクトル化した. 形態素解析器には mecab[3] を使用

[1] Praat: http://www.fon.hum.uva.nl/praat/
[2] FaceAPI: https://www.seeingmachines.com/
[3] Mecab: http://taku910.github.io/mecab/

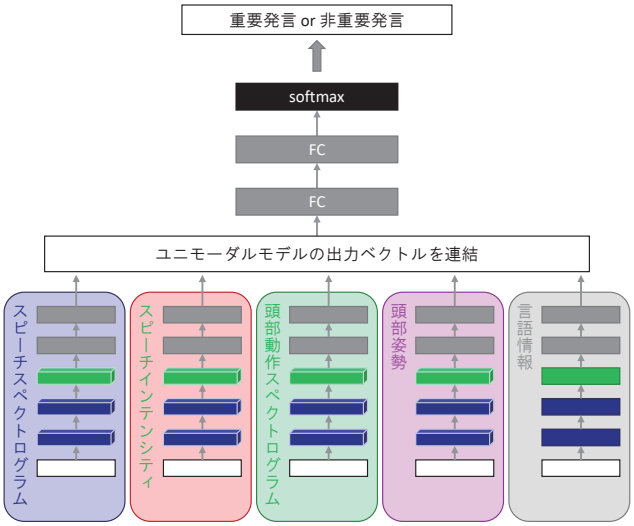


図 2　言語・非言語フュージョンモデル

し，新語対応辞書である NEologd[4] を使用した．Skip-gram モデルの訓練には wikipedia の記事に含まれる文章を用いた．訓練されたモデルは単語を 200 次元のベクトルで表現する．加えて，形態素解析では，各単語に 19 種類の品詞のいずれかが付与されるが，これを 19 次元のベクトルとして表現した．この 2 つを統合し，各単語について 219 次元のベクトルを作成した．非言語情報と同様の考えから，発話内の単語数が少ない発話には，単語数が 48 になるように，空白の単語ベクトルを追加した．48 は発話内容における最大単語数である．したがって，入力データのサイズは，48（最大単語数）×219（単語ベクトル 200+品詞ベクトル 19）×1（チャネル数）となる．詳細なネットワーク設定は表 1 に示す．

3.3 マルチモーダルフュージョンモデル

ユニモーダルモデルを統合し，非言語フュージョンモデル (NV fusion)と，言語・非言語フュージョンモデル(V-NV fusion，図 2 参照) の，2 つのフュージョンモデルを作成した．NV fusion はすべての非言語情報ユニモーダルモデルを統合したものであり，V-NV fusion はすべての非言語情報ユニモーダルモデルと言語情報モデルを統合したものである．ユニモーダルモデルを統合するにあたり，それぞれの softmax 層を破棄し，softmax 層に接続していた全結合層から得られる出力ベクトルを連結させ，フュージョンモデルの入力ベクトルとした．従って，NV fusion と V-NV fusion の入力ベクトルの次元数はそれぞれ，512（=128×4），640（=128×5）である．訓練に使用したハイパーパラメタはドロップアウト率を除き，非言語情報ユニモーダルモデルと同一である．マルチモーダルフュージョンモデルにおいて，ドロップアウトは使用されない．

4. モデル性能の評価

前節で提案したモデルの性能を，Leave-One-Group-Out 交差検証法により評価する．この交差検証法は，訓練に使用しないグループのデータを用いてモデルを評価するため，未知なデータが供給された時のモデル性能を最も適切に評価できる．訓練データはアンダーサンプリングにより正例数と負例数を一致させた．

図 3 に，F 値によるモデルの評価結果を示す．V-NV fusion が最良で，その性能は 0.827 であった．言語情報と非言語情報を

[4] NEologd: https://github.com/neologd/mecab-ipadic-neologd

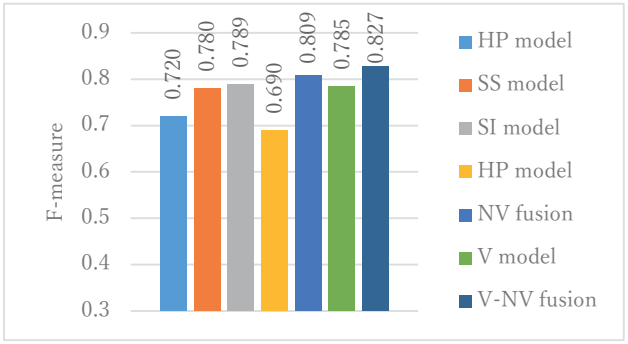


図 3　モデル性能

フュージョンすることにより，いずれのユニモーダルモデルよりも高い性能を示した．従来の機械学習を用いた研究でも報告されたように，深層学習によるアプローチにおいてもマルチモーダルフュージョンは有効であった．次に優れていたモデルは，全ての非言語ユニモーダルモデルを統合した NV fusion であった．ユニモーダルモデルの中では，SI モデルと SS モデル，そして V モデルが優れていることから，音声情報と言語情報を用いたモデルは高性能であった．

5. 議論

本章では，V モデルと NV fusion モデル，そして V-NV fusion モデルの特性について考察する．

5.1 言語情報モデルの特性

言語情報モデルが非言語情報モデルよりも高性能に重要発言を推定できる場合を観察することで，言語情報でのみ捉えられる重要発言の特徴を調査する．

まず，コーパス内で 10 回以上正例として出現する品詞の組み合わせのうち，V モデルが NV fusion モデルよりも多く正例として推定できた組み合わせを数え上げた．その結果を表 2 に示す．言語情報モデルが非言語情報モデルよりも優れた推定を発揮する品詞の組み合わせには，名詞と助詞が必ず含まれており，かつ動詞など，述語と判断できる語も多くの場合で含まれていた．そしてそれらの発話は，ある名詞に対する議論や意思決定，またアイデアの提案であることが多い．

さらに，コーパス内で 20 回以上負例として出現した品詞の組み合わせのうち，V モデルが NV fusion モデルよりも多く負例として推定できた組み合わせについても確認した．その結果，単語数は 1 から 4 であり，さらにフィラーや感嘆詞が含まれる品詞の組み合わせが多いことが特徴的である．そして典型例は，“ああそうですね”，“うん多分”，“ありですね”，“良さげですけど”といった，相槌や確認，また独り言のような，命題的情報を伝達

表 2　V モデルが NV fusion モデルより正例を多く推定できた品詞の組み合わせ

単語数	品詞の組	典型例
3	助詞/動詞/名詞	築地行って
	助詞*2/名詞	サイドメニューとかは
	助詞/助動詞/名詞	焼きそばとかで
	助詞/接続詞/名詞	じゃ東京で
4	助詞*2/名詞*2	パンケーキか唐揚げか
	助詞*2/動詞/名詞	成田着いてから
	助詞/接続詞/名詞*2	じゃあそこで昼
	助詞/動詞/副詞/名詞	まあスカイツリー見て
5	助詞/助動詞/動詞/名詞*2	皇居行くんですか
7	助詞*3/助動詞/名詞*3	上野と秋葉原どっちですかね

する意図のない発話であった．従って言語情報モデルは非言語情報モデルより，命題的情報を伝えない発話を非重要発言としてより多く，より正しく推定することができる．

5.2 非言語情報モデルの特性

非言語情報モデルが言語情報モデルよりも高性能に重要発言を推定できる場合を観察することで，非言語情報モデルがとらえる重要発言の特徴を調査する．

まず，NV fusion モデルが正例の推定に成功した一方，V モデルは推定に失敗した 450 発話を抽出した．そしてそれら発話における，スピーチスペクトログラムと頭部動作スペクトログラムの平均画像を作成した（図 4）．この状況下において，発話者のスピーチスペクトログラムにはエネルギーが確認できるが，その他の参加者のスピーチスペクトログラムにはエネルギーが確認できない．すなわち，ある参加者が発声するとき，その他の参加者は発声していないことが示唆される．頭部動作スペクトログラムでは，発話者のものはエネルギーが強いが，その他の参加者のものは比較して弱い．以上より NV fusion モデルは，他者から静かに傾聴され，注目された発言を重要発言として正しく検出することが示唆された．

一方で NV fusion モデルが負例の推定に成功するが，V モデルは推定に失敗した 503 発話で同様の観察を行った結果，発話者とその他の参加者それぞれのスピーチスペクトログラムにはいずれも強いエネルギーが生じていた．また同様の傾向が頭部動作スペクトログラムにも確認できたことから，NV fusion モデルは全員が発声し，かつ活発に動作する場合に，非重要発言を正しく除外することが可能といえる．

5.3 言語情報と非言語情報のフュージョンによる改善

V-NV fusion モデルによる推定結果から得られる混合行列を，V モデル，また NV fusion モデルと比較することで，主な性能改善点を明らかにする．表 3 に，V モデル，NV fusion モデルそれぞれの混合行列を基準としたときの，V-NV fusion の混合行列の改善割合を示す．V モデルと NV fusion モデルどちらを基準としたときにも，FP が大きく減少し，かつ TN が上昇している．すなわち，非言語情報と言語情報をフュージョンさせることで，非重要発言を誤って重要発言と推定することによる重要発言検出の適合率の減少を防ぎ，かつ非重要発言を正しく排除することが増えるようになることが確認できた．

6. おわりに

本研究では畳み込みニューラルネットワークを用いて，グループ議論における重要発言の推定モデルを提案した．モデルは形態素解析により得られた単語と品詞情報を用いた言語情報モデルと，これを先行研究[Nihei 17]で提案した非言語情報フュージョンモデルと統合した言語・非言語フュージョンモデルを作成した．その結果，言語・非言語フュージョンモデルは全てのモデルの性能を上回り，かつ F 値 0.827 で重要発言を検出可能な高性能なモデルが作成できた．また言語情報モデルの特性を分析した結果，名詞，助詞，動詞といった文の基本的な構成素を含む発話に対しては，非言語情報モデルよりも高性能で推定でき，また非言語情報モデルは他者から静かに傾聴され，注目された発言を言語情報モデルより高性能に推定できること

表 3　V-NV fusion モデルの改善割合

基準	TP	TN	FP	FN
NV fusion モデル	0.34%	3.67%	-16.83%	-1.86%
V モデル	5.07%	4.08%	-18.34%	-21.12%

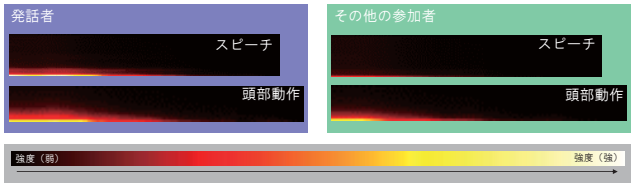


図 4　スピーチと頭部動作の活動量

が確認された．また言語情報と非言語情報をフュージョンすることで，誤推定が減少する効果があることが示唆された．

将来的には本研究の最終目標である，議論の自動要約システムを実現させるため，提案した重要発言推定モデルを用いた要約生成アルゴリズムを検討する．さらに有用な要約が生成できたかを検証するため，生成された要約の評価実験を実施する．

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)，および理化学研究所革新知能統合研究センターの支援を受けたものである．

参考文献

[Golik 15] Golik, P., Tüske, Z., Schlüter, R., and Ney, H.: Convolutional neural networks for acoustic modeling of raw time signal in LVCSR, In *INTERSPEECH-2015* (pp. 26–30). Dresden, Germany, (2015)

[Murray 06] Murray, G., Renals, S., Carletta, J., and Moore, J.: Incorporating Speaker and Discourse Features into Speech Summarization, In *Proceedings of NAACL HLT* (pp. 367–374). Stroudsburg, PA, USA: Association for Computational Linguistics, (2006)

[Nihei 17] Nihei, F., Nakano, Y. I., and Takase, Y.: Predicting Meeting Extracts in Group Discussions Using Multimodal Convolutional Neural Networks, In *Proceedings of the 19th ACM International Conference on Multimodal Interaction* (pp. 421–425). New York, NY, USA: ACM, (2017)

[Pan 16] Pan, J., Sayrol, E., Giro-I-Nieto, X., McGuinness, K., and O'Connor, N. E.: Shallow and Deep Convolutional Networks for Saliency Prediction, In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 598–606). (2016)

[Saggion 13] Saggion, H., and Poibeau, T.: Automatic Text Summarization: Past, Present and Future, In T. Poibeau, H. Saggion, J. Piskorski, & R. Yangarber (Eds.), *Multi-source, Multilingual Information Extraction and Summarization* (pp. 3–21). Berlin, Heidelberg: Springer Berlin Heidelberg, (2013)

[Spärck 07] Spärck Jones, K.: Automatic Summarising: The State of the Art, Inf. Process. Manage., Vol. 43, No. 6, pp. 1449–1481. (2007)

[Xie 09] Xie, S., Hakkani-Tur, D., Favre, B., and Liu, Y.: Integrating prosodic features in extractive meeting summarization, In *IEEE Workshop on Speech Recognition and Understanding (ASRU)* (pp. 387–391). (2009)

[林 15] 林佑樹，二瓶芙巳雄，中野有紀子，黄宏軒，and 岡田将吾: グループディスカッションコーパスの構築および性格特性との関連性の分析，情報処理学会論文誌，Vol. 56, No. 4, pp. 1217–1227. (2015)

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

ウェアラブル端末とセンサ装着ストックによる歩行状態のモニタリング

Monitoring walking condition by wearable devices and sensor attached trekking stock

坂口 憲一[*1] 仲山 加奈子[*1] 工藤 裕[*1]
Kenichi Sakaguchi Kanako Nakayama Yu Kudo

[*1] 株式会社テクノソリューション
Technosolution Co., Ltd.

We developed a prototype of trekking stock that can measure the pressure and acceleration during climbing gait. In both wearable devices (eyeglasses / wristwatch type) and prototypes, it was possible to measure walking data of climbers on actual mountaineering paths, and it was shown to monitor climbers' biological information and walking condition. Furthermore, as a result of the evaluation experiment, we could obtain new knowledge on "visualization of stock movement" and "difference in stock utility in climbing and descent".

1. はじめに

レジャー白書 2017 年[日本 2017]によると，ウォーキング人口は 3,010 万人，登山人口は 650 万人であった．近年，ウォーキングは 3,000 万人強で推移しているが，登山については 2009 年の 1,230 万人をピークに減少傾向にある．一方，年代別では高齢者（60 代以上）の参加割合がウォーキング 53.0%，登山 44.1%となっており，高齢者の参加が多いことが両者の共通的な特徴であるが，登山においては高齢者の山岳遭難が増加しており，社会問題化している．

2016 年の山岳遭難の発生件数・遭難者数・死亡者数（行方不明者含む．以下同様）[警察庁 2017]は，それぞれ 2,495 件（対前年比 13 件減），2,929 人（同 114 人減），319 人（同 16 人減）となっており，前年比では若干減少したものの，統計の残る 1961 年以降，2 番目に高い数値である．表 1 の年齢層別山岳遭難者数によると，2016 年の遭難者数の 50.6%，死亡者数の 67.4%が 60 歳以上の高齢者であるのと同時に，その人数も増加傾向にあることが分かる．

表 1 年齢層別山岳遭難者数

	平成24年（2012）		平成25年（2013）		平成26年（2014）		平成27年（2015）		平成28年（2016）			
	遭難者	死亡	遭難者	死亡	遭難者	死亡	遭難者	死亡	遭難者	構成比	死亡	構成比
20歳未満	165	2	230	0	153	3	201	3	174	5.9%	4	1.3%
20～29	199	7	236	5	222	7	228	10	194	6.6%	12	3.8%
30～39	263	20	251	22	281	13	277	15	291	9.9%	13	4.1%
40～49	267	19	332	32	333	36	372	30	366	12.5%	28	8.8%
50～59	343	41	406	57	402	36	397	43	421	14.4%	46	14.4%
60～69	681	89	686	98	744	97	791	107	746	25.5%	101	31.7%
70～79	451	80	466	81	537	85	609	86	565	19.3%	76	23.8%
80～89	92	25	97	23	114	29	151	35	161	5.5%	36	11.3%
90歳以上	3	0	9	2	6	3	14	6	10	0.3%	2	0.6%
不明	1	1	0	0	2	2	3	0	1	0.0%	1	0.3%
計(人)	2,465	284	2,713	320	2,794	311	3,043	335	2,929	100.0%	319	100.0%

また表 2 の態様別山岳遭難者数に示すとおり，2016 年の態様別では「道迷い」が約 4 割を占めており，「滑落」・「転倒」・「病気」・「疲労」が続く．さらに，過去 5 年間の推移をみると「疲労」や「病気」が増加傾向にあることが分かる．高齢者が増えていることとの関係性も考えられ，且つ疲労による注意力低下が道迷いや転倒・転滑落につながっている可能性もある．

山岳遭難の多くは下山時に発生していることから，登山者の位置情報以外にも，登山中における高齢者の体力・筋力の消耗具合や精神的な疲労具合，体調の変化などを計測し，高齢者本人の主観ではなく客観的な評価結果に基づき，早期下山や休憩，栄養補給などを指南できる仕組みが必要であり，各方面でさまざまな取り組みが実施されている．

表 2 態様別山岳遭難者数

	平成24年（2012）	平成25年（2013）	平成26年（2014）	平成27年（2015）	平成28年（2016）	
	人数	人数	人数	人数	人数	構成比
道迷い	1,031	1,134	1,163	1,202	1,116	38.1%
滑落	380	460	501	501	498	17.0%
転倒	346	393	401	467	471	16.1%
病気	186	221	187	232	229	7.8%
疲労	132	137	162	172	204	7.0%
転落	93	73	90	107	108	3.7%
野生動物襲撃	34	42	48	43	42	1.4%
悪天候	37	64	42	70	18	0.6%
落石	12	17	16	25	16	0.5%
雪崩	8	20	9	17	8	0.3%
鉄砲水	18	7	2	0	2	0.1%
落雷	5	3	0	1	0	0.0%
有毒ガス	0	1	0	0	0	0.0%
その他	136	83	108	128	146	5.0%
不明	47	58	65	78	71	2.4%
合計	2,465	2,713	2,794	3,043	2,929	100.0%

2. 先行研究

まず GPS・Beacon・NFC を活用して，登山者の位置情報の取得および危険情報の提供による遭難事故の防止[国交省 2014][三部 2012]やドローンによる空撮を通じて遭難者の捜索を行う[東京都 2016]研究や実証実験がある．携帯端末の電源確保，電波の強度や検出間隔，位置情報の精度などの課題はあるものの，2018 年度のみちびき（準天頂衛星システム）運用開始以降，実用化されることが期待される．

つぎに運動生理学面では，山本がトレッドミルによる実験環境や実際の登山道において，心拍数や血中乳酸値，動脈血酸素飽和度などを用いて，脚筋力や消費エネルギー量などを分析している[山本 2016]．

また心理面では，岡本らが山小屋に宿泊する登山者に対してアンケート調査を実施し，登山動機の構造を明らかにしたり[岡本 2015]，林らが高所登山における唾液や血液の生体検査から免疫能や心理的変化を調査したりしている[林 2011]．

そして，センサ技術の小型化・高機能化を反映して，井出らが加速度センサを腰部および膝部に装着し，富士山頂での基本歩行（登り・平坦・下り）とストック・荷重の有無による比較検討を実施した[井出 2016]．その結果，①身体動揺の大きさは，下り＞平坦部＞登りの順になったこと，②下りではストック使用により身体の動揺が減少したことなどを明らかにした．

連絡先：坂口憲一，（株）テクノソリューション，〒104-0033 東京都中央区新川 2-21-10，TEL:03-6222-0206，FAX:03-6222-0197，sakaguchi@technosolution.co.jp

3. ウェアラブル端末による登山歩行の計測

前報[坂口 2017]では，実際の登山道において被験者が眼鏡型・腕時計型端末を装着し，登山用ストック（以下，「ストック」と称す）の使用および不使用双方のケースで登山実験を行った．その結果，登山道という条件が安定しない実地環境（フィールド）においても，日常生活に用いる眼鏡や腕時計に組み込まれたセンサからデータを計測することかできた．そして，以下のような可能性を知見として得ることができた．

3.1 下りにおける着地強度の軽減

Z 軸方向（上下）の加速度において，「ストックあり」の方が，「ストックなし」に比べて加加速度の標準偏差が小さく，振幅も減少していることから，歩行バランスの安定化に寄与する可能性が示唆された．さらに，この振幅減少は「登り」に比べて，「下り」に顕著に表れており，ストックを持つことによって下山時の足への負担（着地強度）が軽減された可能性がある．但し，X 軸方向（左右）の加速度においては顕著な差異が見られなかった．

3.2 視線移動の減少に伴う足元への注視

視線の動きが減少し，ストックを付く位置に視線の方向が当たっているものと考えられ，ストック使用による安定した歩行に寄与しているものと推察できた．

3.3 荷重分散と筋力の消耗低減

ストックの使用により二足歩行から四足歩行に近い歩行動作となるため，被験者自身の体重を含めた荷重の分散と筋力の消耗低減によって，被験者の循環器系器官に対する負担が減少した可能性が示唆された．

3.4 登山経験の識別可能性

登山初心者の場合，下山時の Y 軸方向（前後）の加加速度の標準偏差が小さかったことから，登山熟練者に比べて，前方向への踏み込みが弱かったのではないかと推測された．

4. 本研究の目的

前報での知見をふまえて，下りにおける着地強度の軽減および登山経験の識別可能性に注目し，登山歩行時のストックにかかる圧力および加速度を計測できる脱着可能なセンサを試作した．

本報では，試作品を用いた実地環境におけるデータの計測と分析を通じて，試作品の評価および今後の研究課題について整理することを目的とする．

5. 試作品開発

5.1 全体像

試作品の全体像を図 1 に示す．



図 1 試作品の全体像

5.2 試作品開発の目的

今回，試作品を開発した目的は，登山中の疲労度合いや歩行バランスの調整に対する「ストックの使い方の変化」を計測することである．そして，将来的には，計測した結果から推定される疲労や歩行の状態をユーザ（登山者）にフィードバックし，登山中に発生しうる事故やケガを未然に防止できる機器へと発展させることを考えている．

5.3 機能概要

試作品は圧力と加速度を計測できる計測部および計測されたデータを収集・蓄積する制御部に分かれている．またストックの形状（太さ）や長さの違いにも対応できるように，各計測部とデータ制御部は，ストックに着脱できるようにした．なお，ストック自体はすでに市場で流通しているものを採用した．

試作したセンサは，圧力センサ，加速度センサ，データ制御装置からなる．以下に各部について説明する．

①圧力センサ

ストックにかかる圧力を計測でき，先端部分（最下部）に装着可能な圧力センサを試作した．登山道の環境変化以外にも，登山者の疲労具合や熟練度に応じて，先端部分にかかる圧力が変化するものと考えた．登山道は，登りと下りの違い以外にも，木階段やザレ場（おもに砂礫の道），ガレ場（おもに岩場の道），降雨・積雪の有無などによって，その環境が大きく変わる．

②加速度センサ

圧力同様に，加速度にも変化があると考え，ストックに装着可能な加速度センサを試作した．試作品では先端部分に1つ，データ制御装置内に 1 つの合計 2 つの加速度センサがある．

③データ制御装置

圧力センサおよび加速度センタが検知した信号を収集し，MicroSD カード内に CSV ファイルを生成することでデータを蓄積する制御機能を有する．

6. 評価実験

6.1 被験者

被験者 1 名（45 歳，男性）が評価実験を実施した．なお，被験者は年間山行 20～40 日程度の登山熟練者であり，本稿の著者でもある．

6.2 実験方法

被験者に眼鏡型端末および腕時計型端末を装着し，両手に試作品を各 1 本ずつ持った状態で評価実験を 2 回実施した．

（実験器材）
- ・試作品：Caravan 社製トレッキング用ストック
- ・眼鏡型ウェアラブル端末：JINS MEME ES
- ・腕時計型ウェアラブル端末：Fitbit Surge

（評価実験①）
- ・日付：2018 年 2 月 24 日（土）
- ・ルート：小仏バス停～景信山山頂（往復）
- ・時間：14 時 38 分～16 時 18 分
- ・天候：晴れ 気温：14.2℃
- ・距離（往復）：5.3km 標高差：430m
- ・体重：73.6kg ザックの重量（荷重）：7.8kg

（評価実験②）
- ・日付：2018 年 3 月 3 日（土）
- ・ルート：大倉バス停～花立山荘（往復）
- ・時間：11 時 02 分～15 時 17 分

・天候：晴れ，気温：14.8℃
・距離（往復）：12.8km　標高差：1,006m
・体重：73.4kg　ザックの重量（荷重）：8.9kg

7. 実験結果

7.1 ウェアラブル端末からのデータ計測

眼鏡型端末および腕時計型端末から得られた評価実験①・②の計測結果を図 2・図 3 に示す．

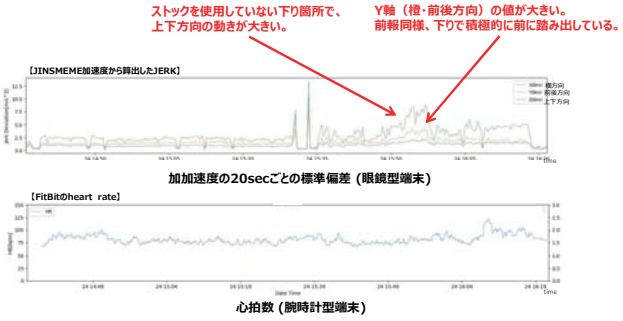


図 2　評価実験①（ウェアラブル端末）

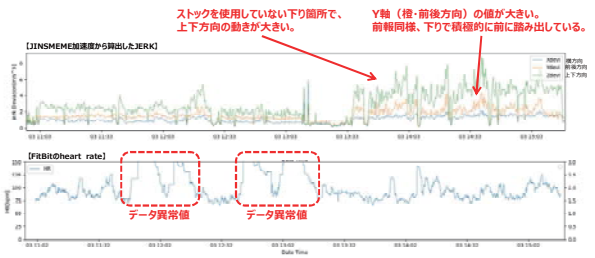


図 3　評価実験②（ウェアラブル端末）

7.2 試作品からのデータ計測

試作品から得られた評価実験①・②の計測結果を図 4・図 5 に示す．なお，評価実験①において，左側ストックの圧力センサおよびデータ制御装置に不具合が発生し，圧力センサからのデータが不正確であったため，両図とも右側ストックの計測結果を示す．

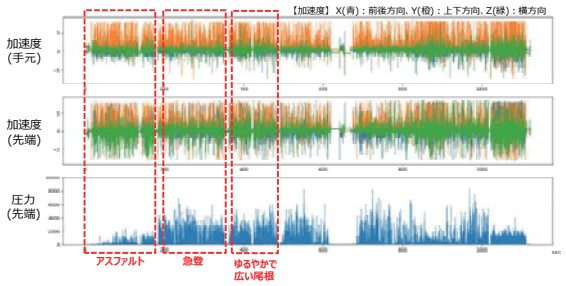


図 4　評価実験①（試作品）

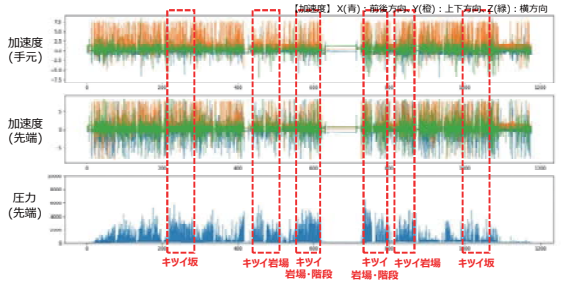


図 5　評価実験②（試作品）

つぎに評価実験①の「ゆるやかな広い尾根」における任意地点の計測結果を図 6 に示す．ストックを接地し，持ち上げ，前方に移動する一連の動作が計測できた．同じく評価実験①の「急登」における任意地点の計測結果を図 7 に示す．

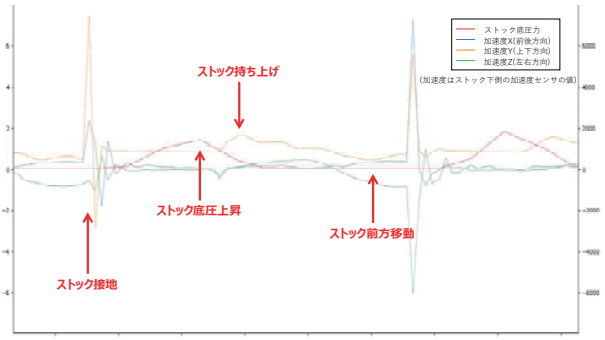


図 6　ゆるやかな広い尾根でのストック動作

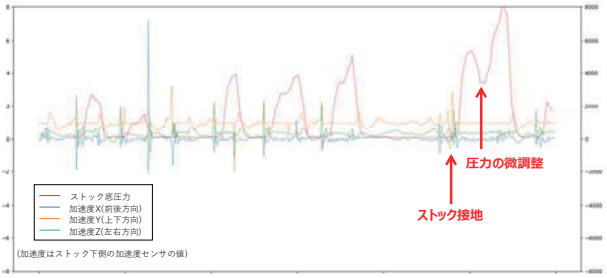


図 7　急登でのストック動作

さらに，評価実験①の「ゆるやかな広い尾根」における登りと下りのストック動作の差異を図 8 に示す．

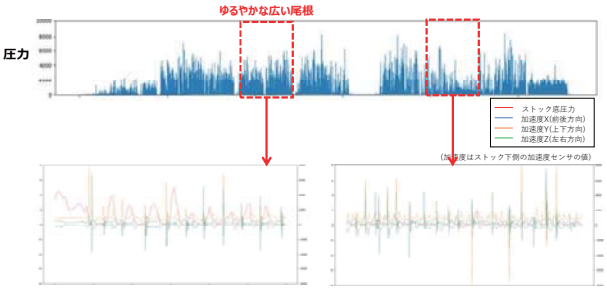


図 8　登りと下りのストック動作の差異

8. 考察

8.1 実地環境（フィールド）におけるデータ計測

本実験においても，実際の登山道（登山口～山頂までの往復）という条件が安定しない実地環境（フィールド）で，ウェアラブル端末（眼鏡型・腕時計型）からのデータ計測とともに，試作品の加速度センサおよび圧力センサからもデータを計測できることを確認した．

前報同様に，今回の評価実験でも被験者の Y 軸（前後方向）の値が大きく，下りで積極的に前に踏み出していることが再確認できた．

8.2 ストック動作の可視化

加速度センサおよび圧力センサから「ストックの接地⇒圧力上昇⇒圧力が抜けるとすぐにストックを上方移動⇒身体を前方移動」というストックを用いた場合の一連の歩行動作を可視化することができた．とくに急登（図 7）の場合には，ストックを接地させたあと，ストックへの力のかけ方を変更し，歩行バランスを調整することで，安全確保を意図した動作であると推測できる．

また，“加速度の大きさと圧力には相関がなく，ストックにかかる圧力は圧力センサでないと計測できない”ことが確認された．

8.3 登山道の傾斜・状態に対するストック効用の差異

図 8 に示すとおり，同じ場所を歩いていても，登りと下りではストックの効用に違いがあることが分かる．登りでは，ストックにかかる圧力が大きいため，ストックを使って前方への推進力を得ていると推測できる．一方，下りでは，ストックにかかる加速度（衝撃）が大きいにも関わらず，ストックにかかる圧力が小さいため，ストックは歩行バランスを安定させるための補助機能を果たしていると考えられる．

さらに，加速度より，接地の衝撃で現れる波形を抽出し，圧力と比較した．接地の衝撃 F は，質量（ストック荷重＋体重＋荷物荷重）と加速度に比例すると考えられる（F=m*a）．今回は被験者が 1 名であり，同じストックを使用していることから，質量はほぼ一定であるとし，接地時の加速度の大きさのみで衝撃を評価することとした．接地の衝撃は，3 軸加速度の合成値にハイパスフィルタ（fc=40Hz）と全波正流を実施し，抽出した（図 9）．図 10・図 11 は，評価実験①・②におけるストックの接地の衝撃と，かかる圧力を示す．前述のとおり，登りや下り，登山道の状態によってストックの使い方を変えていることが確認できる．

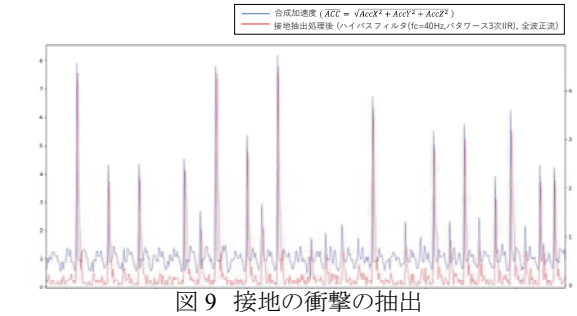


図 9 接地の衝撃の抽出

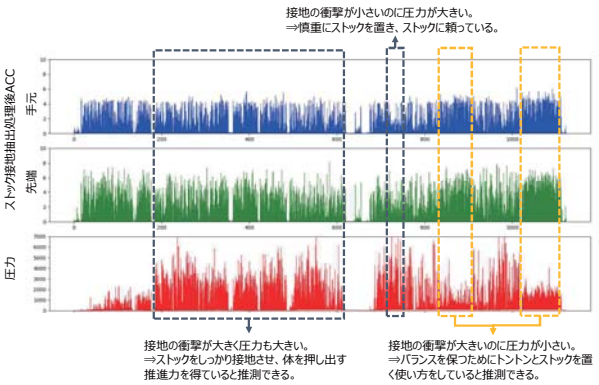


図 10 衝撃と圧力の関係（評価実験①）

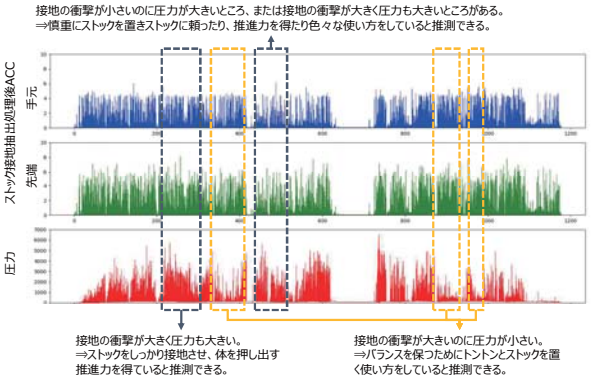


図 11 衝撃と圧力の関係（評価実験②）

9. まとめ

ウェアラブル端末（眼鏡型・腕時計型）および試作品の双方で，実際の登山道における登山者の歩行データを計測することができ，登山者の生体情報や歩行状態をモニタリングできることが示された．

さらに評価実験の結果，「ストック動作の可視化」および「登山道の傾斜・状態に対するストック効用の差異」について，新たな知見を得ることができた．加速度とストックにかかる圧力の関係から，登りでは前方への推進力を得るため，下りでは歩行バランスを安定させるために，ストックを利用することが定量的に評価できる可能性が得られた．

10. 今後の研究活動

今後は，①統制可能な実験環境（階段やトレッドミル等）における斜度・荷重・疲労具合等の差異，②被験者数の増加，③性別・年齢・体格等の身体的特性の差異，④登山の熟練者と初心者における技能・技術の差異にそれぞれ配慮した精緻な実験を行う予定である．また，ストック先端部分にある圧力センサの強度増加やデータ計測動作中の視覚的表現の実装，GPS による位置情報の把握，Bluetooth 経由でのスマートフォン連携等による試作品の構造的・機能的な改良を実施していく計画である．さらに，計測されたデータから個人ごとの特徴量を抽出し，登山者本人に対する効果的なバイオフィードバックの手法についても検討を重ねていきたい．

参考文献

[日本 2017] 日本生産性本部: レジャー白書 2017, 2017.

[警察庁 2017] 警察庁生活安全局地域課: 平成 28 年における山岳遭難の概況, 2017.

[国交省 2014] 国土交通省: G 空間社会における山岳遭難防止対策モデル構築事業, 2014.

[三部 2012] 三部剛義: NFC を利用した登山者間 DTN の構築, 慶應義塾大学大学院, 2012.

[東京都 2016] 東京都山岳連盟救助隊・日本山岳救助機構合同会社: ドローンによる山岳遭難捜索技術開発報告書, 2016.

[山本 2016] 山本正嘉: 登山の運動生理学とトレーニング学, 東京新聞出版局, 2016.

[岡本 2015] 岡本卓也・藤原武弘: 登山行動に関する社会心理学的研究, 関西学院大学社会学部紀要, 2015.

[林 2011] 林綾子・金森雅夫: 北アルプス登山者の登山前・中・後にわたる免疫能・心理的変化, びわこ成蹊スポーツ大学研究紀要第 8 号, 2011.

[井出 2016] 井出里香・五島史行・吉田泰行: 富士山頂において歩行バランスに与える影響, 第 36 回日本登山医学会学術集会, 2016.

[坂口 2017] 坂口憲一・大海悠太・山本正彦・椙本涼太・工藤裕・仲山加奈子: 登山道における歩行バランスと着地強度の計測と評価, SIG-KST 第 32 回研究会, 2017.

Oral presentation | Organized Session | [Organized Session] OS-14

[3C2-OS-14b] [Organized Session] OS-14

Thu. Jun 7, 2018 3:50 PM - 5:30 PM Room C (4F Orchid)

[3C2-OS-14b-01] Social Responses of a Robotic Salesperson Based on the Engagement of Visitors

Jian Zhou[1], Masaya Iwasaki[1], ○Yen-Ru Chin[1], Michelle Geilenberg[1], Mizuki Ikeda[1], Tatsuyuki Kawamura[2], Hideyuki Nakanishi[1] （1. Department of Adaptive Machine Systems, Osaka University, 2. Kyoto Innovation, Inc.）

3:50 PM - 4:10 PM

[3C2-OS-14b-02] Enhancing the Lingering Presence of Remote Speakers by Visual Morphing in Telepresence Robot.

○Hirokazu Yoshida[1], Fumihide Tanaka[1] （1. University of Tsukuba）

4:10 PM - 4:30 PM

[3C2-OS-14b-03] Consideration of Group Discussion Participating Robot Autonomously Performing Head Movement

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

4:30 PM - 4:50 PM

[3C2-OS-14b-04] Predicting User’ s Interest Level in Dialogues with Multimodal Features

○Haruto Nishimoto[1], Kazunori Komatani[1] （1. The Institute of Science and Industrial Research (ISIR), Osaka University）

4:50 PM - 5:10 PM

[3C2-OS-14b-05] Analysis of Influence of Turn-taking by Mutual Action Between Non-speaker

○Takashi Makino[1], Yoshinari Takegawa[1], Keiji Hirata[1] （1. Future University Hakodate）

5:10 PM - 5:30 PM

©The Japanese Society for Artificial Intelligence

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

訪問客のエンゲージメントに基づいた接客ロボットの社会的応答

Social Responses of a Robotic Salesperson Based on the Engagement of Visitors

周 剣[*1] Jian ZHOU　岩﨑 雅矢[*1] Masaya IWASAKI　金 延儒[*1] Yen-Ru CHIN　ミシェル ガイレンベルグ[*1] Michelle GEILENBERG

池田 瑞[*1] Mizuki IKEDA　河村 竜幸[*2] Tatsuyuki KAWAMURA　中西 英之[*1] Hideyuki NAKANISHI

[*1] 大阪大学大学院工学研究科 知能・機能創成工学専攻 Department of Adaptive Machine Systems, Osaka University　[*2] 京都イノベーション株式会社 Kyoto Innovation, Inc.

In recent years, customer service robots have been rapidly deployed. However, it is still unclear what kind of behavior is effective for sale. A conversation cannot be initiated, if the customers are not interested in the robot. Therefore, in this paper, we focus on engagement in the field of Human-Robot Interaction (HRI). In order to produce socially intelligent responses, we introduce a machine learning method to calculate a degree of engagement by analyzing the data which we conducted a field experiment in a real shop. As a result, we develop a model that the robot can hence decide on a socially intelligent response in the start of the conversation.

1. はじめに

近年，店舗や博物館，学校などの公共の場所においてヒューマノイドロボットが頻繁に用いられている[Stock 17][Niemelä 17]. また，博物館を通して訪問者を案内するために予め定義されたシーケンスを実行するというような研究も存在している[Kuno 07][Shiomi 06]. しかし，そのほとんどの場合，ロボットが行う動作は単純なものに限られている. たとえば，ロボットは，タブレットなどの画面に何度も同じ情報を表示することや，何度も同じ動作を繰り返すことによって，訪問者の注目を集めようとする. このようなロボットは主に情報を提供するために使用されているが，人々と社会的に交流することはないため注意を引くことができず，それらの効果は低いままである. これらはロボットの機能の欠如が原因となっているのではなく，ロボットの社会性の欠如が原因となり引き起こされている. したがって，ロボットは人々からの注目の度合いを理解し，ある一定以上の興味がある時に話しかける必要がある. このような他の参加者と同じ場所に留まり，インタラクションを続けることに起因する値としてエンゲージメントがある[Christopher 05]. そこで我々の研究では接客ロボットが最初に訪問客に対して発言を行う際に，その発言の前に会話の対象となる人のロボットに対するエンゲージメントの程度を分析し，会話を開始するのに十分なエンゲージメントの程度になった時にロボットが呼びかけを行うための反応モデルを設計することを目的とする.

本研究では，実際の店舗での実験によるデータを用いるということに重点を置く. そこで，SoftBank Robotics のヒューマノイドロボット Pepper を用いて京都にある実際の店舗において実験を行った. 実験中の訪問客を観察し，得られたデータに基づいて反応モデルを設計する. 本稿は，まず実際の店舗における実験方法について説明した後，エンゲージメントを測定するための適切な訪問客の非言語的な要因を選択し，Pepper によってこれらを分析する方法を説明する. そして，その要因の評価とエンゲージメントの計算方法，ロボットの社会的応答モデルの設計について記述する.

連絡先：中西 英之，大阪大学大学院工学研究科 知能・機能創成工学専攻，06-6879-4182，nakanishi@ams.eng.osaka-u.ac.jp

2. 関連研究

エンゲージメントの定義とモデルは複数存在している. Christopher によると，エンゲージメントは，あるインタラクションにおける参加者が他の参加者と同じ場所に留まり，インタラクションを継続するという目的に帰着する値として定義される[Christopher 05]. また，Sidner らは直接エンゲージメントを注意に関連付けた[Sidner 05] . 彼らは，エンゲージメントは認識された結びつきを確立し，維持し，終了させるプロセスであると述べた. さらに，エンゲージメントは注意だけではなく，それ以外の要因の影響をも受けると考えられてきた. 他のアプローチとして，Corrigan らは，3 つの異なる種類のエンゲージメントを定義している[Corrigan 13]. すなわち，ソーシャルエンゲージメント，タスクエンゲージメント，ソーシャル-タスクエンゲージメントである. また，Salam らは，エンゲージメントはインタラクションの前後関係に応じて定義する必要があると考えた[Salam 15]. そして，会話の状況や話題に基づいて，エンゲージメントが分岐すると定義した. これらの研究が行われてきたが，エンゲージメントに関する明確な定義はまだ存在していない. しかし，これらから得られる有益な情報は多い.

また，実験室実験では実験室にいるということが人とロボットの間のインタラクションに影響を与えるということが考えられる. 例えば，実験室では，カメラなどで録画されているという意識が



図 1 ロボットと握手をする訪問客

強いため，ロボットに対して失礼な行動などはとらない人が多いが実際のフィールドではそのようなことも観察される可能性がある．このように，実験室実験では観察することができないロボットとの自然なインタラクションを観察するため，実際の博物館での実験[川口 09]や実際の教室での実験[神田 04]が行われている．接客ロボットに関しても様々なその目的に応じた実際のフィールドにおける実験が行われてきた[宮下 08]．しかし，接客ロボットが人のエンゲージメントの程度を分析し，それに応じて行動するような研究はされていない．

3. 実際の店舗における実験

実験中の様子を図 1 に示す．本実験では接客ロボットとして Pepper を用いた．Pepper は，2014 年にソフトバンクモバイル株式会社が開発した人型パーソナルロボットである．Pepper を採用した理由の 1 つ目は Pepper の大きさが，設置しても商品を購入することの妨げにならず，店の外からも目立程度であり，客とコミュニケーションする際にはロボット搭載のタブレットを用いて商品の説明や紹介ができるからである．2つ目の理由は Pepper には赤外線センサ，ソナーセンサなどの多くのセンサを用いた安全装置が搭載されており，非常に安全であるからである．実験をする際，Pepper は周辺にいる人との衝突を回避する機能が備わっている．したがって，至近距離に人がいる場合，手振り身振りの動作における腕の動きが自動的に停止または低速化するようになっている．3つ目の理由はその頭を動かすことによって視線を制御することができ，その腕を使ってジェスチャーとポイントを行うことができるからである．一般販売向けの Pepper は日本語と英語を話すことができ，実験では接客にこの 2 ヶ国語を用いた．

また，今回は京都の商店街にある七味専門店「ぢんとら」において実験を行った．この店舗の見取り図を図 2 に示す．この店舗を入口側から見た図を図3に示す．実験中，訪問客の顔がわからないようにするためピントをずらした 3 つの不鮮明カメラを使用した．1 つ目はロボットの正面側から映したもの，2 つ目はロボットの背面側から映したもの，3 つ目は全体の様子を側面側から映したものである．また，訪問客がロボットに近づくとすぐにロボットに搭載したタブレット端末にタッチ操作によって回答可能な同意書を表示し，訪問客から撮影の同意が与えられた場合のみ，ロボット側面側に設置した鮮明カメラによって，顔を認識可能な映像を取得した．さらに，実験者が実験中にロボットの遠隔操作を行う際店内の様子を観察するために，ビデオ通話をつないだタブレットを店内のロボットの後方に設置した．

ロボットの操作はスマートフォンを使って Pepper を遠隔操作できるアプリケーションを開発し，実験者が Wizard of Oz 法[Kelley 84]を使用して行った．Wizard of OZ 法とは，対話システムの開発において効果的なシミュレーション手法である．システムのふりをした人がシステムのかわりにユーザと会話をする．この手法

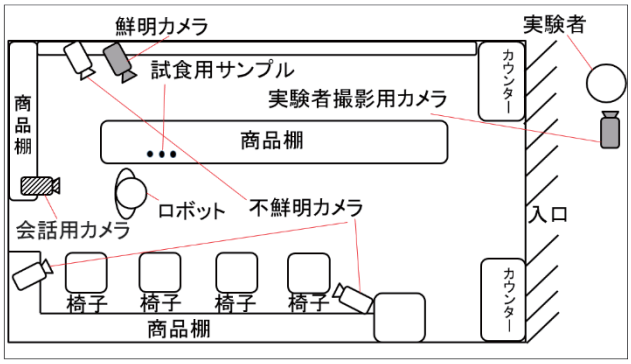


図 2 店舗の見取り図

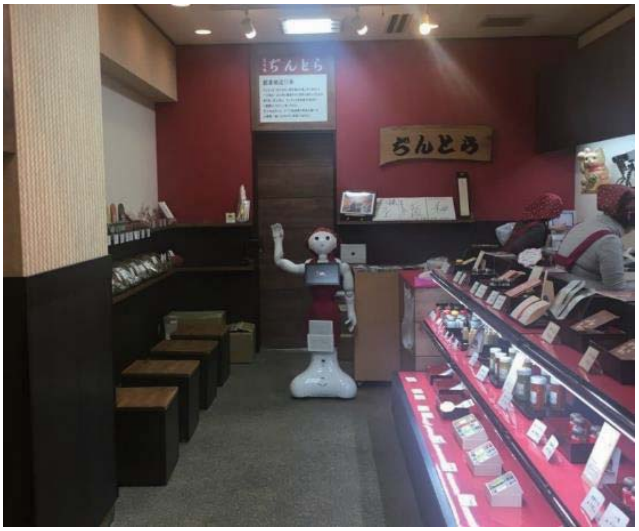


図 3 店舗を入口側から見た図



図 4 ロボット操作用ユーザインタフェース

はシステムに必要な要求や起こりうる問題をあらかじめ知ることができるという利点がある．また，遠隔操作用アプリケーションはスマートフォンを Pepper と同じ無線 LAN 内に接続していれば，Pepper にあらかじめインストールされた行動をとり，入力した言葉を話させることができる．図 4 はそのアプリケーションを示したものである．実験中，Pepper を操作する際にすべての言葉を入力すると，時間がかかり沈黙ができてしまい会話が成り立たなくなる．そこでよく使う一連の言動をあらかじめ Pepper にインストールした．それらの行動は，Pepper のアプリケーションを開発できるソフトウェアである Choregraphe を用いて開発した．実験者は店舗の前にある道の反対側立ち，ロボットと訪問客との間のインタラクションを目視とビデオ通話の映像の両方を用いることによって確認し，訪問客とのインタラクションにおいて適切なロボットの行動を選択した．

実験は 2017 年 4 月 10 日 15:15-16:22，13 日 15:21-16:22，14 日 16:01-17:21，2017 年 8 月 14 日 16:21-17:58，15 日 15:20-16:22，16 日 14:15-15:58 の 2017 年 11 月 27 日 16:08-17:34，12 月 02 日 14:07-16:58，04 日 14:05-17:13，05 日 14:13-16:45 の 10 日間行った．今回の実験では合計 164 組がこの店舗を訪れた．このうち 76 組がロボットと会話を行った．1 組の人数の平平均は 2.2 人であり，約 370 人の訪問客が実験中この店舗を訪れた．

4. エンゲージメントに起因する非言語要因の選択

広く認められた明確なエンゲージメントの定義はまだ提案されていないが，エンゲージメントをモデル化するために複数の先行研究で使用される非言語要因を収集することは可能である．

前述したように，エンゲージメントにはさまざまな要因が含まれている．1 つの一般的な要因は，アイコンタクトである．これは，会話相手に対する注目度における強いサインである[Castellano 14] [Knapp 13]．アイコンタクトや視線の他にも，要因を選択することができる．アイコンタクトをすることで，顔の表情を分析することもできる．また，ロボットに対する反応，例えばうなずきや姿勢なども重要な情報を与えることができる[Knapp 13][Yanco 12]．さらに，ロボットと訪問客の間の距離もエンゲージメントにとって重要な要因である[Michalowski 06] [神田 08]．

今回実験で用いた Pepper は，店舗や家庭での日常生活における人型ロボットコンパニオンとして設計されたものである．このため，レーザーセンサ，超音波ソナーセンサ，タッチセンサ，2 つの 2D カメラと 1 つの 3D カメラが搭載されており，位置や行動，声を検知することが可能である．また，それらだけでなく，幸福感，怒り，恐怖感などの人間の感情をも認識することが可能である．実際の店舗において訪問客を分析するためには，その訪問客を区別し，個々に関するデータを収集する必要がある．これを行うために，Pepper の顔認識機能を使用する．これはそれぞれの People ID によって固有の顔の特性が保存される．まず人について収集されたすべての情報を，People ID とともにロボットのメモリに保存する．そして，そこから People ID に対応する特定の要因の情報を取得し，特定の状況が観察された場合のみ特定の行動をロボットが行うように設計する．

これらより，我々はエンゲージメントの程度を計算するモデルを設計するため，Pepper が提供するツールを用いて分析できるアイコンタクト，アイコンタクト継続時間，距離，接近，笑顔という合計 5 つの非言語要因を選択した．次の章でこれらの非言語要因の選択の妥当性を検証するため，エンゲージメントと各要因の相関を計算する．

5. データ分析と考察

実際の店舗における実験のビデオを使用してデータを収集した．この実験の際に 164 組の訪問客が店を訪れた．今回はロボットから発言する場合を考えるため，我々は，ロボットが最初に発言を行った 153 人の訪問客について，訪問客が入店してからロボットが訪問客に対して最初の発言を行うまでの訪問客の行動をデータとして用いて統計を行う．

アイコンタクトは X1 と表すバイナリデータである．例えば，ロボットが訪問客に挨拶したときに訪問客がロボットを見ていた場合，X1 の値は 1 となる．アイコンタクト継続時間は X2 として表す線形データであり，入店から挨拶までのロボットと訪問客がアイコンタクトを行った秒数である．距離は，X3 として表す線形データである．ここでは，ロボットから店舗の入り口までの範囲を 5 つに分割し，ロボットが挨拶をしたときに訪問客がどの範囲に位置するかを距離として定義する．例えば，訪問客がロボットの横に立っている場合，距離は 0 であり，訪問客が入り口に立っている場合，距離は 4 である．接近の定義は，ロボットが初めて挨拶をしたときに訪問客がロボットに接近するかどうかであり，X4 と表すバイナリデータである．訪問客がロボットに接近した場合，X4 の値は 1 である．笑顔は X5 と表すバイナリデータである．これは，ロボットが挨拶をしているときに訪問客が笑っているかどうかとして定義した．ロボットが挨拶をしているとき，訪問客が笑っている場合，X5 の値は 1 である．最後に，訪問客がロボットとコミュニケーションを開始したかどうかを Y としてバイナリデータで表す．訪問客がロボットと会話を開始した場合，Y の値は 1 である．以上のパラメータを用いて，表 1 に例として 5 つのグループ訪問客のデータを示す．

表 1　訪問客の各データの例

訪問客のId	Y	X1	X2	X3	X4	X5
41001	1	1	15	3	1	1
41002	1	1	5	1	1	0
41003	1	1	20	1	0	1
41004	1	1	6	1	1	0
41005	0	0	0	1	0	0

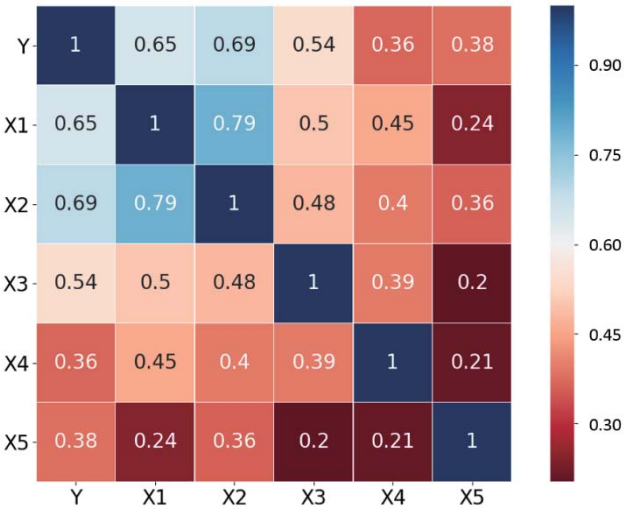


図 5　Y と各 X の相関係数（Y：エンゲージメント，X1：アイコンタクト，X2：アイコンタクト継続時間，X3：距離，X4：接近，X5：笑顔）

図 5 はそれぞれの変数の間の相関係数を示しており，横軸と縦軸が各変数を表している．相関係数は-1 から 1 の間の値になり，1 に近い方が強い正の相関があることを示し，-1 に近い方が強い負の相関があることを示す．これらを見ると，全ての変数において負の相関がなく，互いにある程度の正の相関があることが分かる．したがって，エンゲージメントに起因する非言語要因としてのこれらの選択は妥当であると言える．また，アイコンタクトとアイコンタクト継続時間がエンゲージメントにとって他の要素に比べて，より重要な要因であることが確認できる．

6. 社会的反応モデルの開発

データを分析するため，今回は簡単のため機械学習手法，ロジスティック回帰を使用する．式 5.1 および式 5.2 はロジスティック回帰における数式を示している．

$$Y = \frac{1}{1+e^{-z}} \tag{5.1}$$

$$Z = W^T X + b \tag{5.2}$$

W が重みであり，b はバイアスである．コスト関数を最小化することによって，最適化された重みを得ることができる．表 2 は最適化した重みのパラメータを示している．また，バイアスのパラメータは-0.19654401 であった．

このデータに用いた 153 人の訪問客に対して 5 分割交差検定を行った．5 分割交差検定では，データを 5 つに分割し，訓練 4，テスト 1 の比率で行った．交差検定の結果，88.9%の正確率で訪問客のエンゲージメントを測定できた．

表 2 重みの最適化パラメータ

要因	重み
アイコンタクト	0.53
アイコンタクトの継続時間	1.35
距離	0.99
接近	-0.17
笑顔	1.20

したがって，これらのパラメータを使用して，ロボットの社会的反応モデルを開発することができる．このモデルをロボットにインストールし，タイマーを設定してモデルを何度も繰り返し使用することで，ロボットは訪問客のエンゲージメントをリアルタイムに測定することができ，ある一定以上のエンゲージメントを持つ訪問客に対して，呼びかけるなどの接客方法を選択することができる．今回はロボットが最初に発言する場合のみを考えたため，訪問客から話しかけられる場合を考慮していない．実際の店舗においてこのモデルを使用する際にはこの訪問客が最初に発言を行う場合も考慮しなければならない．しかし，最初に訪問客が発言した場合は，ロボットはその発言に対して返答すればよいため，このモデルと組み合わせることは十分可能であると考えられる．

今後の研究では，このモデルを実店舗で試験し，再現性を調査しなければならない．そして，より多くの訪問客のデータを用いて評価し，また他の要因についても調査する必要がある．

7. おわりに

今回は接客ロボットが訪問客に最初に挨拶などの発言をする際，訪問客のエンゲージメントに基づいて社会的に発言するための反応モデルを設計することを目的とした．そして，実際の店舗における訪問客を観察することによって得られたデータに基づき，ロジスティック回帰を用いてロボットの社会的反応モデルを開発した．このモデルは実際の店舗における実験データにおいて高い正解率を持っており，このモデルを用いれば，ロボットは会話を開始するのに十分なレベルのエンゲージメントを持つ訪問客に対して挨拶を行うことができ，ロボットが行う様々な接客方法に対する訪問客の注意を引くことができると考えられる．本研究は，訪問客のエンゲージメントに応じて返答する接客ロボットの反応モデルを実際の店舗における訪問客の観察データに基づいて設計したという点で HRI 分野に対して大きく貢献していると考えられる．

謝辞

本研究を遂行するにあたり，京七味専門店ぢんとらの皆様には実験場所の提供および実験における多大な協力を頂きました．心より厚く御礼申し上げます．

参考文献

[Stock 17] R. Stock, and M. Merkle, “A Service Robot Acceptance Model: User Acceptance of Humanoid Robots During Service Encounters.” Pervasive Computing and Communications Workshops (PerCom Workshops), 2017 IEEE International Conference on. IEEE, pp. 339-344, 2017.

[Niemelä 17] M. Niemelä, P. Heikkilä, and H. Lammi, “A Social Service Robot in a Shopping Mall: Expectations of the Management, Retailers and Consumers.” Proceedings of the Companion of the 2017 ACM/IEEE International Conference on Human-Robot Interaction. ACM, pp. 227–228, 2017.

[Kuno 07] Y. Kuno, K. Sadazuka, M. Kawashima, and K. Yamazaki, “Museum Guide Robot Based on Sociological Interaction Analysis.” Proceedings of the SIGCHI conference on Human factors in computing systems. ACM, pp. 1191-1194, 2007.

[Christopher 05] P. Christopher, et al. “Engagement capabilities for ecas.” AAMAS’05 workshop Creating Bonds with ECAs, 2005.

[Sidner 05] C. L. Sidner, C. Lee, C. D. Kidd, and N. Lesh, “Explorations in Engagement for humans and robots.” Artificial Intelligence, 166(1-2), pp. 140-164, 2005.

[Shiomi 06] M. Shiomi, T. Kanda, H. Ishiguro, and N. Hagita: “Interactive humanoid robots for a science museum.” HRI’06 Proceedings of the 1st ACM SIGCHI/SIGART conference on Human-robot interaction, pp. 305-312, 2006.

[Castellano 14] G. Castellano, I. Leite, A. Pereira et al.: “Context-Sensitive Affect Recognition for a Robotic Game Companion.” ACM Transactions on Interactive Intelligent Systems, vol. 4, no. 2, pp. 1–25, 2014.

[Corrigan 13] L. J. Corrigan, C. Peters, and G. Castellano, “Social-Task Engagement - Striking a Balance between the Robot and the Task.” Embodied Commun Goals Intentions Workshop ICSR, Vol. 13, pp. 1-7, 2013.

[Salam 15] H. Salam and M. Chetouani: “A multi-level context-based modeling of engagement in Human-Robot Interaction.” in 2015 11th IEEE International Conference and Workshops on Automatic Face and Gesture Recognition (FG), pp. 1–6, 2015.

[Knapp 13] M. L. Knapp, J. A. Hall, and T. G. Horgan, “Nonverbal communication in human interaction.” Cengage Learning, 2013.

[Yanco 12] H. Yanco, “Personalization in HRI: A Longitudinal Field Experiment.” Proceedings of the seventh annual ACMIEEE international conference on Human-Robot Interaction, pp. 319–326, 2012.

[Kelley 84] J. F. Kelley, “An iterative design methodology for user-friendly natural language office information applications.” ACM Transactions on Information Systems (TOIS), Vol. 2 No. 1, pp. 26-41, 1984

[Michalowski 06] M. P. Michalowski, S. Sabanovic, and R. Simmons, “A Spatial Model of Engagement for a Social Robot.” Advanced Motion Control, 9th IEEE International Workshop on, pp. 762-767, 2006.

[川口 09] 川口 一画，葛岡 英明，鈴木 祐也，中尾 誉，山下 淳，カローラピッチ，山崎 敬一: ロボットの発話途中の沈黙と言い直しによる人の注意誘導，日本バーチャルリアリティ学会論文誌, Vol. 14 No. 3. pp. 257-264, 2009.

[宮下 08] 宮下 善太，神田 崇行，塩見 昌裕，石黒 浩，萩田 紀博，“顧客と顔見知りになるショッピングモール案内ロボット．” 日本ロボット学会誌，Vol. 26 No.7, pp.821-832, 2008.

[神田 04] 神田 崇行，石黒 浩，“対話型ヒューマノイドロボットからの日常生活の中の友達関係の推定．” 情報処理学会論文誌，Vol. 45 No.8, pp. 2098-2104, 2004.

[神田 08] 神田 崇行，“ロボットメディアによる人間情報処理研究: 4. コミュニケーションロボットと人間との距離．” 情報処理，Vol. 49 No.1, pp. 24-29, 2008.

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

テレプレゼンスロボットにおけるモーフィングを用いた存在感の余韻強化の試み

Enhancing the Lingering Presence of Remote Speakers by Visual Morphing in Telepresence Robot.

吉田 寛和[*1] Hirokazu Yoshida
田中 文英[*2] Fumihide Tanaka

[*1] 筑波大学 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
Faculty of Engineering, Information and Systems, University of Tsukuba

Telepresence robot can give a sense such like remote person is really existing there. However, this sense is suddenly disappeared after the call. Therefore, the talker will feel loneliness. This research explores "tele-vestige" in which talkers can feel weak presence even after a call finish. To give this "tele-vestige", remote person's face is morphed to a telepresence robot's face after the call. We tested a pilot experiment to investigate the effect of this morphing on loneliness.

1. はじめに

テレビ電話のような遠隔通信メディアの普及により、遠隔地間でもコミュニケーションが容易に行えるようになってきた。対面と同等のコミュニケーションを実現するには未だに至っていないが、それを補う技術として近年注目されているのが物理的な身体を持ったテレプレゼンスロボットである[大塚 2013]。テレプレゼンスロボットはディスプレイ表示やジェスチャによって、遠隔者だけでなく、相手である通話者にも遠隔者がその場にいるかのような存在感を感じさせることができる[妻木 2012]。

しかし、テレプレゼンスロボットは通話が終了すると、遠隔者を特定できる要素がなくなり、遠隔者の存在感が急激に消失してしまう。この急激な存在感の変化が、通話者に通話終了後の寂しさをより顕著に感じてしまうのではないかと考えられる。

本研究は、通話が終了した直後に遠隔者の存在感を希薄しながら通話者に提示することで、存在感に「余韻」を残し、テレプレゼンス終了後の寂しさを軽減することを目的としている。その手法として、通話を終了する際に、遠隔者を特定できる特徴を、ロボットの対応する特徴と混ぜ合わせながら通話者に提示する。本稿では、遠隔者を特定できる要素として顔に注目し、通話終了後に人の顔とロボットの顔を混ぜ合わせながら切り替えを行う。

2. 関連研究

一時的に存在感や臨場感が消失する問題を解決する研究は多くある。テレプレゼンスシステムの多くは遠隔者の映像を平面ディスプレイに表示するため、通話者がディスプレイの正面にいない場合に、存在感が消失してしまう。この問題を解決する手段として、ディスプレイの形状を特殊なものに変えるということがあげられる。SphereAvatar[Oyekoya 2012]は、球面ディスプレイを使用し、顔を球面全体に表示することで、どの位置からでも遠隔者を見ることができる。しかし、バーチャルアバターの映像を使用しており、人間の顔を表示した際に存在感を感じさせることができるかの調査は行っていない。遠隔者の存在感をより高めるために、三澤らは人の顔形状のスクリーンに遠隔者の顔を表示するテレプレゼンスシステムである LiveMask[三澤 2012]を開発した。顔形状のスクリーンは 3D スキャナーを用いて得られたデータをもとに 3D プリンタによって作成しているため、通話が終了した後も遠隔者を特定できる要素は残っている。しかし、通話終了後の存在感についての調査は行っていない。

身体性を工夫した存在感の研究も行われている。ChameleonMask[Misawa 2015]では iPad air と HMD から構成されるヘルメットを代理人となる人間がかぶり、遠隔者の顔を iPad air の画面に表示するテレプレゼンスシステムを提案している。このシステムでは、代理人に遠隔者と同じような体形の人間を使用し、人間を特定するための主要要素である顔をマスクのように装着することで遠隔者の存在感を提示し、通話者に装着している代理人があたかも遠隔者であるように感じさせることができたことを報告している。しかし、代理人がマスクを外すと存在感が急激に消失してしまい、遠隔者がこの場にいないことを感じさせてしまう。

本研究のように遠隔者の存在感を継続することを目的とした研究も行われている。田中らはテレプレゼンスモードから自律モードに切り替わる際のギャップが存在感の低減になることを明らかにし、自律システムが遠隔者を装って通話することによって、このギャップが軽減されることを報告している[田中 2015]。本研究は遠隔者とはっきりわかる状態からの切り替えを行い、存在感を残すことを目的にしているという点においてこの研究と異なっている。

3. 切り替え方法

存在感に余韻を残すためには、テレプレゼンスモードから自律モードへの切り替えが急激に行われるのではなく、遠隔者を特定できる要素とロボットのそれに対応する要素を混ぜ合わせながら徐々に切り替わっていくことが必要であると考えられる。本研究では、遠隔者を特定できる要素として、顔を選択し、2 つの顔を混ぜ合わせながら切り替えるためにモーフィングを使用する。モーフィングとは、映像技術で使用される変形手法[藤代

連絡先：吉田寛和，yoshida@ftl.iit.tsukuba.ac.jp

2015]で、画像を切り替える際に特徴点をもとに画像の形状を変化させながら画素値も変化させる手法である。以下にその手順を示す。

3.1 顔画像の取得

ロボットの頭部に表示する遠隔者の顔は遠隔地に設置したカメラを用いて取得する。本研究では Microsoft LifeCam Studio を使用する。カメラ画像の取得には、OpenCV 2.4.13.5 を使用する。

3.2 特徴点の取得

遠隔者の顔画像とロボットの顔画像間の対応点を取得するために特徴点の取得を行う。人間の顔特徴点の取得には、C++向けのツールキット Dlib に用意されている HOG と SVM を用いた検出器を使用する。取得できる特徴点の数は 68 個である。

ロボットの顔画像ではこの顔検出器が使用できないので、人手であらかじめ特徴点を指定した。人間の顔の特徴点との対応付けを行うために、こちらも特徴点の数は 68 個である。

3.3 正規化

2 次元画像では、カメラから顔までの距離が変化することで画像中における顔の大きさも変化してしまう。そこで、3.2 で取得した特徴点をもとに、遠隔者の顔の高さと幅をロボットの顔の高さと幅に正規化する。

3.4 モーフィング

モーフィングによる顔の変形は、顔を単純な形状に分割し、それらを変形することによって行う。本研究ではドロネー分割によって顔を三角形に分割する。画像 1 における特徴点のx座標x_1から画像 2 における特徴点のx座標x_2への変形において、混合率α ($0 \leqq \alpha \leqq 1$)のとき、モーフィング画像における特徴点のx座標x_Mは以下の式によって求められる。

$$x_M = (1-\alpha)x_1 + \alpha x_2 \tag{1}$$

y座標も同様に、

$$y_M = (1-\alpha)y_1 + \alpha y_2 \tag{2}$$

これによって移動した特徴点を基準に、分割した三角形をアフィン変換することで顔全体を変形する。これと同時に画素値の混合率も変化させる。混合率α ($0 \leqq \alpha \leqq 1$)における点(x, y)の画素値$I_{M(x,y)}$は以下の式によって求められる。

$$I_{M(x,y)} = (1-\alpha)I_{1(x,y)} + \alpha I_{2(x,y)} \tag{3}$$

これらの処理によって得られた画像をロボットの顔として表示する。

4. 実験内容

モーフィングを用いた手法が寂しさの軽減に有効であるか検証をするために、実験を行った。実験では、実験者が遠隔者に、実験参加者が通話者にあたる。実験は 20 代の学生 7 名に協力していただいた。

4.1 使用ロボット

ロボットには、SoftBank Robotics 社の Pepper を使用する。Pepper のディスプレイは頭部ではなく胸部に搭載されているので、本実験に使用すると顔が 2 つになってしまい、実験参加者に違和感を与えてしまうことが考えられたので、Pepper の頭部にディスプレイを搭載するための外装を作成した。外装を取り付けたロボットの画像を Fig.1 に示す。ディスプレイには Surface を使用する。外装を取り付けることで Pepper のカメラが使用できなくなり、実験者が実験室の様子を見ることができなくなってしまうため、Pepper の頭部の上に USB カメラを取り付ける。使用カメラは Microsoft LifeCam Studio である。顔画像の送受信は UDP 通信によって行う。音声の送受信には Skype を使用する。ロボットの発話は Choregraphe2.5.5 の say モジュールを使用して発話したものを録音し、再生したものを Skype で送信する。

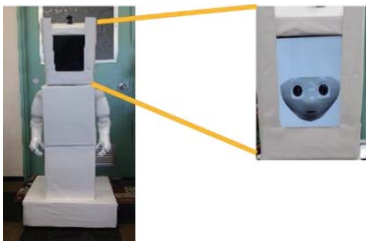


Fig.1: 外装を取り付けた Pepper

4.2 実験条件

実験条件は以下の 3 つで行う。

A) 切断条件: テレプレゼンス終了後、人間の顔がすぐにロボットの顔に切り替わる。
B) フェード条件: テレプレゼンス終了後、人間の顔が徐々に薄くなり、ロボットの顔が徐々に表れてくる(変形は行われない。)
C) モーフィング条件: テレプレゼンス終了後、人間の顔をロボットの顔にモーフィングしながら切り替わる。

A はベースライン条件として行う。B は C による効果が式(3)のみではないことを確認するために行う。

B、C の切り替わりに要する時間は約 20 秒である。実験は参加者内配置で行う。順序効果を考慮して実験参加者ごとに条件の順番を入れかえる。

4.3 実験手順

実験は以下の手順で行う。

1. 実験参加者は実験者とともに実験室に入り、椅子に座ってもらう。
2. 実験参加者には、アンケートに回答してもらう。アンケート回答終了後、実験参加者にしばらく待機するように伝え、実験者は実験室を出て別室に移動する。
3. 実験者が実験室を出た約 1 分後にロボットが「電話が来たみたいです」と発話し、テレプレゼンスモードに切り替わる。この際、画面はすぐに遠隔者の顔に切り替わる。
4. 実験参加者はロボットを介して実験者とともにタスクを行う。タスクとして、実験参加者には実験者と Yes・No ゲームをしてもらう。Yes・No ゲームは以下のルールで行われる。
   ・プレイヤー人数:2 人
   ・1 人が出題者、もう 1 人が回答者となる。出題者は問題を出し、回答者はその答えを考える。

・問題はあらかじめ選択肢が用意されたものを使用する。選択肢にはイラストと名称が記載されており、出題者はその中から答えを 1 つ決める。
・出題者が答えを決めたら、回答者はそれが何かを当てるために質問をする。出題者は質問に対して「はい」または「いいえ」で返答する。「いいえ」の場合は、回答者の質問内容に関連したヒントを出す。
・答えは必ずしもイラストの通りでなくてもよい。ただし、嘘の返答をしてはいけない。
・質問によるやり取りを 3 回繰り返した後、回答者が回答する。正解した場合は回答者の勝ち、不正解の場合は出題者の勝ちとなる。

このゲームを 3 回行う。本実験では実験参加者を出題者、実験者を回答者とする。回答後の正誤の判定に対して実験者は単調的な反応をする。

5. タスク終了後、実験者は実験参加者に自分も実験室へ戻ることを伝え、通話を終了する。終了の際に、ロボットは切り替え手法を実行する。ただし、実際に終了するのは実験者の顔画像の表示と声の出力のみで、実験者は実験参加者側のカメラ映像と音声を確認できる。
6. 切り替え終了から約 30 秒後にロボットが「アンケートに記入をお願いします」と発話する。実験参加者にはアンケートに記入してもらう。アンケート記入後、実験参加者には記入が終わったことをロボットに伝えてもらう。記入が終わったことを確認した後、実験者は実験室に戻る。
7. 1～6 の手順を他の2つの条件でも行う。

各条件における実験参加者の心的状態の変化を調査するため、アンケートには一時的気分尺度 TMS（Temporary Mood Scale）[徳田 2011]を使用する。TMS は「活気」、「疲労」、「怒り」、「抑うつ」、「緊張」、「混乱」の 6 つの下位尺度において今現在の気分変化を評定するアンケートである。アンケートの回答形式は「1. 全くあてはまらない」から「5. 非常にあてはまる」の5段階とする。通話前のアンケートでは TMS のみ行い、通話後のアンケートでは TMS と自由記述を行う。各尺度 3 項目の合計値が合計得点となり、通話前後の合計得点の変化量で評価する。

通話終了直後にアンケートを行うと、切り替え手法の違いではなく、タスクのやり取りや画像に対する印象が影響する可能性がある。そのため、画面が切り替わった後に 30 秒間の待ち時間を設定する。

実験を行うにあたり、以下の仮説を立てた。

仮説 1: 切断条件における「抑うつ」の増加量はモーフィング条件における増加量よりも多い。
（切断条件 > モーフィング条件）

仮説 2: フェード条件における「抑うつ」の増加量はモーフィング条件における増加量よりも多いか、同等である。
（フェード条件 ≧ モーフィング条件）

5. 実験結果

TMS によって得られたアンケート結果から通話前と通話後での気分の平均変化量を Fig.2、「抑うつ」の各質問項目における平均変化量を Fig.3 に示す。「活気」における変化量は増加すればよい結果となり、「疲労」、「怒り」、「抑うつ」、「緊張」、「混乱」における変化量は減少していればよい結果となる。サンプル数が十分ではないので、本研究では分散分析を行わず、数値比較のみを行った。

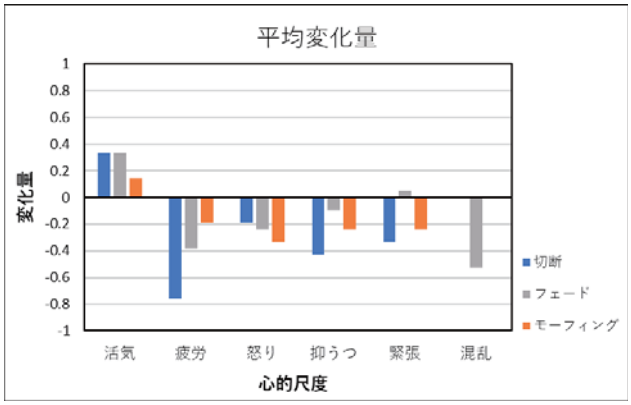


Fig.2 心的尺度の平均変化量

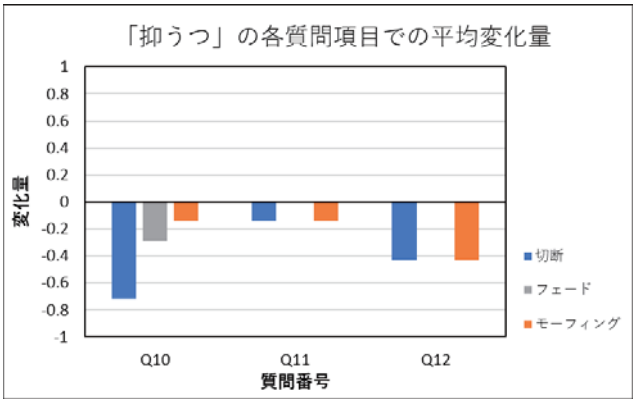


Fig.3 「抑うつ」の各質問項目での平均変化量

6. 考察

抑うつの項目において、変化量の平均が「切断条件 < フェード条件 < モーフィング条件」となった。これは仮説 1、仮説 2 を棄却する結果である。しかし、すべての条件において、通話前よりも通話後のほうが「抑うつ」が軽減しており、本研究の目的に最も関連のある質問である「孤独でさびしい」においても平均変化量が減少していた。これは条件の違いで寂しさの軽減量が変化したわけではなく、もともと寂しさを感じていなかったためであると考えられる。実際、アンケートの回答でも実験前、実験後ともに 1 や 2 を選択する実験参加者が多く見られた。このような結果になった原因として、本実験が通話後の寂しさを感じにくい設定だった可能性が考えられる。通常の遠隔コミュニケーションでは、通話が終了した後、しばらくはその人物と会うことがない。しかし、本実験では実験進行のために通話が終了した数分後に通話者である実験者と会うということがわかってしまっている。そのため、寂しさを感じにくかったのではないかと考えられる。

「活気」、「疲労」、「混乱」においては、フェード条件がモーフィング条件よりもわずかながらよい結果となった。この要因として、モーフィングによる不気味さが考えられる。実験後のインタビューでは「具体的な要因はわからなかったが、フェード条件よりモーフィング条件のほうが気持ち悪かった」や「フェード条件では画像がずれていたため、切り替えに時間がかかっているのだろうと感じたが、モーフィング条件では気味悪さから早くこの場から立ち去りたいと思った」との意見が得られた。MacDorman らの実

験[MacDorman 2006]においても、アンドロイドとヒューマノイドロボットの中間的な顔の画像は不気味さの評価が高くなることが報告されており、今回の実験のような動的なモーフィングでも同様の印象を与えてしまったと言える。このモーフィングでの顔の変形による不気味な印象が、「活気」に影響を与えた結果、「疲労」、「混乱」にも影響が出たのではないかと考えられる。しかし、条件間での差はそれほど大きいものではなく、サンプル数を増やしても有意な差は見られないと考えられる。

その原因として、モーフィングによる切り替えを通話終了後のみに実施したことが考えられる。通話終了後に存在感の余韻を残すことを目的としていたため、人からロボットへの切り替えにのみ変化を加えた。そのため、実験参加者は通話終了時に初めてモーフィングによる切り替えを目にすることになる。これまで何も変化がなかったにも関わらず、突然容姿が変化したことにより、切り替えの際にギャップを感じてしまったのではないか、と考えられる。この改善方法として、通話終了時だけでなく、通話開始時にもモーフィングによる切り替えを行うことが挙げられる。実験参加者からは、「通話中にもモーフィングを行った方がよいのではないか」という提案があった。しかし、先述の通り、モーフィングによる顔の変化は通話者に不気味さを感じさせてしまう可能性がある。そこで、通話者の視線に注目しようと考えている。通話者が視線を向けている状態、つまり意識的にロボットを見ている際は変化せず、視線が外れ、意識がロボットにあまり向いていない状態のときにわずかにモーフィングをすることで、通話中に不気味さを感じさせず通話中のモーフィングを行えると考えられる。

今回行ったアンケート手法も適切ではなかったと考えられる。アンケートは、回答を求める際に実験参加者の意識に介入する必要があり、それによって実験参加者の主観的な心的状態が変化してしまう可能性がある。通話時におけるハグの効果を調査する実験[Sumioka 2013]では、通話前後のストレスホルモンの変化量を計測することによって評価を行っている。このように生理的な変化を用いて評価する方が適切であると考えられる。IJzerman らによると、孤独感によって体温が低下することがわかっている[IJzerman 2012]。そこで、今後は、通話前後における体温の変化を計測することによって評価を行うことを検討している。

7. まとめ

本研究では、テレプレゼンスロボットにおいて通話終了後に遠隔者の存在感が急激に消失することによる寂しさを軽減するために、存在感に余韻を残すことを提案した。その具体的な方法として、通話終了の際にロボットの顔に表示されている遠隔者の顔をロボットの顔とモーフィングしながら切り替えることを考え、実験を行った。比較条件として、切断条件、フェード条件を設けた。通話前と通話終了後にアンケートを実施し、各条件での心的状態の変化量を調査した。しかし、条件間で大きな差は見られなかった。

その原因として、実験が寂しさの変化を評価するのに適していなかったことや単純にモーフィングを用いるだけでは存在感の余韻を提示することはできず、通話者がロボットに対して不気味さを感じてしまっただけとなったことが考えられる。

8. 今後の展望

これらの結果を踏まえ、今後実験手順を改善した再実験を行うことを検討している。まず、実際の使用で想定される通話直後は会うことができないという状況を作り出すことが重要であると考えられる。そこで、実験者と遠隔者の役割を分割することを検討している。また、通話の回数を増やしすぎると次第に通話後の寂しさを感じにくくなる可能性もあり、条件は通話前後にのみモーフィングを行う条件と通話中にもモーフィングを行う条件の 2 条件比較に変更しようと考えている。

評価にはアンケートを使用せず、サーモセンサを用いた実験参加者の体温の変化量を使用することを検討している。待機時間も現在の30秒では通話後の孤独を感じにくい可能性がある。そこで、IJzerman らの実験を参考に、待ち時間を 300 秒程度に設定することを検討している。

謝辞

本研究は JSPS 科研費 17K19993 の支援を受けて行われた。

参考文献

[大塚 2013] 大塚　和弘, 熊野 史朗, 松田 昌史, 大和 淳司: MM-Space: 頭部運動の物理的補強表現に基づく会話再構成, 情報処理学会論文誌, Vol.54, No.4, 1450-1461, 2013.

[妻木 2012] 妻木　勇一: 遠隔コミュニケーションとテレロボティクス, 日本ロボット学会誌, Vol.30, No.6, 606-608, 2012.

[Oyekoya 2012] Oyewole Oyekoya, William Steptoe, Anthony Steed: SphereAvatar: A Situated Display to Represent a Remote Collaborator, Proceedings of the SIGCHI conference on human factors in computing systems, 2551- 2560, 2012

[三澤 2012] 三澤 加奈, 石黒 祥生, 暦本 純一: LiveMask : 立体顔形状ディスプレイを用いたテレプレゼンスシステムにおけるコミュニケーションの評価, インタラクション 2012, 41-48, 2012.

[Misawa 2015] Kana Misawa, Jun Rekimoto: ChameleonMask: Embodied physical and social telepresence using human surrogates, Proceedings of the 33rd Annual ACM Conference Extended Abstracts on Human Factors in Computing Systems, 401-411, 2015.

[田中 2015] 田中 一晶, 宇野 弘晃, 山下 直美, 中西 英之, 石黒 浩: ロボット操作者の偽存在感によるソーシャルテレプレゼンスの生成, インタラクション 2015, 28-37, 2015.

[藤代 2015] 藤代　一成ほか: コンピュータグラフィックス[改訂新版], 公益財団法人　画像情報教育振興協会 , 2015.

[徳田 2011] 徳田　完二: 一時的気分尺度 (TMS) の妥当性, 立命館人間科学研究, 第 22 号, 1-6, 2011.

[MacDorman 2006] Karl F. MacDorman, Hiroshi Ishiguro: The uncanny advantage of using androids in cognitive and social science research, Interaction Studies, Vol.7, No.3, 297-337, 2006.

[Sumioka 2013] Hidenobu Sumioka, Aya Nakae, Ryota Kanai, Hiroshi Ishiguro: Huggable communication medium decreases cortisol levels , Scientific Reports, Vol.3, 3034, 2013.

[IJzerman 2012] Hans IJzerman, Marcello Gallucci, Wim T.J.L. Pouw, Sophia C. Weiβgerber, Niels J.Van Doesum, Kipling D.Williams: Cold-blooded loneliness: Social exclusion leads to lower skin temperatures, Acta psychologica, Vol.140, No.3, 283–288, 2012.

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

グループディスカッション参加ロボットの頭部動作決定機構の検討

Consideration of Group Discussion Participating Robot Autonomously Performing Head Movement

木村 清也 *1　黄 宏軒 *2*3*4　桑原 和宏 *2
Seiya Kimura　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立命館大学情報理工学部
Graduate School of Information Science and Engineering,Ritsumeikan University

*3理化学研究所革新知能統合研究センター
Center for Advanced Intelligence Project,RIKEN

*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

In recent years, Japanese companies are seeking employees with high communication skills. Therefore, there are companies that adopt group discussion at the time of job selection recruitment.Therefore it is thought that by raising communication skills the possibility of succeeding in job hunting can be increased. Repetitive practice is thought to be effective for improving communication skills, while a corresponding partner is required to do iterative practice. However, preparing partners is not easy for many students. We are developing a training system for group discussion with virtual agents and robots. In this paper, we propose for robots participating in group discussion.

1. はじめに

近年，日本企業は社員に対してコミュニケーション能力を求める傾向にあり，その能力を評価するために就職採用選考時にグループディスカッションを取り入れる企業を存在する．したがってコミュニケーション能力を高めることによってより就職活動に成功する可能性を高めることができると考えられる．コミュニケーション能力の向上には反復練習が有効であると考えられている一方で，反復練習を行うためには相応のパートナーが必要となる．しかし，パートナーを用意することは多くの学生にとって簡単なことではない．そこで我々は仮想エージェントやロボットによるグループディスカッションの訓練システムの開発を進めている．ロボットがグループディスカッションに参加するためには，人間にとって自然な振る舞いをしていることが求められる．現在は振る舞いの一つである頭部動作に着目し，グループディスカッション中に他の参加者の非言語行動，言語行動からロボットの頭部動作を決定するシステムの実現を目指している．このシステムは参加者の言語，非言語行動を各種センサーによってデータを収集し，収集されたデータを基に入力モジュール群によってデータの解釈と特徴量を抽出する．その特徴量を基に頭部動作決定部によってロボットの頭部動作を決定するシステムである．そしてこの論文ではシステムの中の機構の一つである頭部動作決定部の検討を行う．本稿は以下のように構成されている．第 2 章では関連する研究について紹介し， 第 3 章で頭部動作決定システムの全体の構成について述べる．第 4 章でシステムの中で頭部動作を決定する機構を構築について述べ，最後に 5 章でまとめを行う．

連絡先: 黄 宏軒，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，〒 606-8501，hhhuang@acm.org

2. 関連研究

就職採用面接の訓練のための仮想エージェント開発はこれまでも行われてきた [Baur 3，Chollet 5，Jones 6]．しかしこれらは 1 対 1 の面接訓練のための仮想エージェントである．複数人会話であるグループディスカッションに参加できるロボットを実現するためには，1 対 1 の対話にはない課題を乗り越える必要がある．[David 2] では，複数のユーザーとエージェントとのインタラクションを実現する上での主要な課題について検討されている．また，これまでになされてきた複数のユーザーとエージェントとのインタラクション関する研究の多くはエージェントやロボットが聴き手としての対話に参加するなど人間との立場が対等でない [Iolanda 4，Marynel 7]．一方我々の研究では，人間とロボットが対等な立場でグループディスカッションを行うことを目標としているため，それに向けたシステムの構築に取り組む必要がある．

3. 頭部動作決定システム

グループディスカッションに参加するロボットのための頭部動作決定システムについて述べる．このシステムはグループディスカッション中に他の参加者の言語行動と非言語行動からロボットの頭部動作を決定するシステムである．システムは大きく分けてセンサー群，入力理解モジュール群，頭部動作決定部の 3 つの要素に分けられる．図 2 にシステムの構成を示す．

(a) センサー群
各参加者および実験環境に取り付けられた各種センサーからグループディスカッション中の参加者の非言語行動，言語行動データを収集する．

(b) 入力理解モジュール群
このモジュール群ではセンサー群によって得られた生デー

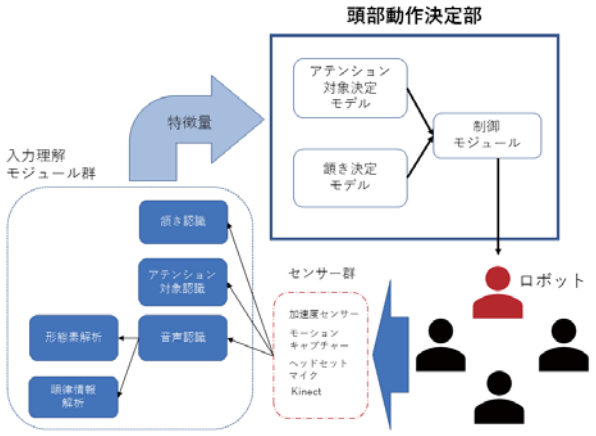


図 1: 頭部動作決定システム構成



図 2: 実験環境

タを抽象度の高いデータに変換し，それらを基にアテンション対象特徴量，発話ターン特徴量，動作特徴量，言語特徴量を抽出し、頭部動作決定部に送信する．

(c) 頭部動作決定部

入力理解モジュール群によって抽出された特徴量からロボットが行う頭部動作を決定し，ロボットに送信する．

この論文では (c) 頭部動作決定部の構築について述べる．

4. 頭部動作決定部の構築

頭部動作決定部の構築を行う．頭部動作決定部では入力理解モジュール群によって抽出された特徴量をもとにロボットの以下の 2 つに関する頭部動作を決定する．1 つ目はロボットがアテンションを向ける対象を決定する．ここでは注視方向と頭部方向の組み合わせをアテンションとして扱い，ロボットが向けるべき対象を決定する．2 つ目はロボットが頷くタイミングを決定する．これらの頭部動作を決定するためにこの機構はアテンション対象決定モデル，頷き決定モデル．そして制御モジュールによって構成されている．アテンション対象決定モデルと頷き決定モデルはロボットの頭部動作の決定を行い，結果を制御モジュールに出力する．制御モジュールは各モデルによって出力された結果を整理し，実際にロボットが行う頭部動作の指令をロボットに送信する．

4.1 対話実験データの収集

テンション対象モデルと頷き決定モデルを生成するために対話収集実験を行った．

4.1.1 実験概要

実験手順は，Fumio らに従ったがメガネ型アイトラッカーは使用しなかった [Fumio 11]．ディスカッショ ンの議題は，日本企業の就職採用面接において頻繁に使用される「サバイバルタスク」型の課題を設定した．この課題は与えられた選択肢の中から提示された条件に基づいて順位づけを行う課題である．今回の実験では配布した資料の中に記載された 15 名の有名人の中から収益や集客を考慮し，最適だと思われる人物の順位をつけていく「学園祭に招待する有名人ランキング」を議題として設定した．また議論が活発となるよう，議論に取り組む前にそれぞれの参加者で課題について考える時間を 5 分間設けた．実験データは互いに顔見知りでな い学生 4 人を 1 グループとした 10 グループの合計 40 人分の データによって構成されている．また，より実践的なグループディスカッションを行ってもらうため実験参加者は就職活動経験者，就職活動中の学生を対象とし，議論中の男女の比率の違いによる発言の優劣をなくすため，グループ内の男女の割合は，すべて 同性か，異性の数が等しくなるように設定した．

4.1.2 実験環境

1.2m × 1.2m の正方形のテーブルの周りに座って議論を行う実験参加者の様子を， 様々なセンサをとビデオカメラを用いて記録した．加速度センサー（ATR-Promotions TSND121）とオーディオデジタイザ（Roland Sonar X1 LE）に接続されたヘッドセットマイク（Audio-Technica HYP-190H）を参加者の頭に装着し，各参加者の顔を 4 台のウェブカメラ（Logicool C920）を用いて撮影した．

4.2 アテンション対象決定モデル

対話実験データからアテンション対象決定モデルを生成する．このモデルでは入力理解モジュール群によって抽出しされた特徴量をもとにアテンション対象決定モデルを用いてロボットがアテンションを向けるべき対象を決定し，制御モジュールに結果を出力する．ロボットはアクチュエータが人間と同じように機能せず，人間よりも自由度がはるかに低く，眼球もない可能性もあることからこの研究ではロボットの視線方向や頭部の向きのとの全体的な組み合わせをアテンションとして扱う．アテンションを向ける対象となるのはロボットの視点から見て，左側に座っている参加者，テーブルの反対側に座っている参加者，右側に座っている参加者とさらに配布した机上の資料 (今回の実験では有名人リスト) の 4 つのである．モデルを生成するためにアテンション対象に関する特徴量が 15 個，発話ターンに関する特徴量 23 個，韻律に関する特徴量 36 個，動作に関する特徴量が 18 個の計 93 種類の特徴量を用いてモデル生成した．また，モデルは「ロボットが発話をしている場合 (Speaking)」「他の参加者が発話をしている場合 (Listening)」「参加者全員が発話をしていない場合 (Idling)」の 3 種類のシチュエーションに分け，非線形 SVM（Support Vector Machine）を用いてコストパラメータ C = 10.0RBF カーネルのパラメータ γ = 0.01 によって生成した．評価には Leave-one-person-out 方を用い，F 値は 0.4〜0.6 程度となった．表 1 は各シチュエーションごとのモデルの精度である．

表 1: アテンション対象モデルの分類結果

Situation	Precision	Recall	F-measure
Idling	0.537	0.536	0.536
Listening	0.566	0.566	0.566
Speaking	0.453	0.450	0.452

4.3 頷き決定モデル

対話実験データから頷き決定モデルを生成する．このモデルでは入力理解モジュール群によって抽出しされた特徴量をもとに頷き決定モデルを用いてロボットが頷きを行うべきかを判定する．判定は他者の発話終了時毎に行われ，その結果を制御モジュールに出力する．このモデルでは，発話の言語特徴量や，発話中の話者やそれ以外の参加者の非言語行動から特徴量を抽出しモデルを生成する．モデルを生成するためにアテンション対象に関する特徴量が 13 個，発話ターンに関する特徴量 6 個，韻律に関する特徴量 4 個，動作に関する特徴量が 7 個，言語特徴量が 4 個の計 34 個の特徴量を用いた．モデルの生成には非線形 SVM を用いてコストパラメータ C = 20.0RBF カーネルのパラメータγ = 0.1 によって生成した．評価には Leave-one-person-out 方を用い，その結果 F 値は 0.796 となった．

4.4 制御モジュール

このモジュールではアテンション対象決定モデルと頷き決定モデルによって出力された結果をもとに実際にロボットが行う頭部動作の指令を送信する．特徴量をもとにアテンション対象モデルによって出力された結果は，制御モジュールによってアテンション対象の平均継続時間である 9.6 秒間の過去の出力結果が蓄積される，そしてその 9.6 秒の間で最も出力の多かった対象をアテンションを向ける対象として決定しロボットに送信する．また，グループディスカッションの開始から経過した時間が 9.6 秒に満たない場合は開始からその時点でまでで最も多かった出力結果をアテンションを向ける対象として決定しロボットへ送信する．頷きモデルでは特徴量をもとに他者の発話の終了時に頷きを行うべきかが判定され，頷きを行うべきと判定された場合は制御モジュールが実験参加者の頷きの平均継続時間である 1.3 秒間の頷きを行う指令をロボットに送信する．アテンション対象の切り替えと頷きが同時に発生した場合は頷きが優先される．また，ロボットが頷いている間はアテンション対象の切り替えは行わないが，頷き行っている間もアテンション対象モデルによる結果の出力と制御モジュールへの蓄積は行い，頷きが終了した時点で頷きを行っていた時間も含めた 9.6 秒の間で最も出力が多かった対象をアテンションを向ける対象として決定しロボットに送信する．頷き行っている間に新たに頷きを行うべきと判定された場合，その時点から 1.3 秒間の頷きを行う指令をロボットに送信する．

5. 終わりに

この論文ではグループディスカッションに参加するロボットの頭部動作システムを構築するために必要な機構の一つである頭部動作決定部の提案を行った．頭部動作決定部は入力理解モジュールによって抽出された特徴量を基に，頭部動作決定部が頭部動作を決定しロボットに出力する．今後は入力理解モジュール群の実装も進めることで，リアルタイムに頭部動作を決定するシステムの構築を目指す．

参考文献

[Baur 3] Tobias Baur, Ionut Damian, Patrick Gebhard, Kaska Porayska-Pomsta, and Elisabeth Andre : A Job Interview Simulation: Social Cue-based Interaction with a Virtual Character, In 2013 International Conference on Social Computing, pp. 220-227 (2013)

[Jones 6] Hazael Jones, Mathieu Chollet, Magalie Ochs, Nicolas Sabouret, and Catherine Pelachaud : Expressing social attitudes in virtual agents for social coaching, Proceedings of the 2014 international conference on Autonomous agents and multi-agent systems, pp. 1409-1410 (2014)

[Chollet 5] Mathieu Chollet, Magalie Ochs, and Catherine Pelachaud : Mining a Multimodal Corpus for Non-Verbal Signals Sequences Conveying Attitudes. In The 9th edition of the Language Resources and Evaluation Conference, pp. 3417-3424 (2014)

[Traum 2] David Traum ： Issues in Multiparty Dialogues. In Advances in Agent Communication, International Workshop on Agent Communication Languages In Proceedings of the 16th International Conference on Multimodal Interaction, pp. 201-211 (2003)

[Fumio 11] Fumio Nihei, Yukiko I. Nakano, Yuki Hayashi, Hung-Hsuan Huang, and Shogo Okada： Predicting Influential Statements in Group Discussions using Speech and Head Motion Information, pp. 136-143 (2014)

[Leite 4] Iolanda Leite, Marissa McCoy, Monika Lohani, Daniel Ullman, Nicole Salomons, Charlene Stokes, Susan Rivers, and Brian Scassellati : Emotional Storytelling in the Classroom: Individual versus Group Interaction between Children and Robots. In 10th ACM/IEEE International Conference on Human-Robot Interaction, pp. 75-82 (2015)

[Vazquez 7] Marynel Vazquez, Elizabeth J. Carter, Braden McDorman, Jodi Forlizzi Aaron Steinfeld, and Scott E. Hudson : Towards Robot Autonomy in Group Conversations: Understanding the Effects of Body Orientation and Gaze, Proceedings of the 2017 ACM/IEEE International Conference on Human-Robot Interaction, pp. 42-52 (2017)

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

対話におけるマルチモーダル情報を用いたユーザの興味の有無の推定

Predicting User's Interest Level in Dialogues with Multimodal Features

西本 遥人 Haruto Nishimoto　駒谷 和範 Kazunori Komatani

大阪大学産業科学研究所
The Institute of Scientific and Industrial Research (ISIR), Osaka University

We are developing a system that predicts a user's interest level for enabling natural human-system dialogues. The prediction results can be used for adaptive response generation according to the user's interest in a current topic. We incorporate multimodal features consisting of dialogue information such as switching pauses, prosody and verbal contents in user utterances, and user face images. We also develop two methods to integrate these multimodal features. The experimental results showed that using multimodal features is promising for the prediction.

1. はじめに

対話における人の発話には，その言語内容だけでなく，様々な有用な情報が含まれる．実際，対話分析においては，相手の声の韻律情報，顔の表情等の非言語情報も重要である [1]．

本研究では，人（ユーザ）とシステムの対話において，ユーザの心的状態を推定し，それを用いて応答を生成する音声対話システムの構築を目指す．本研究では，ユーザの心的状態の推定の一例として，ユーザの対話内容への興味の有無の推定を行う．

システムがユーザの心的状態に応じて応答を変えると，自然な流れで対話ができるようになる．ユーザが興味を持たない場合，システムは対話を別の話題に切り替えたり，「興味のある話題はなんですか？」等とユーザに対して話題の決定を促す応答ができる．一方興味を持つ場合，対話中の話題を掘り下げたり，その話題に似た別の関連話題を提示できる．

複数の情報を用いてユーザの状態を推定する研究は多く存在するが [2][3]，本研究では，対話内容への興味の有無を推定する．ユーザの応答から得る情報として，声の韻律情報，発話内容，顔画像情報を用いる．それら 3 つの情報に加え，本研究では，対話情報に注目する．対話情報とは，システムとユーザの対話において，「対話」という状況から得られる情報である．そして，それら 4 つの推定結果を用いて興味の有無の推定を行うシステムの構築を目指す．

興味の有無の推定を行う際にユーザの複数の情報を用いると，ある一種類の情報のみを用いる興味の有無の推定が困難な対話であっても，他の情報により統合推定結果を修正でき，より信頼できる結果を得られる可能性がある．図 1 のように，一種類のユーザの情報のみ用いる場合と複数の情報を用いる場合を比較する．システムのある発話に対してユーザが退屈な顔をして低い声で「すごいですね」と発話し，対話に興味がない場合を考える．興味の有無の推定に発話内容のみを用いた場合，「すごいですね」という発話は肯定的な文であるため，ユーザの興味の有無の推定はしづらい可能性が高い．一方，複数の情報として「ユーザの発話内容」,「顔の表情」,「声の韻律情報」を用いる場合，退屈な顔であり低い声という情報が追加される．そこから，システムは情報を統合して興味がないと推定できる可能性が高くなる．



図 1: ユーザの興味の有無の推定に複数の情報を用いた場合の利点

2. 対象データ

2.1 使用した対話コーパス

実験にはシステムとユーザの対話が収録されたマルチモーダル対話コーパスを用いた．そのコーパスは京都工芸繊維大学で収集されたものである [4]．用いたコーパスのやりとりは，以下の例のように，スポーツや音楽等の話題に沿ってシステムが質問を行ったり，話題に関する詳細な知識を紹介したりするものである．コーパスはユーザ 1 名につき 10-15 分，1 名につき約 80 のやりとりがあり，ユーザ 5 名分のデータを使用した．やりとりに関しては次の節で詳細を述べる．

やりとり例 1
S：どんなスポーツが好きですか？
U：サッカーです.
やりとり例 2
S：2020 年に東京でオリンピックが開催されます.
U：今から楽しみです.

このマルチモーダル対話コーパスにはアノテータにより興味の有無を判断したラベルが付けられている．合計 6 名のアノテータは，収集されたデータをもとに，ユーザが対話内容に興味を持っているかどうかを，1 やりとりごとに判断する．そして「興味あり (o)」,「興味なし (x)」,「不明 (t)」,「設定トラブル等で本来の対話と無関係なやりとり (e)」の 4 つのラベルか

連絡先: 西本 遥人，大阪大学産業科学研究所 知識科学研究分野，〒 567-0047 大阪府茨木市美穂ヶ丘 8-1，:06- 6879-8416，nishimoto@ei.sanken.osaka-u.ac.jp

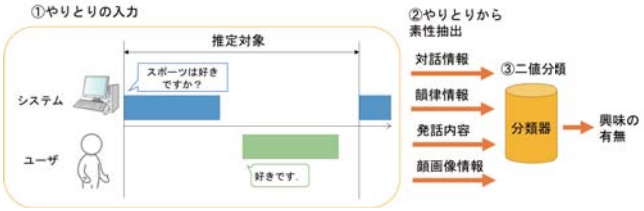


図 2: 興味の有無の推定手法の全体像

ら最適だと判断したラベル 1 つをやりとり毎に付与する．なお,「不明 (t)」のラベルは「興味あり (o)」と「興味なし (x)」の中間の意味合いをもつ．

このラベルをもとに興味の有無の正解となるラベルを多数決方式により作成した．o の数，もしくは x の数が 4 以上の場合，それを正解ラベルとした．それに該当しないやりとりのうち，e がひとつでも存在すれば e とした．これら 2 項目以外は t とした．

本実験では，興味の有無の二値分類を行うため，正解ラベルが t または e のやりとりは今回使用データに含めない．用いた正解ラベルが o と x のやりとりはそれぞれ 131，170 であり，合計が 301 であった．すなわちマジョリティベースラインは（全て x と推定した場合）は，$170/301 = 0.565$ である．

2.2 興味の有無の推定の対象区間

本研究では，システムの発話開始時刻から次のシステムの発話開始時刻までの区間を推定対象とする．図 2 の左のように，システムとユーザの発話が交互に行われる対話を想定するため，その推定対象区間にはユーザの発話が含まれている．以降，この区間を以降「やりとり」と呼び，興味の有無の推定対象とする．

3. マルチモーダル情報を用いた統合推定

与えられた正解ラベルをもとに機械学習で分類器を構築し，興味の有無の推定を行う．構築には，複数のやりとりを学習データとして用いる．図 2 に機械学習を用いた興味の有無の推定手法の全体像を示す．入力として，ユーザのマルチモーダル情報についての素性を抽出する．学習データにより構築された分類器を用い，ユーザのマルチモーダル情報を統合した推定結果を出す．推定結果は興味の有無の二値である．

以下では，対話情報，声の韻律情報，発話内容，顔画像情報の 4 つの情報で設計した素性を述べる．

3.1 対話情報の素性

対話という状況から得られる情報として以下の 4 つを用いる．ユーザの声の情報や顔の情報だけではなく，対話情報を用いて推定を行うことで，推定性能の向上を図る．

- 応答時間
- システムの発話内容の単語数
- ユーザの発話内容の単語数
- システムとユーザの発話内容の単語数の差

一つ目の応答時間は，1 やりとり中のシステムの発話終了からユーザの発話開始までの時間である．これは興味の度合いに応じて応答時間に変化が生じると予想される．これはユーザが興味を示さなかった場合より，興味を示した場合の方がユーザの応答時間が短い傾向にあるからである [5]．二つ目から四つ目の素性には，当該やりとり中のシステム発話とユーザ発話の単語数を使用する．ユーザが興味のある話題は，単語数は多くなりやすく，一方で興味のない話題は，その話題についての知識をあまり保持しないため，発話は短くなりやすいと考えられる．

表 1: 韻律情報の素性項目

素性項目の名称		素性項目の説明
RMSenergy		音量の二乗平均平方根値
mfcc	[1]	1 次メル周波数ケプストラム係数
	[2]	2 次メル周波数ケプストラム係数
	…	…
	[5]	5 次メル周波数ケプストラム係数
F0		基本周波数
voiceProb		その時点での音が声である確率
zcr		波形のゼロ交差率

表 2: 韻律情報の演算項目

演算の名称	演算の説明
max	データ中の最大値
min	データ中の最小値
range	最大値と最小値の差分
maxPos	最大値を出力した位置
minPos	最小値を出力した位置
amean	算術平均
linregc1	線形近似の勾配度
linregc2	線形近似のオフセット
linregerrQ	線形近似の二乗誤差
stddev	標準偏差

3.2 韻律情報の素性

興味の有無の推定に必要な要素がユーザの声の韻律やその変化に含まれる．例えば，対話中で他の発話よりも声が大きかったり，声が高かった場合，そのやりとりにおいてユーザが対話内容に興味を持っている可能性が高い．一方，声が小さい場合はユーザが対話内容に興味を持っている可能性は低いと考えられる．

INTERSPEECH 2009 Emotion Challenge で用いられた音響的素性セット（以下，IS09）を使用すると，韻律に関する素性が取得できる [6]．IS09 で抽出される素性は，メル周波数ケプストラム係数 (mfcc)，声のパワー (RMSenergy)，ゼロ交差率 (zcr)，声である確率に関する素性 (voiceProb)，基本周波数 (F0) といった素性項目からなる．それらは複数の演算項目によって演算される．

本推定で使用する韻律に関する素性数は 90 である．演算項目は 10 項目，素性項目は 9 項目を用いる．表 1 と表 2 は，それぞれ用いる素性項目，演算項目の一覧である．

興味の有無の推定の対象区間であるやりとり中のユーザの発話部分の音声ファイルから IS09 を用いて韻律情報に関する素性を抽出する．入力はやりとりの音声からシステムの発話区間音声を取り除いた音声を用いた．使用するコーパスにはユーザ発話のないやりとりが存在するため，その場合は素性値を全て 0 とした．

3.3 発話内容の素性

発話内容をユーザの興味の有無の推定にはユーザの発話内容をテキストに変換したものを入力とし，単語の原形に関する bag-of-words で取得する素性と，品詞の数に注目して設計

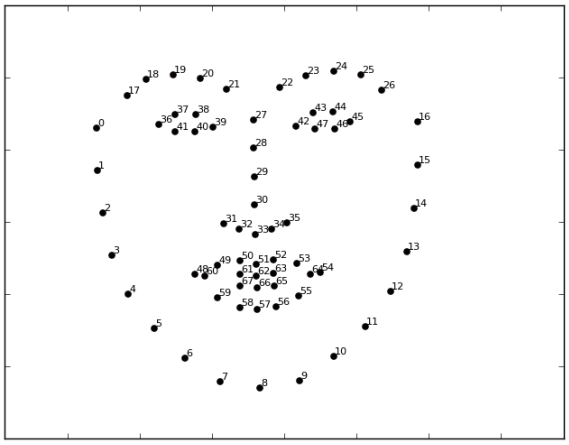


図 3: 人の顔におけるランドマークの位置

した 4 つの素性を抽出する．bag-of-words で用いる単語は登場する全ての単語から付属語とコーパス中で 1 回しか登場しない単語を除いたものである．品詞の数に注目して設計した 4 つの素性は，名詞の数，副詞の数，形容詞の数，感動詞の数である．これらは興味のある場合，発話が長くなり数が増加する傾向があると考えたため，素性に含めた．なお，形態素解析には MeCab[*1] を用いた．発話内容に関する素性数は合計 99 である．

3.4 顔画像情報の素性

顔の各部位の動き方がユーザの興味の有無に関係していると仮定し，人間の顔に含まれる特徴点（以下，ランドマーク）の位置の変化を素性として抽出する．これまでの研究で，顔の表情の分析には顔の各部位の動きが関係していることは明らかになっている [7]．ユーザの興味の有無は顔の表情に現れると考えられるので，ランドマークを用いた素性を抽出する．今回は対象となるデータが動画データであるため，その動画のフレーム毎 (100ms) にランドマークを取得する．ランドマークの位置は，静止画中のピクセル座標 (x 座標，y 座標) である．また位置の変化はピクセル座標のユークリッド距離を用いて表現する．ランドマークは Dlib[*2] を用いて取得した．

人間の顔の 68 のランドマークのうち，顔の特定の部位のランドマークのみを用いて素性抽出を行った．顔の部位の中でも口，顎は発話時や顔の表情を変化させる際に他の部位に比べてより位置が変化すると考えた．用いるランドマークは口の 4 点，顎の 1 点であり，ランドマークの動きは 12 の演算により処理した．演算は韻律情報の素性抽出に用いた表 2 の 10 の演算項目に加え，尖度と歪度を含めた 12 の演算項目である．それらは移動距離の最大値，変化の割合等である．図 3 のランドマークのうち，口には 48，51，54，57 の点を用い，顎には 8 の点を用いる．合計の素性数は $(4+1)*12=60$ である．

3.5 統合推定手法

ユーザのマルチモーダル情報をそれぞれ用いて抽出した素性を用いて，それらの情報を統合する．その手法として，late fusion と early fusion を設計した．late fusion と early fusion の統合の概略図を図 4 に示す．

*1 http://taku910.github.io/mecab/
*2 http://dlib.net/

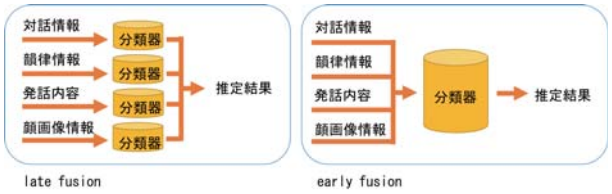


図 4: late fusion と early fusion の推定手法の概略

late fusion は図 4 のように，ユーザのマルチモーダル情報の素性をそれぞれ用いて分類器を複数作成し，その各結果を用いて統合する．統合の際には，マルチモーダル情報を用いたそれぞれの推定での SVM の判別平面からの距離に符号を与えたものを素性として，再度 SVM で分類する．

$$d = \boldsymbol{w}\boldsymbol{x} + b \tag{1}$$

式 1 の d は SVM の判別平面からの距離に符号を与えたものである．$\boldsymbol{w}$ は素性の重みベクトルであり長さは素性数に一致する．$\boldsymbol{x}$ は素性ベクトルである．b はバイアス項である．素性の重みベクトルとバイアス項は SVM による学習により得られる．与える符号は，分類器による推定結果が o の場合は正，x の場合は負とする．

early fusion は図 4 のように，各情報から得られた素性をまとめて，分類器を一つ作成し推定を行う手法である．対話情報の素性は 4，韻律情報の素性は 90，発話内容の素性は 99，顔画像情報の素性は 60 であった．

4. 実験結果と考察

表 3: 一種類の情報のみ用いた推定の正解率

発話	韻律	顔画像	対話	正解率
○	-	-	-	0.748
-	○	-	-	0.661
-	-	○	-	0.585
-	-	-	○	0.668

表 4: 統合推定の正解率

発話	韻律	顔画像	対話	early	late	oracle
○	○	-	-	0.731	0.754	0.857
○	-	○	-	0.748	0.678	0.904
○	-	-	○	0.738	0.654	0.824
-	○	○	-	0.668	0.761	0.884
-	○	-	○	0.698	0.754	0.834
-	-	○	○	0.688	0.694	0.854
○	○	○	-	0.728	0.751	0.927
○	○	-	○	0.728	0.751	0.870
○	-	○	○	0.728	0.688	0.920
-	○	○	○	0.701	0.744	0.910
○	○	○	○	0.734	0.744	0.934

ここでは，一種類の情報の用いた推定結果と複数の情報を統合した結果を比較し，情報を統合することの有用性を説明する．一種類の情報を用いた推定は，3.5 節で述べた統合手法は用いることはできないため，その一種類の情報の素性をそのまま用いて分類器を構築し，推定結果を出す．

4.1 一種類の情報のみ用いた推定結果

表 3 は一種類の情報のみを用いたユーザの興味の有無の推定の正解率である．発話内容のみを用いた推定の正解率は 0.748 であり，4 つの推定のうち最も性能がいいことがわかる．以降は，対話情報，韻律情報，顔画像情報を用いた推定の順に性能が良いことがわかる．今後は性能の低い顔画像情報を用いた推定の性能の向上が課題である．

4.2 自動的に統合した場合

表 4 は，複数の情報を用いた統合推定の正解率を示している．○のついたユーザ情報を用いて late fusion，early fusion，次節で述べる oracle で統合推定を行ったときの正解率を示している．表 3 より，発話を用いた推定は正解率が 0.748 であったのに対し，表 4 より，late fusion に注目すると，発話+韻律を用いた推定は正解率が 0.754 であった．このことから，late fusion で統合することで性能がわずかに上昇することがわかる．情報を統合することで性能は良くなるが，この結果は 2 つの情報を統合させたものである．3 つもしくは 4 つの情報を統合させた結果は，発話+韻律+顔画像，発話+韻律+対話を統合させた推定の正解率 0.754 が最高であり，2 つの情報を統合させた結果より性能が低い．そのため，より多くの情報を統合する推定の性能の向上が今後の課題である．

late fusion による 2 つの情報の統合について，組み合わせる情報によって正解率の増減に大きな差がある．例をあげると，韻律のみの正解率は 0.661，顔画像のみの正解率は 0.585 であったが，これらを統合すると，正解率は 0.761 まで増加した．同じく韻律と対話をそれぞれ用いた場合の正解率は 0.661，0.668 であったが，統合すると正解率は 0.754 に増加した．反対の例をあげると，発話と対話をそれぞれ用いた場合の正解率は 0.748，0.668 であったが，統合すると正解率は 0.654 に減少した．すなわち，正解率が増加する組み合わせは互いにあまり相関のない情報を持ち，一方が他方を補うことができるといえる．反対に，正解率が減少する組み合わせは互いに相関のある情報を持つといえる．統合することで性能を上昇させるために，互いに相関の少ない素性を設計する必要がある．

early fusion による統合では，情報を複数用いた場合でも性能の向上は認められなかった．2 つ，3 つ，4 つの情報を用いた統合の最も正解率の高い数値は，それぞれ 0.748，0.728，0.734 であり，発話のみを用いた推定の正解率 0.748 を上回らなかった．唯一，用いる情報を 3 つから 4 つに増やした場合では，性能が向上した．各情報の素性数の次元に差がある状態で統合したため，今後は素性数の差を減らすための手法を考える必要がある．

4.3 統合が理想的に行われた場合

推定性能の上限を知るために，ユーザの興味の有無の推定において，それらを理想的に統合した場合 (oracle) を考える．oracle では，正解が o である場合に，いずれかの推定結果に o が含まれれば o とする．それ以外の場合は x とする．

oracle での統合から正解率を出し比較する．oracle の正解率は，統合の性能の上限の値となる．統合推定の結果を示した 4 に注目すると，2 つ，3 つ，4 つの情報を用いた oracle による統合の最も正解率の高い数値は，それぞれ 0.904，0.927，0.934 であった．これから，より多くの情報を用いた統合推定の方が推定性能の上限が高くなるということがわかる．

5. おわりに

本研究では，ユーザから得られるマルチモーダル情報から素性を抽出した．各情報に関する素性からユーザの対話内容への興味の有無を推定した．マルチモーダル情報を統合し，ユーザの対話内容への興味の有無の推定手法を示した．実験の結果から，提案した late fusion を用いて自動的に統合した際，一種類の情報のみを用いた推定より性能が向上する場合が認められた．対話情報を含めたマルチモーダル情報を組み合わせることで，推定性能の上限が向上することがわかった．

今後の研究課題として，推定性能の向上のための素性抽出手法の改良が挙げられる．

参考文献

[1] Mark L. Knapp, Judith A. Hall, and Terrence G. Horgan. Nonverbal communication in human interaction. *Cengage Learning*, 2013.

[2] 岡田将吾, 松儀良広, 中野有紀子, 林佑樹, 黄宏軒, 高瀬裕, 新田克己. マルチモーダル情報に基づくグループ会話におけるコミュニケーション能力の推定. 人工知能学会論文誌, Vol. 31, No. 6, pp. AI30–E_1–12, 2016.

[3] 上村譲史, 目良和也, 黒澤義明, 竹澤寿幸. 字句情報，音響情報，表情から推定した話者感情の食い違い状況の分析と食い違い自動検出手法の提案. 第 78 回全国大会講演論文集, 第 2016 巻, pp. 321–322, mar 2016.

[4] 荒木雅弘, 冨増紗也華, 中野幹生, 駒谷和範, 岡田将吾, 藤江真也, 杉山弘晃. マルチモーダル対話データの収集と興味判定アノテーションの分析. *SIG-SLUD*, Vol. B5, No. 02, pp. 20–25, oct 2017.

[5] 河原達也, 川嶋宏彰, 平山高嗣, 松山隆司. 対話を通じてユーザの意図・興味を探り情報検索・提示する情報コンシェルジェ. 情報処理, Vol. 49, No. 8, pp. 912–918, 2008.

[6] Björn Schuller, Stefan Steidl, and Anton Batliner. The interspeech 2009 emotion challenge. In *Tenth Annual Conference of the International Speech Communication Association*, 2009.

[7] P. Ekman and W. Friesen. *Facial Action Coding System: A Technique for the Measurement of Facial Movement.* Consulting Psychologists Press, 1978.

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

非話者間の相互行為によるターンの受け継ぎの影響の分析

Analysis of Influence of Turn-taking by Mutual Action Between Non-speakers

牧野孝史 *1　竹川佳成 *1　平田圭二 *1
Makino Takashi　Takegawa Yoshinari　Hirata Keiji

公立はこだて未来大学 *1
Future University Hakodate

In Japanese, it is difficult to recognize completion point only by syntactic information because Japanese is the language whose case structure is not determined by word order. However, turn-taking occurs smoothly and there is little possibility that long silence or duplication occurs between utterance.I claim that non-verbal behavior such as non-speaker's gaze and backchannel is important to recognize completion point of turn-taking in multi-party conversation. In this paper, we observed an excerpt of dialog from the video recording s of the discussion. I found that there were differences in gaze of non-speakers between when speakers switched and when the speaker continued.

1. はじめに

ある会話において，先行発話がどの時点で終了するか (以下，完結点) の推定には，文，節，区，語彙等の統語が重要な役割を果たしている [2]．また，完結点は，韻律や統語構造，ジェスチャーなどの複数の要因によって決定されると言われている [4]．英語においては，語順によって格構造が決定されることが多いため，特に統語情報が完結点の推定に重要であるとされている [14][15]．一方で，日本語は各構造が語順によって決定されないため，完結点の推定に統語情報を用いることが難しい．しかし，実際の会話では日本語であっても，話者が交替するといった現象 (以下，ターンの受け継ぎ) はきわめて円滑に行われており，発話間に大きな沈黙が生じたり，無秩序に重複が発生したりすることは少ない．

そこで，本研究では日本語におけるターンの受け継ぎはなぜ，遅延なく，円滑に行われるのかという問題に取り組む．この問題の解決によって，会話エージェントシステムへの応用といった工学的な分野で広く利用されることが期待される．例えば，参加者の様々な相互行為の情報から完結点をあらかじめ推定することで，自然なタイミングによる発話の開始や，ターンの受け継ぎのための適切な振る舞いが可能な会話エージェントの実現に大きく寄与すると期待される．また，その他，遅延のある TV 会議システムにおいて，事前に参加者が発話を終了することを予測し通知することで，発話衝突を解決するなど，自然な会話システム構築の基盤的な技術となりうる．

複数人対話においては，非話者 (次話者とならない聞き手) が存在し，非話者の行為に着目した研究がいくつかなされている．従来研究では，非話者は次話者を見続けるという傾向があることが示唆されている．また，現話者の視線を回避するために，他の方向に視線を向けたり，発話末前に視線を移動するということが観測されている [3]．しかし，非話者のこれらの行為と現話者や次話者の行為の関係性に関しては十分に議論されていない．そのため，本研究では，3 人による議論を対象に，非話者の行為によるターンの受け継ぎへの影響を分析によって例証する．

連絡先: 牧野孝史，公立はこだて未来大学，〒 041-8655 北海道函館市亀田中野町 116 － 2，0138-34-6444，g2117044@fun.ac.jp

2. ターンの受け継ぎに関する研究

ターンは文，節，区，語彙等の統語上の単位やイントネーション等の韻律上の要素等，様々な特徴によって構成される [13]．また，ターンの終わりには，話者が交替する可能性のある時点，つまり，ターン移行関連場所 (TRP: transition relevance place) が存在する．次のターンへ移る際には，沈黙と重複が起こることは少なく (起こったとしてもそれは短いものである)，基本的に一人の参加者が一つのターンをとって話すという原則がある．このようなターンの受け継ぎの仕組みにおいては，各 TRP において以下のよう規則が順に適応されると述べている [13] ; (1) 現話者による次話者選択，(2) 現話者による次話者選択が行わなければ，次話者による自己選択が可能，(3) 自己選択が行わなければ，現話者による継続が可能．また，規則 (3) で現話者が自分のターンを継続した場合，話者が交替するまで，規則 (1) から (3) が繰り返し適応される．

以上は，語順によって格構造が決定されることが多い英語による発話データを対象としたターンの受け継ぎの分析に関する知見である．一方で，日本語による発話は，完結点が予測しにくいと言われている [2]．具体的には，助詞が格構造を決定するために重要な役割を担っている日本語では，表層上の語順が自由であり，発話終了地点に近づくまでの最終的な発話の構造が変更されることがある [?]．また，一般的には述部要素の終わりが文法的完結点とみなされることが多いのにもかかわらず，述部要素のさらに後方に語が続く場合もある．そのため，動詞の語幹の出現は完結点への投射をもたらすが，そこが完結点であるかどうかを判断するには不十分である，英語のように，発話の最初から文全体の構造が明らかである言語と比べると，日本語は文の構造が変化していく可能性を有している．つまり，日本語による発話では，完結点の推定が非常に難しいと言えよう．その結果，発話間の沈黙時間が長くなることや，発話の重なりなどが発生することが予測される．

3. データ

本研究で分析した会話資料は，先行研究 [12] によって収録された，3 人による日本語会話の映像データである．参加者は，親しい間柄の 20 代の大学生または大学院生同士であった．対話は，男が得か女が得かという議題を与え，10 分間以内で議

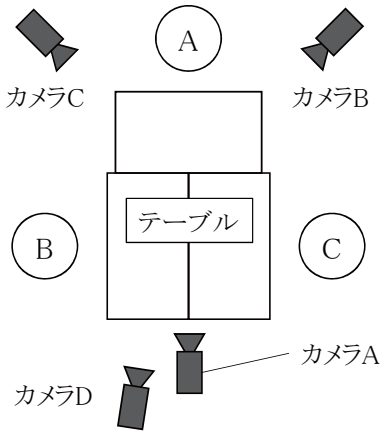


図 1: 収録状況

論を行なった後に，3 人で 1 つの答えを出すといった手続きで行われた．収録環境を図 1 に示す．3 人の参加者はテーブルを挟んで三角形となるように対座してもらい，発話の収録のために書く被験者の胸にピンマイクを装着している．また，対話状況の全体的な外観や参加者のバストアップの様子の映像を 4 台のビデオカメラで撮影した．図 1 のように参加者を撮影するためにカメラ A, B, C を配置し，全体を俯瞰できるようにカメラ D を配置した．

本研究で分析するのは，2017 年 7 月 14 日に収録された，大学院生 3 人による議論場面である．参加者 3 人の性別は，男 1 名，女 2 名である．各話者は大学で知り合い，同じサークルのメンバーの友人同士である．3 人とも「です・ます」体ではなく，砕けた話し方ができる程度の中であった．事例分析においては，それぞれ，話者 A(女)，話者 B(男)，話者 C(女) と表記する．

4. 事例分析

以下，実際の会話の相互作用の中で参加者がどのようにターンの受け継ぎを言語的または非言語的に表示しているのかについて，短い会話部分を取り上げ，そこでのターンの受け継ぎのプロセスを詳細に分析する．ここでは，何度か発生するターンの受け継ぎのタイミングのプロセスをその要因とともに記述する．本研究では，特に非話者間の視線や頷きなどの非言語情報に着目した分析をする．これから説明する事例では，話者 B が男の方が得であるという意見を主張している場面である．この場面は，話者 A，話者 C の順にそれぞれの意見を言い合い，話者 A が話者 B に意見を求めている場面で，話者 B が自分の意見の詳細を述べている場面である．それぞれの役割として，話者 B は現話者，話者 A は次話者，話者 C は非話者となっている．

4.1 事例 1：話者 B のターンの継続

事例 1 (図 2) の発話 1 から 5 までは，話者 B が何度かターン受け継ぎの表現を話者 A に対して行うが，自身でターンを継続している場面である．まず話者 B が，「1 : なんていうのちょっと制限されちゃっているみたいなね」と発言している．この際，話者 B は頷きを行いながら話者 A へ視線を向けることで，ターンを話者 A へ交替しようしている [15][16]．話者 A に着目すると，話者 B の発話中は話者 B を注視し続けており，発話末付近において，頷きを行なうことで，話者 A へターンを交替するような合図を送っている [15]．話者 C に着目すると，話者 A と同様に話者 B を注視し続けている．この際，ターンは後退せず，話者 B が継続して発話を続けた．

次に話者 A と話者 C の頷きを確認し，話者 B が，「2: まぁ男もそりゃ育てるけどやっぱさ」という発話をしている．この際，話者 B は発話 1 と同様に視線によって話者 A へターンを交替するような合図を送っている [15]．話者 A に着目するとは，話者 B を注視し続けており，ターンが交替する可能性がある [5][6][7]．しかし，発話 2 においてもターンは交替せず，話者 B が継続して発話を続けた．

話者 B が「3: 一番女が愛情注がなきゃいけない雰囲気じゃん」「4: 今って」と発話した際，話者 B は発話 1 や発話 2 と比べて，長い時間話者 A を注視している．そのため，この発話は発話 1 や発話 2 に比べて，よりターンの交替の合図を強く発信している [8]．話者 A に関しては，今までの話者 B の発話時と同様に話者 B を注視し続けている．この際も，ターンは交替せず，話者 B が継続して発話を続ける．

このように現話者が視線やジェスチャー等で次話者を指定し，ターンを交替する合図を出しており，次話者が合図を受け取るような行為をするが，実際には交替しない場合が多く見られた．

4.2 事例 2 : 話者 B から話者 A へのターンの受け継ぎ

事例 2 (図 3) の発話 5 から 11 までは，事例 1 の続きであり，引き続き話者 B がターンの受け継ぎの表現を話者 A に対して行い，話者 A へターンが移行した場面である．まず，話者 B が「5: だからなんかそういうとことかも」という発話をしている．この際，話者 B は，視線を下に向けてまま何度か頷くことで，次話者を選択せずにターンの終了を表示している．話者 A に着目すると，話者 B の発話開始時は話者 B を注視する様子が見られるが，発話末付近において話者 C へと視線を移す．この直後，話者 A は話者 B を注視しながら笑いを起こしている．話者 C は話者 B の発話終了直後に話者 A を頷きながら注視する様子が確認できる．このように発話 5 において，話者 A と話者 C の間で，視線を交差しようとする行為が観察された．

続けて，話者 B が「6: まぁ要因としてあるんじゃないかっと」と発話し，話者 A を注視することで，再度ターンを話者 A へ交替しようとしている．その際，話者 A は話者 B を注視しているが，ターンを受け取らなかったため，続けて「7: それなら男の方がやっぱね」という発話を続ける．このターンの最後に，話者 B は視線を下に向けることで，次話者を選択せずにターンの終了を表示している．

その後，約 0.7 秒の沈黙が発生し，次に誰がターンをとるかわからない状況に，話者 A が「8: うーん」というあうづちをうち，ターンを取ろうとする．しかし，この後すぐに話者 B が「9: まぁお金もかからんし」と発話を続けることでターンを継続している．この際，話者 B は話者 A を注視することで，ターンを話者 A へ交替しようとしている．しかし，その後，約 1.0 秒の沈黙が発生したため，続けて話者 B は「10 : っていうことは」と発話を続け，ターンを継続している．この際，話者 A は話者 B から視線を外し，話に従事していない様子を見せ [5][6][7]，発話 10 の終了後に「11 : でも今は男も化粧する時代だし」といった発話をすることでターンを開始している．この際，話者 C は発話 10 の際は話者 B を注視していたが，発話 11 が開始すると同時に現話者となった話者 A を注視し始めている．

この事例では，次話者と非話者が一度，視線を交差しようとする場面が観察された．その後，現話者のターンの受け継ぎの

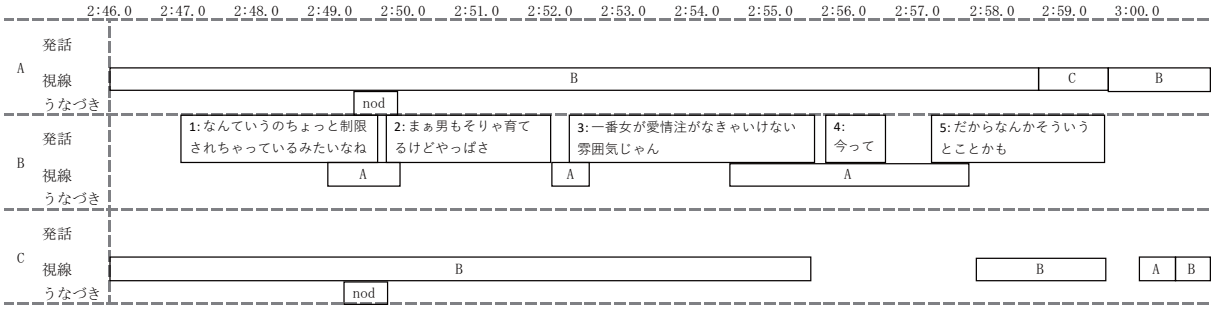


図 2: 事例 1 の書き起こし

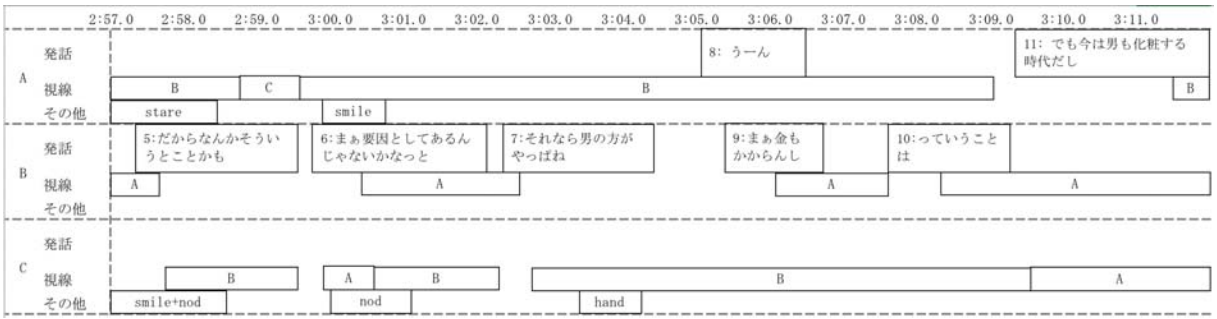


図 3: 事例 2 の書き起こし

表示を受け取り，ターンの移行へと成功している．

4.3 事例 1 と事例 2 の比較

事例 1 では，何度か発生するターンの受け継ぎのタイミングには実際にターンを交替することがなかったが，事例 2 においては発話 8 の話者 A によるあいづちの後にターンが交替する．この 2 つの事例において異なる部分を調べる．ここで非話者である話者 C の非言語的表現に着目して，ターンの受け継ぎの分析をする．

事例 1 の発話 1 から発話 3 までの間，話者 C は視線を現話者である話者 B へと向けている．このように現話者を注視するという非言語的表現は話に従事していることを示す一つの方法 [5][6][7] であり，話者 C が話者 B に次にターンを取って発話を開始することを認めるための表示であると解釈することができる．その後，発話 3 のターン終了時に話者 C は頷きながら，話者 B から視線をそらしている．この際，現話者である話者 B の発話では連辞「じゃん」といった発話末要素が現れており，ターンが終了することを示している．そのため，このターン終了時の頷きや現話者から視線をそらすといった非言語的表現は，話者 C が話に従事しないという表現 [5][6][7] をしているのではないかと考えることができる．

次に事例 2 の発話 5 のターン終了時に話者 C は一度，話者 B から視線を外し，発話 6 のターン開始時に話者 A を注視している．この際，現話者である話者 B の発話では終助詞「も」といった発話末要素が現れており，視線を下に向けいることから，次話者を選択せず，ターンを終了することを示している．そのため，現話者から視線を逸らし，その後，話者 A を注視するといった非言語的表現は，現話者の完結点を認識し，話者 C が次話者となることを回避し，話者 A へターンの開始を求めるような行為 [2] なのではないかと考えることができる．その後，発話 7 のターンの終了時に話者 A による「7: うーん」というあいづちがなされる．これは話者 A が発話順番を受け取るという表示をしているを解釈することができる．そして，発話 10 のターン終了時に話者 A がターンを受け取ることに成功している．

このようにターンが交替しない事例 1 では非話者は現話者の方を注視し続ける様子が観察され，ターンが交替した事例 2 では非話者が次話者に対して視線を向けるといった様子が観察された．

5. 考察

3 人の議論場面を分析したところ，現話者が受け継ぎの表示をしているが，ターンが交替しない場合が多く観察することができた．これは日本語における完結点を統語情報から予測することが困難 [2] であることや，言語や非言語的表現による意図が必ずしも 1 つではない [3] ためである．事例分析で見てきたように，実際にターンが交替した場合と継続した場合を比較したところ，非話者の視線に違いがあることが確認できる．そこで，ターンが継続した場合と交替した場合の非話者の行動に着目し，ターンの受け継ぎに関して考察する．

まず，ターンが継続したときの非話者の行動に関して，発話中に現話者を注視することや発話末において人以外を注視するという行為が特徴的である．複数人対話において，現話者は次話者と相互注視をすることが多いことが知られている [8]．その上で，非話者が現話者へ視線を向け続ける続けるということは，非話者が話に従事していること (engagement) を示す [5][6][7] し，現話者が続けて発話をしやすい環境を作り出している．また，発話末において非話者が現話者から視線を逸らすということは，非話者が話に従事していないこと (disengagement) を示す [5][6][7] し，現話者の視線の向け先である次話者が発話しなければならない，もしくは，現話者が話続けなければいけな

い環境を作り出している．

次に，ターンが交替したときの非話者の行動に関して，次話者の方を注視するという行為が特徴的である．非話者の視線行動として，発話末付近で現話者を見続ける場合が圧倒的に多いことがわかっている [3]．つまり，非話者が次話者に視線を向けることは稀なので，誰とも視線を交差しないことが多い．分析において，いつ非話者が次話者へ視線を向けたかを調べたところ，現話者は人以外へ視線を向け，次話者が非話者へ視線を向けた直後であった．このことは，次話者が視線によって発話を開始しようするが，現話者からターンを譲渡するといった行動がなかったため，非話者にターン開始の容認を求めたものと解釈できる．その時，非話者は次話者のターン開始の要求に気づき，容認するために，次話者へ視線を向けたと考えられる．しかし，実際には，次話者と非話者の視線交差の後，次話者によってターンが開始されるまで少しの間，現話者による発話が続いたため，必ずしも現話者のターン終了時にこういった行為が見られるわけではない．

以上のようにターンが継続する時と交替する時の非話者の視線行動に違いを見つけることができたということは，ターンの受け継ぎを認識するために非話者の行動が影響を与えていることを示唆する．しかし，ここでの分析は，抜粋された事例をもとに説明したにすぎない．すなわち，非話者の行動が特徴的である部分のみを分析対象として選択されているのである．より重要なことは，非話者の視線行動が実際にターンが交替される発話末でない時に出現したということである．今後は発話末以外における非話者の行動とターンの受け継ぎの関係性を統計的に分析する必要がある．

6. おわりに

本研究では，3 人による議論場面を観察し，そこで生じる非話者の行動とターン受け継ぎの関係性を分析した．分析の結果，ターンが継続する時と交替する時で非話者の視線行動に違いがあることがわかり，ターンの受け継ぎを認識するためには現話者や次話者の行動だけでなく，非話者の行動が影響を与えていることが示唆された．

従来，ターン構成単位 (TCU: Turn Construction Unit)[13] や間休止単位 (IPU: Inter Pausal Unit)[10]，長い発話単位 (LUU: Long Utterance Unit)[1] といった発話単位の末尾に着目したターンの受け継ぎの分析を行ってきた [8][9][11]．この分析手法では，前後の行為を考慮したターンの受け継ぎといった問題は扱うことができない．本研究では，ターンが交替される発話より前に非話者がターンの受け継ぎに関する表示を行なっていることが確認できた．今後，ターンの受け継ぎの認識方法をより理解するために，発話末以外における非話者の行動とターンの受け継ぎの関係を調査していきたい．

参考文献

[1] Den, Y., Koiso, H., Maruyama, T., Maekawa, K., Takanashi, K., Enomoto, M., Yoshida, N.: Two-level annotation of utterance-units in Japanese dialogs: An empirically emerged scheme, In Proceedings of the 7th International Conference on Language Resources and Evaluation, pp.1483-1486 (2010).

[2] 榎本美香: 会話の聞き手はいつ話し始めるか: 日本語の話者交替規則は過ぎ去った完結点に遡及して適用される, 認知科学, vol. 10, no. 2, pp. 291-303 (2003).

[3] 榎本美香, 伝康晴: 3 人会話における参与役割の交替に関わる非言語的行動の分析, 人工知能学会研究会資料, SIG-SLUD-A301, vol. 38, pp. 25-30 (2003).

[4] Ford, C., Thompson, S. and Barbara, F.: Practices in the construction of turns: The "TCU" revisited, Pragmatics, vol. 6, pp. 427-454 (1996).

[5] Goodwin, C.: Restarts, pause, and the achievement of a state of mutual gaze at turn beginning, Sociological Inquiry, vol. 50, pp. 272-302 (1980).

[6] Goodwin, C.: Chapter3: Notes on the organization of engagement. Conversation organization, Academic Press, pp. 95-125 (1981).

[7] Goodwin, C.: Gesture as a resource for the organization mutual orientation, Semiotica, vol. 62, no. 1-2, pp. 29-49 (1986).

[8] 石井亮, 大塚和弘, 熊野史朗, 松田昌史, 大和淳司: 複数人対話における注視遷移パターンに基づく次話者と発話開始タイミングの予測, 電子情報通信学会論文誌 A, vol. J97-A, no. 6, pp. 453-468 (2014).

[9] Kawahara, T., Iwatate, T., Takahashi, K.: Prediction of Turn-Taking by Combining Prosodic and Eye-Gaze Information in Poster Conversations, INTERSPEECH2012, Porland (2012).

[10] Koiso, H., Horiuchi, Y., Tutiya, S., Ichikawa, A., Den, Y.: An analysis of turn-taking and backchannels based on prosodic and syntactic features in Japanese map task dialogs, Language and Speech, vol.41, pp.295-321 (1998).

[11] 小磯花絵, 伝康晴: 円滑な話者交替はいかにして成立するか, 認知科学, vol. 7, no.1, pp.93-106 (2000).

[12] 牧野孝史, 三浦寛也, 竹川佳成, 平田圭二: 複数人対話における話者交替現象分析のための議論コーパスの作成, 人工知能学会研究会資料, SIG-SLUD-B507, pp.3-8 (2017).

[13] Sacks, H., Schegloff, E. and Jefferson, G.: A simplest systematic for the organization of turn-taking for conversation, Language, vol. 50, no. 4, pp. 696-735 (1973).

[14] Sacks, H.: Lectures on conversation, Oxford: Blackwell (1992).

[15] Schegloff, E.: Turn organization: One intersection of grammar and interaction, Cambridge University Press, pp. 52-133 (1996).

[16] 高梨克也: 会話連鎖の組織化家庭における聞き手デザインの機能, 社会言語科学会第 10 回研究大会予稿集, 社会言語科学会, pp.191-196 (2002).

Oral presentation | Organized Session | [Organized Session] OS-7

[3D1-OS-7a] [Organized Session] OS-7

Thu. Jun 7, 2018 1:50 PM - 3:30 PM Room D (4F Cattleya)

[3D1-OS-7a-01] Projection of self-body image in the full body illusion

○Atsushi Yumoto[1], Eiji Otake[2], Sotaro Shimada[2] （1. Meiji University Graduate School, 2. Meiji University ）

1:50 PM - 2:10 PM

[3D1-OS-7a-02] “Time” and “Projection”: Models of Others Emerging by Temporal Overlapping

○Tetsuo Ono[1], Kazuki Mizumaru[1] （1. Hokkaido University）

2:10 PM - 2:30 PM

[3D1-OS-7a-03] The model of behavioral change induced by external self-projection using a robotic system.

○Hideyuki Takahashi[1], Hiroshi Ishiguro[1] （1. Osaka university）

2:30 PM - 2:50 PM

[3D1-OS-7a-04] Activating Third-Person Perspective Self on HMD using Constructive Approach

○Kenri Kodaka[1] （1. Graduate School of Design and Architecture, Nagoya-city University）

2:50 PM - 3:30 PM

©The Japanese Society for Artificial Intelligence

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

フルボディー錯覚における自己身体のプロジェクション

Projection of self-body image in the full body illusion

湯本　淳史[*1]
Atsushi Yumoto

嶋田　総太郎[*2]
Sotaro Shimada

[*1] 明治大学大学院
Meiji University Graduate School

[*2] 明治大学
Meiji University

The full body illusion (FBI) is an illusion of the self-ownership and self-agency towards an avatar that is touched synchronously with one's own body. Here we investigated the FBI using an avatar that moves synchronously with the participant's movement. Participants made their steps on the spot while watching a VR scene as if the avatar walked in a street either synchronously or asynchronously with their steps. The avatar was presented in either 1st-person or 3rd-person perspective. The result showed that the participants felt the sense of ownership and the sense of agency toward the avatar that moved synchronously in both 1st- and 3rd-person perspectives. Our results suggest that our body image can be projected on the avatar that moves synchronously with our own body.

1. はじめに

自己身体認識は身体所有感と運動主体感から構成される[Gallagher 2000]. 身体所有感とはこの身体は自分自身の身体であると感じる感覚であり, 運動主体感とはこの運動を引き起こしたのは自分自身であると感じる感覚である. 「プロジェクションサイエンス」の考え方を用いると, 自己身体認識とは脳内にある自己身体の表象を身体的なものに投射することで自分の身体として認知することだと説明できる. このとき, 自己身体の表象の投射先が自己身体以外となる例として, ラバーハンド錯覚やフルボディー錯覚が挙げられる.

ラバーハンド錯覚とは, 自己身体を自分の手ではない偽物の手(ラバーハンド)に投射して, ラバーハンドが自分の手のように感じられる錯覚である[Kalckert 2012]. ラバーハンド錯覚を全身に拡張した現象がフルボディー錯覚であり, 自分の身体が刺激されている状態で, アバターの 1 人称視点でアバターが筆で同じ場所を刺激される映像を見ると, そのアバターに対し身体所有感を感じることが報告されている[Petkova 2011]. 3 人称視点のフルボディー錯覚ではアバターの背面をアバターの後方から見る. 自分の背中を刺激された状態で, 3 人称視点からアバターの背中が刺激されている映像を見るとアバターに対して身体所有感を感じることが報告されている[Heydrich 2013].

本稿では, 自ら動かせるアバターに対して身体所有感および運動主体感を感じる錯覚（フルボディー錯覚）について検討する. ここでは, アバターを 1 人称視点で見た場合と 3 人称視点で見た場合, アバターの動きが同期している場合と非同期である場合において錯覚の強度に違いが生じるのかを調べる. これによって自己身体全体がどのように他の物体に投射されるのかについて考察する.

2. フルボディー錯覚実験

2.1 被験者

16 名の健康な男性が実験に参加した(22.0 ± 0.61 歳). 被験者には実験前に実験内容や安全性についての説明を行い, 書面にて実験参加の同意を得た.

連絡先:湯本淳史, 明治大学大学院理工学研究科, 神奈川県川崎市多摩区東三田 1-1-1, E-mail: ce171075@meiji.ac.jp

2.2 実験環境

被験者はモーションキャプチャーデバイス(Perception Neuron, Noitom, CHN)とヘッドマウントディスプレイ（HMD: Head Mounted Display)(Oculus rift, Oculus, USA)を装着した. Oculus rift は視野角が約 110°, 解像度が 1080×1200, リフレッシュレートが 90 Hz であった.

Perception Neuron のセンサは磁気の影響を受けやすいため磁場シールド(アンティエミー4010T 東京計器ピエーション株式会社, JPN)の中に入り, 磁場の影響を極力少なくし実験を行った. また, Perception Neuron のセンサは計 12 個のセンサを用いて実験を行った.

被験者は実験開始位置に立った状態で HMD を装着した. ゲーム開発プラットホーム(Unity, Unity Technologies, USA)で仮想現実空間の映像を作成した.

2.3 実験手順

被験者にアバターが 1.0 m/s の速さで前に動いている映像を見せながら, 1 分間その場での足踏みを行ってもらった(図 1). アバターに対する身体所有感を変調させる要因として視点(一人称視点:1pp, 三人称視点:3pp)とアバターの動きの整合性(同期 vs 非同期)の二つの要因を設け, 2×2 = 4 つの実験条件で実験を行った. 非同期条件は事前に録画しておいたモーションデータをアバターに反映させて行った.

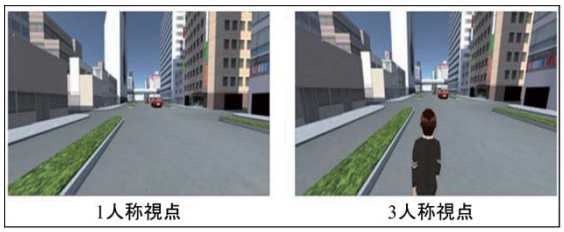


図 1　実験映像

実験開始前に, 足踏みによる影響をなくすために HMD の画面が真っ暗な状態でその場での足踏みの練習を数回行ってもらった. 足踏みを行うにあたり被験者には「普段のんびり歩いている感覚で足を上げる高さとタイミングを一定にすること.」と教示を行った. 足踏みによる実験開始位置からの変位が 50 cm 以内, 一回前に測定した変位との差が 10 cm 以内であれば練習を終了してもらった.

フルボディー錯覚の強度を測る指標として以下の 2 つを用いた.

(1) ドリフト測定

客観的指標としてドリフト測定を行った. 1 分間の足踏み終了後に被験者に対し「開始位置から動いてしまったと感じたら基準位置まで戻ってください. 前後左右に動くまたは回転していただいても大丈夫です. 」と教示を行った. そして被験者が戻った位置を実験終了位置とし, 実験開始位置からの前後方向の被験者の位置の変位を測定した(図 2). また映像あり条件の変位と映像無し条件の変位の差をドリフト距離とし, フルボディー錯覚生起の指標として定義した.

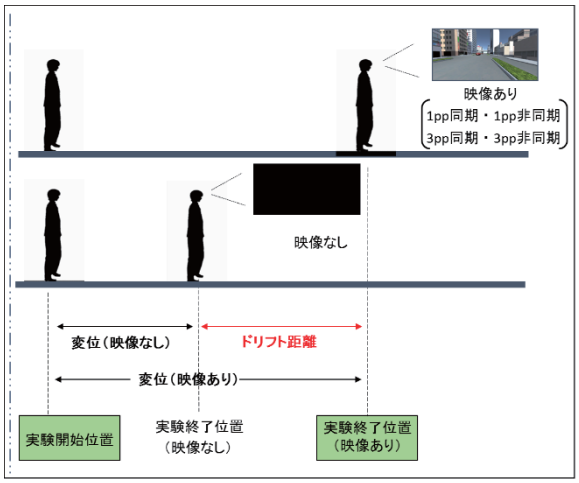


図 2 ドリフト測定

(2) 自己身体感アンケート

主観的指標として自己身体感アンケートを行った. アンケートは先行研究[Kalckert 2012]で用いられたものを今回の実験に合わせた内容に変更し日本語に翻訳したものを用い, 身体所有感と運動主体感およびそのダミー項目の全 8 項目から成る. 評価には「とても思う(+3)」から「まったく思わない(-3)」までの 7 段階リッカート尺度を用いた. 2 項目は身体所有感に関するもの(「アバターの身体が自分の身体であるかのように感じました」など), 2 項目は運動主体感に関するもの(「アバターの身体は, 私の意思に従うように, 思った通りに動きました」など), 残りの 2 項目ずつはダミーの質問(「二つ以上の身体を持っているかのように感じました」や「アバターの身体が私の意思をコントロールしているかのように感じた」など)であった.

被験者はそれぞれの実験条件につき 1 試行ずつ行った. 順序効果を避けるため 4 つの実験条件の呈示順序は被験者間でカウンターバランスを取った.

身体所有感, 運動主体感それぞれ 0 に対して有意に大きなスコアであった場合(t 検定), アバターに対して身体所有感, 運動主体感を感じたと定義した.

3. 実験結果

3.1 ドリフト測定

身体所有感に関する客観的評価を解析した結果, 1pp 同期, 3pp 同期条件において(0 に対して)有意なドリフト距離($t(15) = 2.95$, $p < 0.01$, $t(15) = 3.03$, $p < 0.01$, 図 3)が得られた. さらに二要因分散分析を行った結果, 動きの整合性の主効果がみられた($F(1, 15) = 9.27$, $p < 0.01$, 同期 > 非同期, 図 3).

以上の結果より, 1pp 同期, 3pp 同期条件においてフルボディー錯覚が生起したといえる.

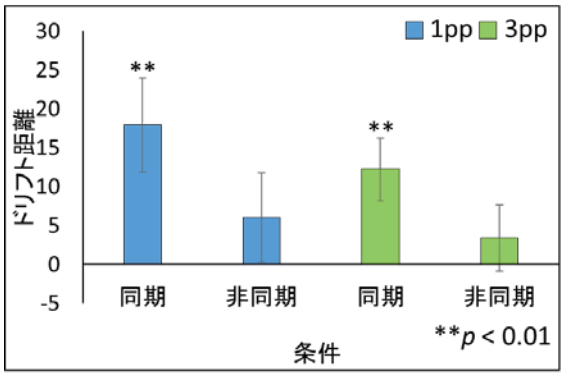


図 3 フルボディー錯覚生起の客観的指標

3.2 自己身体感アンケート

身体所有感に関するアンケートを解析した結果, 1pp 同期条件において有意なアンケートスコアが得られた(t (15) = 2.31, $p < 0.05$, 図 4). さらに 2 要因分散分析(視点×動きの整合性)を行った結果, 視点($F(1, 15) = 8.10$, $p < 0.05$, 図 4), 動きの整合性($F(1,15) = 15.36$, $p < 0.01$, 図 4)による主効果が見られた. また, 交互作用が見られた($F(1,15) = 7.37$, $p < 0.05$, 図 4). 交互作用の効果を調べるために単純主効果の下位検定を行った結果, 1pp 非同期と 3pp 非同期条件の間および 3pp 同期と 3pp 非同期条件の間に有意な単純主効果が見られた(F (1,15) = 15.26, $p < 0.01$, F (1,15) = 22.69, $p < 0.01$, 図 4).

運動主体感に関するアンケートを解析した結果, 1pp 同期, 3pp 同期条件において有意なアンケートスコアが得られた(t (15) = 10.6, $p < 0.01$, t (15) = 11.4, $p < 0.01$, 図 5). さらに 2 要因分散分析(視点×動きの整合性)を行った結果, 動きの整合性による主効果が見られた(F (1, 15) = 16.55, $p < 0.01$, 図 5). また, 交互作用(F (1,15) = 7.23, $p < 0.05$, 図 5)が見られた. 交互作用の効果を調べるために単純主効果の下位検定を行った結果, 1pp 非同期と 3pp 非同期条件の間および 3pp 同期と 3pp 非同期 条件の間に有意な単純主効果が見られた(F (1,15) = 9.68, $p < 0.01$, F (1,15) = 23.77, $p < 0.01$, 図 5).

以上の結果より, 1pp 同期, 3pp 同期条件にアバターに対して身体所有感, 運動主体感を感じたといえる.

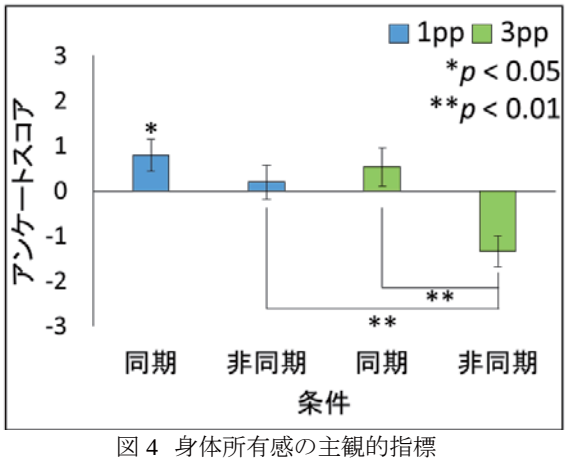


図 4 身体所有感の主観的指標

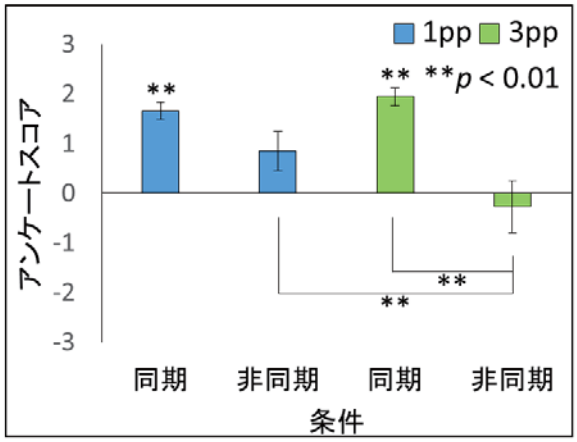


図 5 運動主体感の主観的指標

4. 考察

今回の実験では，VR 環境において自分の身体の動きをアバターに投射し，視点とアバターの動きの違いによる自己身体感を調べた．自分の動きに同期していれば視点に関係なくアバターに対して身体所有感，運動主体感を感じることが分かった．この結果は自分の手と同じ動きをするラバーハンドに対して身体所有感，運動主体感を感じたと報告した先行研究[Kalckert 2012]の結果と整合性があり，このことから自分の動きに同期していれば身体の一部だけでなく身体全体を外界に投射できると考えられる．今後は脳活動や生理学的指標を計測することで，自己身体のプロジェクションのメカニズムを解明していきたい．

参考文献

[Gallagher 2000] Gallagher, S: Philosophical conceptions of the self: Implications for cognitive science. Trends in Cognitive Sciences, 4: 14-21. 2000.

[Kalckert 2012] Kalckert, A: Moving a rubber hand that feels like your own: A dissociation of ownership and agency. Frontiers in Human Neuroscience, 6, 40. 2012

[Petkova 2011] Petkova, V. I: The perspective matters! Multisensory integration in ego-centric reference frames determines full-body ownership. Frontiers in psychology, 2, 35. 2011

[Heydrich 2013] Heydrich, L: Visual capture and the experience of having two bodies – evidence from two different virtual reality techniques. Front. Psychol., 4, 946. 2013

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

「時間」と「プロジェクション」:時間的重なりによって創発する他者モデル

"Time" and "Projection": Models of Others Emerging by Temporal Overlapping

小野 哲雄[*1]
Tetsuo Ono

水丸 和樹[*1]
Kazuki Mizumaru

[*1] 北海道大学 大学院情報科学研究科 ヒューマンコンピュータインタラクション研究室
Human-Computer Interaction Lab., Graduate School of Information Science and Technology, Hokkaido University

To make it behave as if an artifact (agent) has an internal model (model of others) is important as a design principle for making people understand the artifact (AI system) with increased autonomy. In particular, in this research, we focused on "time" and proposed a model that allows people to assume other models of artifacts by temporal overlapping of utterance behaviors in communication. In this paper, first of all, after overviewing our research on "duality of the body" and "temporal overlapping" in the interaction, we proposed a framework of "models of others emerging by temporal overlapping". We conducted experiments based on this framework and verified its validity. In the future, from this point of view, we are planning to conduct research on the interaction design of people and artifacts based on "time".

1. はじめに

「プロジェクション科学」とは，人間の認知機構を解明するためのまったく新しい方法論であるとともに，そのモデル論的理解をとおして工学的応用までも射程に収めている野心的な構想である[小野 16]. [鈴木 16]が述べているように，認知科学におけるこれまでの研究は，刺激の「受容」とその利用過程に注目し，知覚，記憶，思考などのさまざまな認知現象について，精度の高いモデルを作り上げてきた．しかし一方で，内部に構成されたモデル（表象）が世界のどこかに「投射」（プロジェクション）されていると考えなければ理解できない現象も多数存在する．たとえば，視覚・聴覚などの（直接的な神経回路が存在しない）遠感覚における投射，ラバーハンドイリュージョン，子どもの遊び行動における投射（imaginary companion），異常事態における他者の存在感（third man factor）などは新しい概念や機構を想定しなければ説明できないと考えられる．

本研究では，人とロボットのインタラクションにおける「時間」に注目し，「プロジェクション」との関係を明らかにする．具体的には，2 体のロボット同士のインタラクションにおいて，両者の発話行動を徐々に時間的に重ね合わせ（temporal overlapping），予期的に振る舞わせる．これを観察していた人は，ロボットが相互に他者モデルを持っていると想定するようになり，両者がインタラクションを行っている空間を「社会空間」（social space）と認識するようになると予想している．このプロセスは後に述べるように，人間が「身体の二重性」（duality of embodiment）を持つがゆえに，自身の認知的なモデルをロボットへ「プロジェクション」することによって成立しているとみなすことができる．

ここで本研究における「身体の二重性」とは，「外に向かう身体」と「内へ向かう身体」を意味している．たとえば，人が他の人に道案内をする場合，外部へ表出するジェスチャという行為と自身の記憶にアクセスするプロセスは不可分であり，双方が影響を与え合っていることが明らかとなっている[Ono 00, 小野 01]. つまり，人は自身の「身体の二重性」を，予期的な振る舞いをしているロボットにも付与するのではないかと予想している．

本研究の成果は，AI 技術の進展により，自律性が高まった人工物（AI システム）の挙動を人に理解させるためのインタラクションデザインの原理として重要である．つまり，人同士の信頼感の醸成は，お互いに外部に表出される情報だけから内部状態を推定し，その状態推定が「時間」的に抗えない相互の反応を繰り返すことによって行われる．言い換えると，同様の認知機構を持っているならば欺くことができない「時間的な制約」によってインタラクションを継続することによって信頼感は醸成されるのである．人とロボットのインタラクションにおいても同様に「時間」に基づくインタラクションデザインが必要であると考える．

2. 「身体の二重性」と「時間」

2.1 道案内における「身体の二重性」

本節ではまず，我々がすでに行った，人と人および人とロボットの道案内の場面におけるインタラクション実験における「身体の二重性」について述べる．[小野 01, Ono 01]では，身体の同調的動作による対話者間の関係の構築，および，この関係に基づく情報伝達のメカニズムを理解するための枠組みを提案した．これらの研究における実験の結果，人と人のインタラクションでは，身体の同調的な動作により円滑な情報伝達が行われていることが明らかとなった（**図 1 左**）．また，人とロボットのインタラクションでは，人がロボットの身体の向きや，腕，首の動きに引き込まれるように同調的な動作をしたとき，円滑な情報伝達が行われることが明らかとなった（**図 1 右**）．一方，上記のような身体の同調的動作が起こらない場合，人は道案内における空間情報の想起や記憶が難しいことが明らかとなった．

つまり，人が道案内で行うジェスチャ（「外に向かう身体」）と空間情報の想起・記憶（「内に向かう身体」）は不可分であり，双方が「時間」的に同期しない場合，インタラクションが阻害されることが明らかとなった．したがって，これらの研究により，インタラクションにおける「身体の二重性」と「時間」の重要性が明らかとなった．

連絡先：小野哲雄，北海道大学大学院情報科学研究科，札幌市北区北 14 条西 9 丁目，tono@ist.hokudai.ac.jp



図 1. 道案内実験における人と人の同調的動作(左),
同様に人とロボットの同調的動作(右)

2.2 「時間的な重なり」とコミュニケーション空間

人とロボットのインタラクションにおいて,ロボットを文脈適応的に振る舞わせるためには,人同士のコミュニケーション空間やその活性度を認識することは重要である[小野 13].この機能を実装することにより,ロボットが人同士のコミュニケーション空間を回避したり,対話の活性度が低下したタイミングで介入するなど,「空気を読む」ことにより円滑な社会的なコミュニケーションを実現するための基盤を構築することができる.

この機能を実現するために,我々は対話の参与者の音声発話の「重なり」に注目した対話活性度の計算方法を提案した[Imayoshi 12, Imayoshi 13].この簡易な計算方法により,人同士のコミュニケーション空間を高い確率で認識できるようになり(**図 2**),さらにこの計算方法を用いて,ロボットが人同士のコミュニケーション空間を認識し回避する応用システム(**図 3**)や,このコミュニケーション空間内だけで,情報漏洩することなく安全に人同士が対話することができるシステムを開発してきた.

これらの研究をとおして,音声対話における「時間的な重なり」はコミュニケーション空間を認識する重要な手がかりとなることが示された.

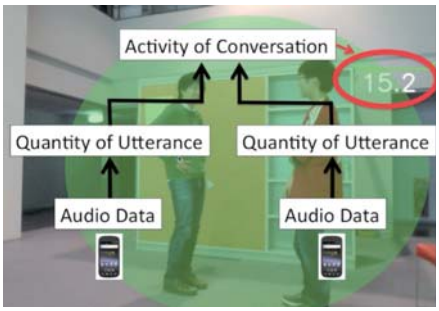


図 2. 音声発話の重なりを用いた対話活性度の計算



図 3. 社会空間を認識し,それを回避するロボット

3. 時間的重なりによって創発する他者モデル

すでに述べたように,エージェントやロボットなどの人工物を内部モデル(他者モデル)を持っているかのように振る舞わせることは,自律性が高まった人工物(AI システム)の行動を人に理解させるためのデザイン原理として重要である.本稿では,これまでの我々の研究(2 節参照)に基づき,発話行動の時間的な重なりによって人に他者モデルを想定させることができるインタラクションデザインの枠組み ***Temporal Overlapping*** を提案する.

図 4 に,本稿で提案する枠組みの概要を示す.2.1 節で述べたように,空間情報の円滑な伝達のためには,同調的な身体動作が重要な役割を果たすことが明らかとなった.また,2.2 節で述べたように,音声発話の時間的な重なりは,コミュニケーション空間を識別するための重要な指標となることが明らかとなった.つまり,発話と身体動作の「時間的な重なり」は円滑なコミュニケーションにおいては頻繁に観察される現象であると考えられる.

2 体の人工物(ロボット)が上記のように「時間的な重なり」をもって発話と身体動作を行うとき,我々には 2 体が予期的に振る舞っているように見えるだろう.なぜならば,一方の発話や身体動作が終了する前に他方は行動を起こさねばならず,そこには「予期」(prediction)が不可欠となる.この予期的動作の基盤にあるのが,他者に対するモデル(他者モデル)であろう.この他者モデルは,同様の身体を有した者同士が,一定のインタラクションの履歴をとおして形成されていくものであると考えられる.

ここで,なぜ上記のような推論が成り立つのであろうか.それは我々が「身体の二重性」を有しており,実際に観察可能なのは「外に向かう身体」だけであるが,当然,不可分な「内へ向かう身体」があることを想定してしまうためである.このプロセスは,自分の内部モデルを他者や人工物に無意識に「投射」(プロジェクション)することによって成立していると思われる.



図 4. インタラクションデザインの枠組みである
Temporal Overlapping の概要

4. 検証実験

本研究で提案した枠組 ***Temporal Overlapping*** を検証するため,2 つの検証実験を行なった[水丸 17].実験 1 では,2 体のロボットの発話行動の「時間の重なり」が人間に与える影響を調査するため,クラウドソーシングサービスを利用した.さらに,実験 2 では,ロボット 2 体のインタラクションを実際に実験参加者が観察を行い,発話行動の「時間の重なり」の効果を調査した.実験の詳細については,[水丸 17]を参照されたい.

4.1 実験 1 の実験設定と手続き

実験 1 では,ロボット(Pepper)2 体の発話の間隔が,それを観察する人間にどのような印象を与えるのかを調査するために,クラウドソーシングサービスを利用した.調査に使用したロボットのビデオは,発話間隔をパラメータとして,3 つの条件(Overlap 条件,Default 条件,Delay 条件)により作成された(**図 5**).

まず,Overlap 条件では双方のロボットの発話が徐々に重なっていき,最終的には 1 秒重なるように設定した.会話ビデオ全体の長さは 60 秒であった.次に,Default 条件では発話間隔が常に 0 秒であり,一方のロボットの発話が終了するとすぐにもう

一方のロボットが発話を開始した．会話ビデオ全体の長さは 67 秒であった．最後に，Delay 条件では発話間隔は常に 1 秒であった．会話ビデオ全体の長さは 79 秒であった．



図 5. 各条件におけるロボットの発話間隔

実験 1 の実験参加者は 721 名であり，ロボット 2 体の会話ビデオを見た後，以下の 3 項目のアンケートに 5 段階形式（5 が最もポジティブ）に回答してもらった．

1. How natural was the conversation of the robots?
（ロボットの会話はどの程度自然だったか）
2. How lively was the conversation of the robots?
（ロボットの会話はどの程度活発だったか）
3. How familiar were the robots with each other?
（ロボット 2 体の関係はどの程度親密だったか）

4.2 実験 1 の結果

実験 1 のアンケート結果について，1 要因被験者間比較（クラスカル・ウォリス検定）を行なったところ，項目 2「ロボットの会話はどの程度活発だったか」について有意傾向が確認された（**図 6**）．このため，事後検定として Mann-Whitney の U 検定（片側検定）を行なったところ，Overlap 条件と Delay 条件との間に有意な差が確認された（$p<.05$）．この結果は，発話の間隔が常に 1 秒ある Delay 条件よりも，発話の重なりが生じる Overlap 条件の会話の方が活発に感じるということを示している．

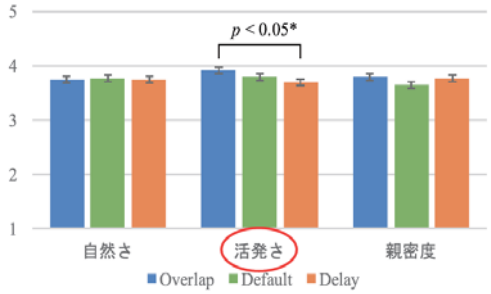


図 6. 実験 1 のアンケート結果

4.3 実験 2 の実験設定と手続き

実験 2 では，実際のロボット 2 体を用いて，ロボット同士の会話を実験参加者が直接観察した（**図 7**）．また，実験手続きは以下のとおりである．

1) 実験参加者は実験の説明を受け，2 体のロボットの前に立つように指示を受ける
2) 実験者の合図で実験参加者はロボットに挨拶する
3) ロボットの会話が始まる
4) 実験者は別室で様子をモニタリングする

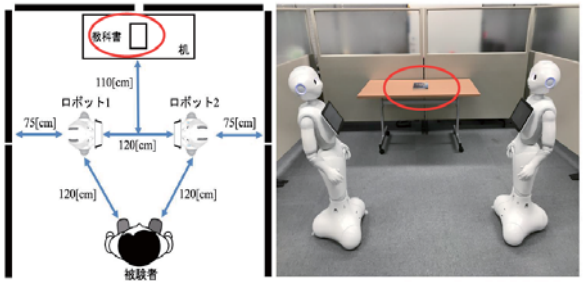


図 7. 実験 2 の実験環境（左：平面図，右：実験参加者視点）

5) 会話のおわりに片方のロボットが実験参加者に机の上の教科書を見るようにすすめる
6) 実験者は会話終了後，およそ 30 秒後に実験室に入り，実験終了の旨を伝える
7) 実験参加者はアンケートに答える

手順 7 において，実験参加者は以下の 5 段階形式（5 が最もポジティブ）のアンケートに答えた．

1. ロボットの会話はどの程度自然だったか
2. ロボットの会話はどの程度活発だったか
3. ロボット 2 体の関係はどの程度親密だったか

4.4 実験 2 の結果

実験 2 のアンケート結果については，どの項目間についても有意な差は確認されなかった．ところが実験参加者の行動を分析したところ，行動は以下の 2 つのパターンに分けられた．

1. 教科書を見に行くときに，ロボット 2 体の間を通る
2. 教科書を見に行くときに，ロボット 2 体の間を避け，いずれかのロボットの後ろを通る

条件ごとに実験参加者がどちらの行動をとったか人数を計測した（表 1）．フィッシャーの正確確率検定により有意な差が確認されたため，事後検定を行なった．その結果，Overlap 条件と Delay 条件との間に有意な差が確認された（$p<.05$）．この結果は，Delay 条件よりも，発話の重なりが生じる Overlap 条件の方がロボットの間を避けて通る実験参加者が多いことを示している．

	ロボットの間を通る	ロボットの間を避ける
Overlap	4	9
Default	8	5
Delay	11	2

表 1. 各条件における実験参加者の行動人数

4.5 考察

本節では本検証実験における実験 1 と実験 2 の実験方法の違いによる影響，および Overlap 条件と Delay 条件の結果の違いについて考察を行う．

まず実験 1 と実験 2 は本質的に異なる実験であると考えられる．実験 1 はロボット 2 体の発話行動の「時間の重なり」が人間に与える影響を調査することを目的としていた．実験結果から当初の実験の目的は達成されているが，ロボットが本来持つ身体性（インタラクションにおいて人間の身体を引き込むような動的な性質）は当然含まれてはおらず，より客観的な視点から印象評価がなされていたと思われる．一方，実験 2 は上記の意味でのロボットの身体性を含む，実験参加者の主観的な視点からロボットのインタラクションを捉えていたため，**表 1** で示したような

行動が生起したと思われる．このメカニズムを探ることは大変興味深いため，5 節において改めて議論したい．

5. 「時間」に基づくインタラクションデザイン

人工物（エージェント）が内部モデル（他者モデル）を持っているかのように振る舞わせることは，自律性が高まった人工物（AI システム）を人間に理解させるためのデザイン原理として重要である．特に本研究では「時間」に注目し，発話行動の時間的重なりによって人に人工物の他者モデルを想定させることができるインタラクションデザインの枠組み ***Temporal Overlapping*** を提案した．4 節で述べた実験結果に基づき，この提案した枠組みの意味について議論したい．

現時点での仮説的な説明を**図 8** に示す．この図を簡潔に説明すると以下のとおりとなる．

1. Overlap 条件の実験参加者は，発話行動が徐々に重なっていく 2 体のロボットを観察した（図中のロボットの Utterance 間にある Overlapping の部分の変化に注意）
2. 発話行動の時間的重なりから，2 体のロボットが予期的に振舞っているように実験参加者には見える（図中の Prediction を認識するようになる）
3. 上記の 2 より，ロボットに「他者モデル」を想定するようになる

この理由としては，実験参加者は同調的な発話行動を行う 2 体のロボットを観察するだけであるが，人間には「身体の二重性」（「外に向かう身体」と「内に向かう身体」）があるため，それを無意識にロボットに「投射」（プロジェクション）してしまい，ロボットにも「他者モデル」（「内に向かう身体」）があると想定してしまうからであると推測できる．

上記 1〜3 のプロセスをとおして，実験参加者は 2 体のロボットに他者モデルを想定し，さらにロボット間に社会空間を認識したため，Overlap 条件ではロボット間を通るのを避け，ロボットの後ろを通ったのではないかと考えられる．

この社会空間の認識は，インタラクションに参与している人の主観的な時間（「いま」）においてのみ立ち現れると考えられる．現在，このプロセスのより詳細な検討を行っているが，「時間」と「プロジェクション」の関係は人間の認知における本質的なメカニズムであると思われる．今後はこのメカニズムの解明とともに，その工学的な利用を考えていきたい．

すでに述べたように，人工物が内部モデルを持っているかのように振る舞わせることは，自律性が高まった人工物（AI システム）を人に理解させるためのデザイン原理として重要である．今後は，この観点から，「時間」に基づく人と人工物のインタラクションデザインについて研究を進めていく予定である．

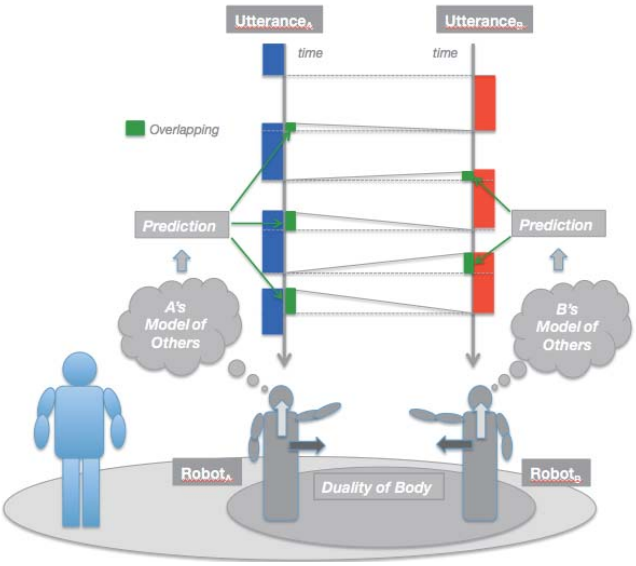


図 8. ***Temporal Overlapping*** と実験結果の仮説的説明

参考文献

[Baker 17] Chris L. Baker, Julian Jara-Ettinger, Rebecca Saxe and Joshua B. Tenenbaum, Rational quantitative attribution of beliefs, desires and percepts in human mentalizing, *Nature Human Behaviour* 1, pp. 1-10, 2017. DOI: 10.1038/s41562-017-0064.

[Imayoshi 12] Imayoshi, A., Munekata, N. and Ono, T.:Augmented Social Space: Robots Can Generate Context-Aware Adaptive Behaviors According to the Activity of Communications, *Proc. the 2012 IEEE/RSJ Int. Conf. Intelligent Robots and Systems (IROS 2012)*, Workshops and Tutorials, TW8_0011, 2012.

[Imayoshi 13] Akira Imayoshi, Hiroshi Yoshikawa, Nagisa Munekata, Tetsuo Ono. Robots that Can Feel the Mood: Adaptive Interrupts in Conversation Using the Activity of Communications, *Proc. of 1st International Conference on Human-Agent Interaction (iHAI 2013)*, 2013.

[水丸 17] 水丸和樹，坂本大介，小野哲雄（2017）．複数ロボットの発話の重なりによって創発する空間の知覚，HAI シンポジウム 2017，G-15，2017.

[小野 01] 小野哲雄，今井倫太，石黒浩，中津良平．身体表現を用いた人とロボットの共創対話，情報処理学会論文誌，Vol. 42，No. 6，pp. 1348-1358，2001.

[Ono 01] Tetsuo Ono, Michita Imai, Hiroshi Ishiguro. A Model of Embodied Communications with Gestures between Humans and Robots, *Proc. of 23rd Annual Meeting of the Cognitive Science Society (CogSci2001)*, pp. 732-737, 2001.

[小野 13] 小野哲雄，今吉晃．「空気を読むロボット」：コミュニケーション空間を利用した人を動かす HAI デザイン，『人工知能学会誌』，Vol. 28，No. 2，pp. 284-289，2013.

[小野 16] 小野哲雄：「プロジェクション・サイエンス」の視点からの認知的メカニズムのモデル論的理解，2016 年度日本認知科学会第 33 回大会，OS03-2，2016.

[鈴木 16] 鈴木宏昭：プロジェクション科学の展望，2016 年度日本認知科学会第 33 回大会，OS03-1，2016.

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

ロボットを用いた自己の外部投影による行動変容のモデル化

The model of behavioral change induced by external self-projection using a robotic system.

高橋 英之[*1, 2]
Hideyuki Takahashi

石黒浩[*1, 2]
Hiroshi Ishiguro

[*1] 大阪大学
Osaka university

[*2] JST ERATO

Recently, there are a lot of communication robots that are aimed to be a good human partner. We believe that these robots can also be a good tool for inducing the deep self-understanding throughout the conversation with these robots. We sometimes project ourselves to communication robots and this external self-projection helps to know about ourselves objectively. In this presentation, we would like to propose the model connecting external self-projection to behavioral alternation. Further, we also discuss how a robotic system can facilitate the behavioral alternation by introducing our several recent findings.

1. はじめに

近年，様々なコミュニケーションロボットが開発されている．これらのロボットは，人間のパートナーとして生活に溶け込み，我々の暮らしをより豊かにすることが期待されている．一方で，ロボットによってもたらされる“豊かさ”とは何なのであろうか？例えば，ロボットが人間の友人や恋人としてずっと寄り添い続けることが，はたして我々人間にとって長期的な豊かさとなりえるのであろうか？そのような人間とロボットの親密な関係性に価値を見出す人はもちろんいると思われる一方で，どこかそういう光景に違和感を覚える人も同時に存在する [岡田 2014]．現状では，コミュニケーションロボットがもたらす具体的な効用については，まだ普遍的なグランドデザインが描けていないように思われる．

我々は，コミュニケーションロボットが提供する一つの価値として，ロボットとの交流により，人間の自己の外部投影を促進し，行動変容を引き起こすことで個人の成長につながる“気付き”を生じさせることにあると考えている．本発表では，「ロボットを用いた自己開示の促進」と「ロボットを用いた批判的思考の促進」という二つの具体的な研究事例を紹介することで，ロボットが促す自己変容過程のモデル化について議論したい．

2. ロボットを用いた自己開示の促進

ミヒャエル・エンデの児童文学「モモ」の主人公の少女モモは傾聴の達人であり，モモに自分の話を聞いてもらった人たちは，自分の本来的な目的や願望（私的欲求）に対する気づきを取り戻すという．この作品中で，モモのこのような傾聴術の秘訣として「モモ自身が空っぽであり，聞いた内容について善悪の判断をしないこと」があるとしている．すなわち，モモに話を聞いてもらう人は，自らの発言がモモに評価されているという意識が希薄なため，社会的通念などから自由に自己の気持ちを開示することが可能になると思われる．

我々はこのような話からヒントを得て，ロボットを用いた傾聴システムの可能性について研究を行っている [Uchida 2017] [Kumazaki 2018] [高橋 2018a] ．ロボットは話し相手としての一定の存在感を有している一方で，社会と連続的な存在ではなく，人間の傾聴者と比較して，人間は社会的通念から自由に様々な私的欲求を開示できるのではないかと考えた．

連絡先：高橋英之（大阪大学） takahashi@irl.sys.es.osaka-u.c.jp

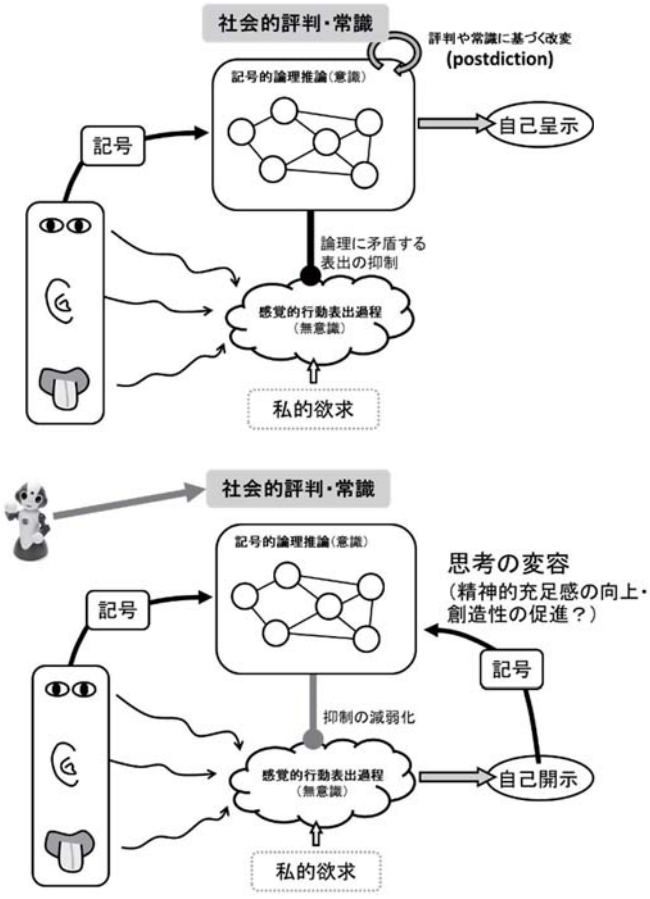


図 1. 自己呈示（上）とロボットによる自己開示（下）のモデル

これまでの検討から，特にネガティブな自己に関する話題に関して人間相手よりもロボット相手に話をすることを好む被験者の割合が多いこと，さらに fMRI による脳機能計測による検討から，このようなネガティブな自己の表出は脳の報酬系の活動を高めることが示唆されている．さらに興味深いことに，誰もいない環境よりも，ロボットがいる環境において，人間はよりネガティブな自己を開示する傾向が強いことも示されている．これは，ロボットが単に人間よりも存在感が希薄なためこのような傾向が生ま

れているのではなく，ロボットに人間のネガティブな自己開示を引き出す何らかの機能性があることを示唆している．

ロボットを用いた自己開示の促進に関するモデル

図 1 はこのようなロボット傾聴に関して我々が想定しているモデルである．傾聴の文脈において，自己呈示と自己開示という二種類の自己についての言及がみられることが知られている．我々の定義における自己呈示とは，社会的に自分のあるべき姿を提示することであり，その表出の論拠を他者と共有可能な形で論理的に述べることが可能である．ただし論理は後付再構成をすることも可能であり，社会的評判や常識の制約を満たすように常に論理は改変される．一方で，自己開示とは自分でも自覚しきれていない私的欲求の直感的表出によるものであり，その表出の原因を論理的に説明することが難しいため，論理による改変が行われにくい．基本的に，社会的に共有可能な論理は直感に優越し，社会的評判や常識を意識している際には，論理は強い制約により自らの表出を制限する．しかしロボットが相手の場合には，社会的評判や常識への意識が減弱し，論理の制約が弱まることにより，私的欲求にもとづく表出が自己開示として行われる．私的欲求そのものは言語化することが難しいが，自己開示した発話内容は私的欲求を源とするものであり，人間は自らの自己開示を外的に表出することにより，自己の私的欲求に対する気づきを得ることができる．このような気づきが，長期的な私的欲求にもとづく行動変容につながると想定している．

今後の研究の課題

ロボットが人間のネガティブな自己開示を引き出す（外在化させる），という事例は再現性が高く，有効なロボットの利用法につながる可能性を秘めていると思われる．一方で，行動療法のように外的な教示や誘導により直接的に人間行動を変化させる手法と比較して，このような自由な自己開示を引き起こすことの有用性や実効性を定量化することが難しく，今後，その評価法を確立する必要がある．有効な評価法についての一つの可能性として，我々の予備実験のデータから，ネガティブな自己開示は，ポジティブな自己呈示と比較して開示内容が被験者間でばらつく（多様性が大きい）ことが示唆されている．すなわち自己開示がネガティブだということは，より個人の固有性に先鋭化した自己認識をしていることを意味しており，このような固有性の認識が社会集団における真の意味での多様性を生み出し，その集団の活動を創発的なものにしていくのかもしれない．

3. ロボットを用いた批判的思考の促進

もう一つ，ロボットを用いた自己の外部投影について我々が取り組んでいるテーマとして批判的思考の促進がある．我々は思い込みや先入観によって思考が方向付けられやすく，日常的に批判的思考を行うことはとても難しい．心理学において，このような思考を妨げる先入観などの要因のことを「確証バイアス」と呼ぶ [Nickerson 1998]．真に客観的に物事を考えるとは，様々な今ここの状況に縛られた“主体”としての自己を離れて，“客体”として客観的に自己を捉える必要がある．

このような問題意識から，我々は，小型ロボットを用いた自己客観視システムを提案している[高橋 2018b]（図 2）．本システムでは，まず被験者に単独で，様々な価値観のトピック（例えば，「考え方の違いを話し合いによって解決することは重要である」）についてそれぞれ自分が「賛同する」か「賛同しない」を二択で選択してもらい，さらに「その理由は○○からです」の○○を埋める形でその選択の理由をパソコンのソフトウェアにより回答してもらう．そしてその後，小型ロボットと対面し，被験者が事前に入力した自らの意見をそのまま主張する小型ロボットの意見をすべて反論するように被験者に教示する．このシステムにより，自らの考えを外部投影（客体化）することが可能になり，明示的にそれを否定してもらうことで批判的思考が促進するのではないかと考え，このシステムの実効性について現在，検討を行っている．

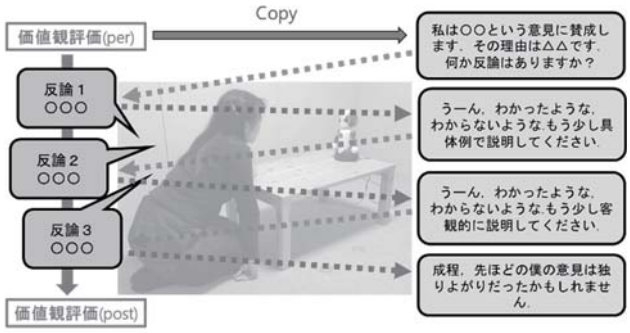


図 2. ロボットを用いた批判的思考の促進システムの概要

これまでの実験から，このシステムを用いることで，被験者は自らの考えを自発的に変容させることが示唆されている．特に自らの価値観が乗り移ったロボットに繰り返し被験者の反論に対して食い下がらせることで，表面的な反論を超えた被験者の熟考を引き出せることが分かった．また特に日ごろから行動に反映させていない価値観については，このシステムを用いることで考えが深まったり，考えが変容したりする傾向が強いことも示唆されている．

ロボットを用いた批判的思考の促進に関するモデル

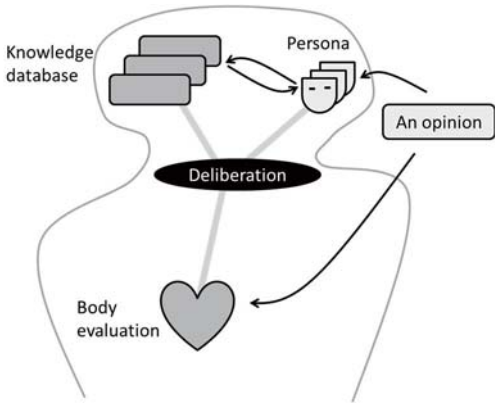


図 3. 批判的思考のモデル

図3は，批判的思考に関して我々が想定しているモデルである．我々がある意見に対して価値判断を行うプロセスは，明示的な知識や論理にもとづいて判断するプロセスと，身体感覚にもとづく快・不快で判断するプロセスの二つがある．論理的に判断するプロセスは，自分が現在どのような社会的立場をとっているのかというスタンス（ペルソナ）によって修飾される一方で，身体感覚はより文脈に依存しない普遍的な評価プロセスと言える．そして我々の考える批判的思考とは，論理にもとづくプロセスと，身体感覚にもとづくプロセスが両方調和的に働くことで生じる意見であると定義する．今回提案するシステムによって，繰り返し

被験者に反論を要求することにより，被験者の普段使わない評価プロセスを活性化し，それにより異なるプロセスを多角的に用いた思考の深化を実現しようと考えている．特に論理のみでの思考は，解が一つの方向に固定化する傾向が強いため，そこに身体感覚という論理では説明しきれない複雑システムを加えることにより，より創発的な思考が可能になるのではないかと考えている．

今後の研究の課題

提案システムは，まだ予備実験の段階であるが，被験者に思考を促す一定の効果があることが示唆された．このシステムの肝は，外部から特定方向への価値観のバイアスを与えずに，被験者自身で考えさせ価値観を変容させることにある．多くの既存システム（例えば情報推薦システム）は，何らかの形で開発者が使用者を一定の方向に誘導するような意図が，顕在的・潜在的に組み込まれている．一方で本システムの狙いは，自分自身と自問自答することにより，外部からの価値観の流入がない「考える場」をユーザーに提供することにある．このようなシステムがどのような長期的，短期的な利益をユーザーにもたらすのかは未知数であるが，一方でアクティブラーニングなど能動的な学習の重要性が叫ばれる今日において，考える場を提供するサービスには社会の中で一定の価値があるのではないかと考えている．

今後は，本システムを使用することで，単純に思考変容が生じることを示すだけではなく，このような思考変容にどのようなポジティブな意味合いがあるのかを検討していく必要がある．一つの研究の方向性としては，システムの使用前後で被験者が行う価値観の理由づけがどれだけ深化したのか，第三者評価により検討することがあげられる．

4. まとめと議論

今回の発表では，我々が取り組んでいるロボットを用いた自己の外部投影とそれによる行動変容モデルについて，二つの具体的な事例を交えつつ議論を行った．このようなシステム開発において今後重要になってくるのは，どのようにその有用性を評価するのか，という点がある．我々の一つのアイディアとして，このようなシステムを用いることで，集団の構成員の多様性が増加し，より集合知が働きやすくなるのではないか，という点について考えている．このようなシステムが集団行動に与える影響を評価する上で，単体の被験者を対象にした心理実験だけでは限界があり，今後はシステムにより個が集まったグループ全体のパフォーマンスがどのように向上するのか，という視点が必要になってくる．その観点から，我々は本発表で述べた個の行動変容を引き起こすシステム開発に加えて，それぞれの個が集まった集団のパフォーマンスを評価する課題の提案も行っている．具体的には，“人狼ゲーム”と呼ばれる会話ゲームを改良した課題を提案している [Takahashi 2017]．今後はこのような課題を用いて，自己の外部投影を行うロボットシステムの有用性についてより具体的な提言を行っていきたいと考えている．

参考文献

[岡田 2014] 岡田美智男，松本光太郎: ロボットの悲しみ コミュニケーションをめぐる人とロボットの生態学，新曜社，2014.

[Uchida 2017] Uchida, T., Takahashi, H., Ban, M., Shimaya, J., Yoshikawa, Y., & Ishiguro, H. A robot counseling system—What kinds of topics do we prefer to disclose to robots?. In Robot and Human Interactive Communication (RO-MAN), 2017 26th IEEE International Symposium on (pp. 207-212). IEEE.

[Kumazaki 2018] Kumazaki, H., Warren, Z., Swanson, A., Yoshikawa, Y., Matsumoto, Y., Takahashi, H., ... & Kikuchi, M. (2018). can robotic systems Promote self-Disclosure in adolescents with autism spectrum Disorder? a Pilot study. Frontiers in Psychiatry, 9, 3

[高橋 2018a] 高橋英之，守田知代，島谷二郎，吉川雄一郎，石黒浩., 内藤栄一， ロボットに誘発される自己開示とそれに付随する線条体の活動., 第 20 回ヒト脳機能マッピング学会，2018.

[高橋 2018b] 高橋 英之 , 島谷 二郎 , 小山 虎 , 吉川 雄一郎 , 石黒 浩，小型ロボットを用いた自己客体視システムによる思考変容の誘発， ヒューマンコンピュータインタラクション研究会予稿, 2018.

[Nickerson 1998] Nickerson, R. S., Confirmation bias: A ubiquitous phenomenon in many guises. Review of general psychology, 1998, 2(2), 175-220.

[Takahashi 2017] Takahashi, H., Ban, M., Osawa, H., Nakanishi, J., Sumioka, H., & Ishiguro, H. (2017). Huggable communication medium maintains level of trust during conversation game. Frontiers in psychology, 8, 1862.

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

HMDによる構成的空間を舞台とした「三人称的自己」の顕在化

Activating Third-Person Perspective Self on HMD using Constructive Approach

小鷹研理 *1
KENRI KODAKA

*1名古屋市立大学芸術工学研究科
Graduate School of Design and Architecture, Nagoya-city University

This articel discusses a new paradigm of interaction study between a player and an avatar in HMD space based on an understanding of cognitive mechanisms of the out-of-body experience.

1. はじめに

通常, 我々の頭部と視点は空間的に一致したものと体感されるが, （夢や幽体離脱のような）特殊な条件下では, 両者は切り離され, 自身の身体を外側から眺めているような主観状態となる. このようなかたちで感じられる自己のあり方に対して, 筆者は既に発表した論考 [小鷹 2017] において「三人称定位」という用語を与えている. 筆者の研究室は, ここ数年, 視点の位置を自由に切り替え可能な HMD 技術の恩恵を受けるかたちで, HMD 空間内のインタラクションを通して「三人称定位」の設計を目指すプロジェクトをすすめているところである. 本稿の主たる目標は, この種の探求が学術的に如何なる意義を持つかを整理し（本稿で「三人称定位」は, 新たに定義する deownership という投射概念で読み替えられていく）, さらに, この新しいタイプの自己感の投射を, 実験科学のフレームの上で適切に処理するための道筋を提示することにある.

2. インタラクション研究における投射

情報関連技術の急速な小型化・高速化に伴い, 「インタラクション研究」と呼ばれる分野が, 学術研究の中で市民権を得るようになって久しい. こうした分野が新しく創設されなければならなかった背景には, 従来の学術研究の枠組みでは, 人間と人工物の間に成立する（とりわけ主観的な）関係性を評価するための道具立てを十分に整備されていなかったという事情が関係しているだろう. 実際, 2000 年前後にあっては, インタラクション分野は, 今よりも, デジタルアートとしての色合いを濃くしていたことは記憶に新しい. いずれにせよ, その後のインタラクション研究の盛り上がりが顕著に示すように, 人間と人工物（環境）との間に何かしらの interactivity を設計することそのものに対するモチベーションは非常に高い. このモチベーションは何によって支えられているのだろうか. 筆者は, この問いに対して, 「自己の投射」という切り口で整理することが有効であると考える. [ハラリ 2015] によれば, 人間と他の種を決定的に分かつものは, 集団で虚構に共感する能力であるとしている. この虚構には, 例えば, 神話, 宗教や国家といったものが代入されるが, これによって, 数百・数千というオーダーで集団が一致団結できることこそが, 現在の生態系の地位を得るうえで, 決定的な出来事（認知革命）であったと記されている. このように, 人間という種の本性には, 自己を周囲に投射し, より抽象的なレベルでの＜大きな自己＞を形成することに対する欲望がある. そして, 近年の情報技術の高度化は, この自己の対象を, ついにモノやイメージといった「人工物」にまで広げていくことを可能としている. そのように考えると, 近年のインタラクション研究の盛況は, 人類学的な必然として理解可能である.

連絡先: 464-0083 愛知県名古屋市千種区北千種 2-1-10, kenrikodaka@gmail.com

2.1 agency

さて, インタラクション研究において永らく主題となってきた投射の一つは, （研究の当事者がそれを意識しているか否かを別として）「自己主体感：sense of agency」と呼ばれるものである. agency は, まさに, 人工物に対して＜主体的に関わっている＞という感覚と関わるものであり, インタラクションにおける「心地よさ」「一体感」といった主観的体験の評価に関わるファクターとして, デザインやインタフェース研究でも注目されている [渡邊 2015]. 一般に, agency の投射は, 運動感覚と人工物に生じるイベントとの間で時間的同期が成立していることが要件となる. agency の特異性は, この遅延が許容範囲内であれば, 人工物がどのような外観であっても, また（イベントの生起が感知できる限りにおいて）人工物との距離がどれほど離れていようとも, 投射が成立してしまう点にある *1. この種の agency の「節操の無さ」を理解するには, 例えば, くしゃみと同時に遠方の建物のガラスが偶然割れるような極端な状況に際しても, 「まるで自分がガラスを割ってしまった」ような感触が得られるであろうことを想像すれば十分である.

2.2 ownership

対照的に, 「融通の効かない」投射の代表的な位相として挙げられるのが, ownership（所有感）である. ownership は, 厳密な意味で, 「それが自分の身体そのものであると感じられる感覚」のことである. agency と ownership が独立した位相であることは, 鉛筆で何かを書いている時, 鉛筆との一体感を感じることはできても（agency）, 鉛筆そのものが自分の手や指そのものである（ownership）とは到底感じられないことを思い出せば十分である. 1998 年に端を発する Rubber Hand Illusion（RHI）の一連の研究によれば, ownership の投射を構成するための空間要件は, 1）対象イメージが身体と（向きも含めて）同型的な外観を有しており（固有感覚-視覚間の同期）, 2）それらが, 身体の周囲（身体近傍空間）に呈示されていること, の二点に集約される. この, ownership の投射距離の限界を決定する身体近傍空間の範囲は, 手であれば数 10cm

*1 とにもかくにも投射が成立することと, それが（デザインにおいて主題となる）“性質の良い”投射であるかどうかは別の水準の話である. その意味で, 本稿は minimal な agency が立ち上がる条件を議論していることに注意されたい.

程度, 全身であれば 1 ～ 2 m 程度であることが知られている [Serino 2016]. RHI には, 運動感覚を同期させる Moving RHI と呼ばれるタイプのスキーマも存在するが [Kalckert 2012], 運動感覚の付与（によって生じた agency）が, ownership を高めることに寄与するとは限らない点は重要である. 実際, 筆者らが, 昨年度, 手の真上に設置したスクリーンに手の影を投影することで, 影に ownership を投射できることを示した研究の中では [Kodaka 2017a], 手の運動の有無で, ownership 変調の副作用と考えられる手の位置感覚の移動量（proprioceptive drift）に有意な差は観測されなかった. さらに, 幾何学的な形状をした影を実際の手の動きと連動させた場合, 影を動かしているという感覚（agency）は得られた一方で, ownership 関連の指標は有意な反応を示さなかった. これらの結果は, agency が ownership をゼロから boost できない, その原理的な限界を鮮やかに示すものである. 関連して, よく誤解されることであるが, ownership の投射は, 視触覚間の同期すら絶対的な要件としてカウントしない. 筆者らは, 影のみならず鏡を使った投射においても, 全く手を動かさない状態で, ownership を鏡像に投射できることを示している [石原 2017]. さらに, [Durgin 2007] は, 空間要件を満足する位置にセットしたラバーハンドに単にレーザーを当てるだけで, 85 パーセントの被験者が, 照射部分に触覚を感じることを報告している. このように, ownership の投射の本性には, 極めて受動的な特性が見出される.

2.3 投射距離と＜出来事の直接性＞のトレードオフ

agency は, ownership と異なり空間的自由度が極めて高いため, 投射先のイメージのパターンを問わず, 様々なインタラクションに適用できる. 一方で, そうした際限の無い自由度は, agency の究極的な形態が「脳波リモコン」的な投射であることからもわかるように [小鷹 2017], プレイヤー自身の生々しい物理的な身体の感覚を, 身体外空間には持ち込まないことよってはじめて成立してきた, という逆説がある. 他方, ownership の投射は, ときに agency とは比べ物にならない強烈な違和（ある種の＜生々しさ＞）をつくりだす. この違和は, むしろ, 自覚レベルで, （投射対象が）自分の身体でないことが明らかなときに, より増強されるように思われる. この現象的観察は, ownership の投射において, 無意識レベルの（ボトムアップな）プロセスが作用していることと無関係ではない. 実際, ownership の投射されたラバーハンドを, 予告なく鋭利な刃物で突き刺そうとすると, 強い反射的な回避反応が生じることがわかっている [Armel 2003]. こうした回避反応は, 投射対象への直接的な刺激が, 「＜自分＞の感覚系に＜直接的な出来事として＞作用している」という信念と関連づけらているはずだ. 本稿では, この種の無意識的信念を＜出来事の直接性＞（あるいは単に＜直接性＞）と呼ぶ. この＜直接性＞は, 空間的自由度の高い agency の投射の過程で（多くの場合）跡形もなく消失してしまう. すなわち, 一般に, ＜直接性＞と投射距離は, トレードオフの関係にあると考えるべきである.

筆者の理解では, 従来の「インタラクション研究」のほとんどが, agency の水準の投射に留まっており, ownership を直接的に扱うものは, いまだに数えるほどである（例えば, [石原 2015]）. この背景に, ownership の投射に課される, 厳しい空間要件が強く関係していることは間違いない. そして, この空間要件に関わる困難は, 同時に, ＜直接性＞の投射に関して現在の「インタラクション研究」の限界を示しているように思う. 本研究の関心と照らして, HMD 空間におけるアバターの操作を例に, この限界を以下で指摘したい. まず, アバター全身に対して ownership を投射するためには, 極めて近接した状態で背後よりアバターを視界に捉える状況を取らざるを得ない（Full Body Illusion：FBI）. この場合, アバターの周囲を俯瞰できないうえに, アバターの顔面を含む正面を視界に捉えられない. これは, あらゆる視点からの見えを潜在的に構成可能な HMD 空間の設計において, 大きな制約とならざるを得ない. 一方で, 対面したアバターが, HMD 装着者の身体動作と連動して動くだけであれば, それは agency の水準の投射に留まるものであり, 仮想空間の内部でアバターに生じたことを, 文字通り＜自分自身＞の身に起きた出来事として感じることは困難である [*2]. それでは, 対面状況を含むようなもう少し緩やかな中距離的なスケールで, アバターに＜出来事の直接性＞を投射することは如何にして可能か.

3. 第三の投射：deownership

筆者は, 以上の問題に対して, （agency と ownership をある種の二項対立と捉えたうえでの）新たに「deownership」と呼ぶ第三項的な位相区分を提案したい. deownership は, ownership に対して, ＜反対＞や＜離脱＞、および＜下降＞などの意味を付加する「de」の接頭語を与えた, 筆者による造語である. 筆者が, この新たな位相区分に対応する主観状態として想定するのは, 幽体離脱における自己感である. 実際, この用語に含意されているのは, ownership から, 空間的および心理的に離脱すること, あるいは ownership で特徴付けられる身体的自己を, （ownership を完全には解体しないままに）反対側から眺めているような感覚, さらには, ownership を視点から切り離して（相対的に）下降させていくイメージである.

幽体離脱の発生状況は, 体験者ごとにかなり多様である. 距離的な側面に注目すると, 自身の身体にかなり接近している場合と, 数 m 以内の中距離的な場所から自身の身体を眺めている時とで大別されるという [メッチンガー 2015]. さらに, 後者の場合, 典型的には, 仰向けで横たわっている自身の身体を上方より対面的に眺めるという視点がとられる. 以上は, deownership の投射が, ownership の投射に課される空間的制約よりも, かなり緩和した条件で生じ得ることを示している. 興味深いことに, 幽体離脱経験者の約半数は, 視点の位置をコントロールできない. この受動性に関して, deownership は, むしろ, ownership と親和的である. さらに, 幽体離脱においては, 多くの体験者が, 視点の位置に身体の存在を感じていない. すなわち, 視点の位置に, ownership によって紐付けられた「身体的自己」が存在しない. この点は, deownershp の特異性を理解するうえで非常に重要である. なぜなら, この身体の不在こそが, 幽体離脱的な投射と, 日常的に 「鏡やモニタ映像に映っている自分を眺めている」状況とを区別するものであるからである. 後者の場合, あくまでも身体の本体は視点の側にある（という信念がある）. 視点と身体は一体となったまま, ただ身体のイメージのコピーが, 身体外のいずれかの断面に恣意的に投影されているというだけである [*3]. 一方で, 幽体離脱の投射で主題となる deownership は, 文字通り, 「身体の投影された場所に自分の身体（の本体）が存在する」という事態であり, これは, 端

*2 ownership の空間要件をはみだしても, 「共感」（empathy）と呼ばれる機制によって, 他者の痛みを我が身のものと引き受けることは可能である. ＜出来事の直接性＞と「共感」は明らかに類似した概念であるが, 投射の対象が主観レベルで「自分」であるか「他者」であるか, において決定的に異なるように思われる. いずれにせよ, この違い（あるいは共有部分）を概念的に整理することは, 学術的な意味で非常に重要なことであり, 今後の課題と認識している.

*3 本稿の文脈では, 日常的に鏡像を見ているときに投射されているのは, agency と考えるのが自然であるが, 鏡像は（鏡像に照り返された位置に存在する）身体的自己への信念を積極的に強化する作用を持つ点において, やはり特別な意味を持つ投射である.

的にいって, 「見る自己」と「身体的自己」の分離である.

minimal phenomenal selfhood の議論に倣って, 自己の主体を「視点的な自己」に置くならば [Limanowski 2014], agency や ownership の投射は, あくまでも自己の主体を保存したままに, 自己の一部を外部に投射するという形態がとられていることがわかる. 一方で, deownership の投射は, これとは逆に, 自己の一部を（身体として）特定の場所に固定したままに, 主体そのものが, 外部に投射されているという構図（被投射による投射）がとられる. このようにして投射された「見る主体」において, 「身体的自己」において生じた出来事が, どのような＜直接性＞を帯びるかを考えるのは興味深い. 一過性の幽体離脱が, 生命にとっての危機的状態で生じることが多く報告されていること, したがって, 幽体離脱が感覚系の被る痛みなどの負担を回避するための機能を有している可能性を勘案すれば, deownership における＜直接性＞が, 個々のモダリティーに関して, ownership と同水準の強度を持つとは思えない. それでは, 幽体離脱者にとっての身体は, プレイヤーにとっての（例えば）マリオと同じ程度のリアリティーしか持ち得ないのだろうか. ここには, ＜出来事の直接性＞の定義にも関わる, 非常に繊細な水準における, リアリティーの差異が存在するように思われる. こうした考察を踏まえると, 中距離的なスケールにおけるプレイヤーとアバターの関係において, アバターに生じる＜出来事＞としてのリアリティーを新たな段階へと引き上げていくための一つの方略として, 両者の関係を agency 的なインタラクションのみならず, 幽体離脱で生じている視点と身体の分離（deownership）という様相で捉えようとするアプローチには, 一定の可能性が秘められていることがわかる.

4. deownership を実験科学で扱うために

近年になって, agency および ownership が, 認知神経科学の分野で正統的な概念として認知されるようになった背景の一つには, 実験科学において, それらの強度を間接的に指し示すことが可能な客観指標が「発明」されてきたことが指摘できる. 他方, agency や ownership は, あくまで主観的な感覚を指し示すものであるため, 直接的には, アンケートによって rating されるほかない [*4]. では, deownership の主観的な強度は, どのような「質問」によって rating されることが適切だろうか. 重要なことは, deownership の投射は, 単に鏡で自分を見ている状況とは区別されなくてはならない. したがって, 視点と身体が分離していることに関わる主観的体験（例えば「自分の身体が, アバターの位置にあるような感じがする」「自分が, 身体から離れてしまっている感じがする」など）を直接に問うことが, まずは自然であろう. しかし, deownership の感覚が, 幽体離脱が示すように突如 0 から 1 へと boost する創発的な特性を有しているであろうことを踏まえると, 幽体離脱の誘発方法が確立していない現段階においては, 非常に曖昧な指標として機能せざるを得ない. したがって, deownerhip においても, 幽体離脱で生じている主観的変調に強く寄り添いながら, 何らかの複数の客観指標を先んじて仮説的に検討しておくことは, 研究コミュニティーにとって有益であるように考える.

このような客観指標の一つの候補として, Own Body Transformation（OBT）課題で計測可能な, 全身に関わる「空間変換能力」が挙げられるが, 既に [小鷹 2017] で述べているため, ここでは深入りしない. 本稿では, OBT においても問題となる「重力」の問題について詳細に検討する. 筆者らは, これまでに, deownership に関わる HMD のインタラクションを対外的に複数発表してきた [小鷹 2015][Kodaka 2017b]. 2017 年に Siggraph Asia で発表した「Recursive Function Space」（以下, RFS）は, 両手に保持したコントローラの位置から自分の上半身を眺める体験を可能とする. このとき, 右手に視点を映した際には, 常に自分自身の頭部に視点が収斂するように設計している（つまり, 視点の回転に関する agency が排除されている）. この設計思想は, 幽体離脱における, 受動特性と対応している点が重要である. さて, この擬似的な幽体離脱体験において, 体験者は「やばい」「きもちわるい」「oh-my-god」「weird」といった表現で違和感を訴える. 設計者である筆者自身の体感に照らすと, この違和感は, 視界に捉えられているアバターこそが, 「自分の本来あるべき位置である」という信念と関連づけられる. そして, RFS の体験中にあって, この違和感の濃淡は, アバターと視点との空間関係において著しく変化する（違和感の極大化するポイントは, 体験者によって異なる）. 筆者の研究グループは, 各種の展示会で, RFS のデモンストレーションを重ね, 体験者より（上記の反応を含む）種々のフィードバックを得ていく中で, deownership の投射の可否を左右する要因として, 「重力」に注目するようになった.

その後, さらに重力と deownership の関係を詳細に検討するために, 筆者らは, 「self-umbrelling（重力反転計画 α）」と呼ばれる HMD インタラクションを, 既に 2018 年 1 月の研究室展示「からだは戦場だよ 2018」で公開している. これは, 仰向けとなって寝転んだ状態で傘を開くと, 傘を保持している体験者の頭部（HMD）を起点とする一人称視点から, 傘のさらに上方から, 寝転んでいる自分自身（アバター）を見下ろす三人称視点へと変換するものである. このとき, 傘を開くことによって, 視点の位置は徐々に天井に向かって吹き上げられていく. このインタラクションにおいて重要なのは, 三人称視点をとった際の「視点的自己」に想定される身体の向き（うつ伏せ）が, 体験者の実際の物理的状態（仰向け）から反転していることである. そして, 前述の研究室展示において, ほぼ全ての体験者が, 「仰向け」から「うつ伏せ」の重力の反転を, ごくごく自然のことのように受け入れていたことは非常に興味深い [*5].

こうして蓄積されていった体験者のリアクションの観察を通して, deownership に関わる重要な変数として「重力」が浮上してきたのは非常に示唆的である. なぜなら, 既に述べたように, 仰向けで寝ている状態で, 視点のみが天井側へと移動し, 寝ている身体を対面状況で眺めるような対外離脱の典型的状況では, 視点側の「自己」にかかっている重力は, 主観的に反転していると考えられるからである. 臨床状況で右角回に直接電気刺激を付与することで誘発された対外離脱の事例 [Blanke 2002] でも同様に, 患者は実際には仰向けで寝ている状態であったにも関わらず, 天井からぶら下がるようにして漂い, 自分自身を見下ろしているような主観的状態であったことが報告されている. また, このような重力反転は, うつ伏せ状態の健常者に対しても, 実験室レベル（FBI の誘発）で確認されている [Ionta 2011]. 関連して, parabolic flight によって一時的に生じる micro gravity 状態にあって, 体が逆さまとなったような感覚, あるいは空間そのものが逆さまとなるような感覚（inversion illusion）が, 頻繁に報告されることがわかっている

*4 多くの場合, 何らかのデータが客観指標として機能するためには, 主観評価との強い相関を示すことが要求される. agency の投射に伴う temporal binding（主観的同時性の移動 [Stetson 2006]）や, ownership の投射に伴う proprioceptive drift（身体位置感覚の移動）はその一例である.

*5 この重力の反転作用における主観的感覚については, 体験者の一人である, 古谷利裕氏（画家・評論家）による, 投稿直前に発表された論考 [古谷 2018] に詳しい.

[Graybiel 1967]. こうした事実により, 幽体離脱が, 重力加速度を検知する前庭系の機能が何らかの原因で失調したことによる結果であるという考え方が発表されている [Blanke 2012].

以上を踏まえ, 筆者の研究グループは, 現段階で, 「重力反転錯覚が幽体離脱を誘発するうえでの基底的な前提条件を構成する」という仮説を採用している. これは, 実験科学的な文脈で, 重力反転に関わる知覚強度を, deownership の投射に関する間接的な評価指標として検討することを意味する. この仮説のうえでは, deownership の投射の設計が, 『重力反転錯覚の誘発』という具体的な課題へとブレークダウンされる点が重要である.

5. 展望

筆者の研究グループは, アバターを含む HMD 空間において, 幽体離脱的な投射を新たに導入するプロジェクトを, 二つの方向性（1：デモンストレーションの設計, 2：心理実験の実施）から並行的にすすめている. 前者は, （前章で紹介したような）幽体離脱的な視点変換を埋め込んだインタラクション空間を, （多少のエンタテイメント性も考慮しながら）具体的に体験可能なかたちで設計することであり, これは, 設計の自由度が飛躍的に高くなること, さらに比較的多数の人に体験してもらうことで, 多様なフィードバックを得ることができる点に利点がある. 後者は, 実験科学的な枠組みで, 認知的な要因が, deownership の投射において, どのように作用するかを慎重に検討していくことである. これら二つの課題のアウトカムは, お互いの設計に影響を与えるものであり, その意味で本プロジェクトの進行において両輪をなすものである.

後者に関して, 本講演では, 「姿勢要因が重力知覚に与える影響」を検討するべく, （既に実施している）HMD を用いた心理実験の内容を比較的詳しく解説する予定である. 残念ながら, 本稿では既に紙幅が尽きており, 詳細を割愛せざるを得ない（現在, 国内会議および国際ジャーナルに投稿する準備をすすめている）. 実験の結論のみを先取りすると, 「仰向け」状態は（「立位」「うつ伏せ」と比して）, 知覚される重力の方向性において強力な不定性を抱えているという知見を得ている. 「仰向けの主体は, 比較的簡単にうつ伏せの“気持ち”に転じることができる」と言えば, より伝わりやすいだろうか. この結果は, 仰向け状態で, 幽体離脱が報告されるケースが多いことに対応しているかもしれない.

この種の実験の知見を辛抱強く蓄積していくことで, 幽体離脱的な投射を科学的に議論するうえでの風通しの良い土壌を整備していくことが, 本プロジェクトの当面の課題である.

謝辞

本研究の一部は,JSPS 科研費 15K21281, および中山隼雄科学技術文化財団の助成を受けた.

参考文献

[小鷹 2017] 小鷹研理：「HMD 空間における三人称定位： 幽体離脱と Own Body Transformation からのアプローチ」, 日本認知科学会大会, 2017

[ハラリ 2015] ユヴァル・ノア・ハラリ, サピエンス全史, 河出書房新社, 2016

[渡邊 2015] 融けるデザイン ―ハード×ソフト×ネット時代の新たな設計論, BNN 新社, 2015

[Serino 2016] Serino, A. et al. (2016). Body part-centered and full body-centered peripersonal space representations. Scientific Reports, 5(1)

[Kalckert 2012] Kalckert, A., & Ehrsson, H. H. (2012). Moving a Rubber Hand that Feels Like Your Own: A Dissociation of Ownership and Agency. Frontiers in Human Neuroscience, 6, 40.

[Kodaka 2017a] Kodaka, K., & Kanazawa, A. (2017). Innocent Body-Shadow Mimics Physical Body. i-Perception, 8(3)

[Durgin 2007] Durgin, F. H. et al. (2007). Rubber hands feel the touch of light. Psychological Science, 18(2), 1527.

[石原 2017] 石原由貴・小鷹研理：「Mirror Visual Feedback を活用した鏡の移動による上肢の移動感覚の変調」, 情報処理学会シンポジウム・インタラクション 2017

[Armel 2003] Armel, K. C., & Ramachandran, V. S. (2003). Projecting sensations to external objects: evidence from skin conductance response. Proceedings. Biological Sciences / The Royal Society, 270(1523)

[石原 2015] 石原由貴・小鷹研理：「デスクトップ・プレゼンスのための身体変形感を誘起する背面タッチインタフェースの研究」, 情報処理学会シンポジウム・インタラクション 2015

[メッチンガー 2015] トーマス・メッチンガー, エゴ・トンネル 心の科学と「わたし」という謎, 岩波書店, 2015

[Limanowski 2014] Limanowski, J. (2014). What can body ownership illusions tell us about minimal phenomenal selfhood? Frontiers in Human Neuroscience, 8, 946.

[Stetson 2006] Stetson, C. et al. (2006). Motor-sensory recalibration leads to an illusory reversal of action and sensation. Neuron, 51(5), 6519.

[小鷹 2015] 小鷹研理・信田勇貴：「I am a volleyball tossed by my hands: 二人称視点を採用した幽体離脱の誘発」, 情報処理学会シンポジウム・インタラクション 2016

[Kodaka 2017b] Kodaka, K., & Mori, K. (2017). Recursive function space. In SIGGRAPH Asia 2017 VR Showcase

[古谷 2018] 古谷利裕, 「幽体離脱の芸術論」への助走, ÉKRITS (online) http://ekrits.jp/2018/03/2515/

[Blanke 2002] Blanke, O. et al. (2002). Stimulating illusory own-body perceptions. Nature, 419(6904), 269-70.

[Ionta 2011] Ionta, S. et al. (2011). Multisensory mechanisms in temporo-parietal cortex support self-location and first-person perspective. Neuron, 70(2), 363-74.

[Graybiel 1967] Graybiel, A., & Kellogg, R. S. (1967). Inversion illusion in parabolic flight: its probable dependence on otolith function. Aerospace Medicine, 38(11)

[Blanke 2012] Blanke, O. (2012). Multisensory brain mechanisms of bodily self-consciousness. Nature Reviews. Neuroscience, 13(8), 556-71.

Oral presentation | Organized Session | [Organized Session] OS-7

[3D2-OS-7b] [Organized Session] OS-7

Thu. Jun 7, 2018 3:50 PM - 4:50 PM Room D (4F Cattleya)

[3D2-OS-7b-01] Projection in Experience Sharing

○Eimei Oyama[1], Kohei Tokoi[2], Naoji Shiroma[3], Sosuke Nakamura[4], Tomoko Yonemura[5], Natsuo Suzuki[6], Takashi Omori[6], Hiroyuki Okada[6] （1. AIST, 2. Wakayama University, 3. Ibaraki University, 4. Hosei University, 5. Meikai University, 6. Tamagawa University）

3:50 PM - 4:10 PM

[3D2-OS-7b-02] Does literary reading enhance social abilities?

○Hidetsugu Komeda[1], Kenshiro Ichimura[1], Satoru Nishiyama[1], Miho Nishiguchi[1], Tomoya Watanabe[1] （1. Kyoto University）

4:10 PM - 4:30 PM

[3D2-OS-7b-03] A generative model describing the process of projection

○Hiroki Yokoyama[1], Hiroyuki Okada[1] （1. Tamagawa University Brain Science Institute）

4:30 PM - 4:50 PM

©The Japanese Society for Artificial Intelligence

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

体験共有における投射について

Projection in Experience Sharing

大山英明[*1] Eimei Oyama
床井浩平[*2] Kohei Tokoi
城間直司[*3] Naoji Shiroma

[*1] 産総研 AIST
[*2] 和歌山大学 Wakayama University
[*3] 茨城大学 Ibaraki University

中村壮亮[*4] Sousuke Nakamura
米村朋子[*5] Tomoko Yonemura
鈴木夏夫・大森隆司・岡田浩之[*3] Natsuo Suzuki, Takashi Omori & Hiroyuki Okada

[*4] 法政大学 Hosei University
[*5] 明海大学 Meikai University
[*6] 玉川大学 Tamagawa University

It is possible to share experiences of other person by reproducing the sensory information of the person in the same posture as the person experienced. We will introduce 'Experience Sharing System,' by which we can share the other person's experiences, describe various 'projections' in experience sharing, and report preliminary evaluation experiment of experience sharing system.

1. はじめに

ウェアラブル技術，ユビキタス技術の進展により，人が見たり，聞いたりしている視覚・聴覚情報を記録・配信することが，可能になりつつある．小説，コミック，テレビ，映画等のメディア作品の相当の部分を，様々な体験を読者・視聴者に追体験させる作品が占めているが，VR／テレイグジスタンス技術の進展に伴って，より高い臨場感を持って，様々な体験の追体験が可能になりつつある．

現実に様々な経験を体験している人(実体験者)が，ヘッドマウンテッドカメラやウェアラブルマイクロフォン(アレイ)等のセンサによって，その感覚情報を記録・送信し，それを，ヘッドマウンテッドディスプレイ(HMD)やヘッドフォン等の感覚情報再生デバイスを装着した人(追体験者)が，体験者が体験した状態(体勢)で，再生することによって，実体験者の経験を仮想的に追体験できる．これは，JST CREST「パラサイトヒューマンネットによる五感情報通信・環境センシング・行動導誘導」(FY2007-2012)において，前田らにより作業訓練用に提案された技術[Maeda 2011]であるが，HTC Vive や Oculus Rift CV1 を始めとして，広視野・高解像度の HMD が本格的に普及すれば，臨場感の高いメディアとして，爆発的に普及する可能性がある．これを，我々は体験共有システムと呼んでいる．暦本らの Jack In Head[Kasahara 2014]や，南澤らや株式会社アシックスによる東京マラソンの疑似体験の提供[ASICS 2016]を始めとして，体験共有技術について，活発に研究開発と応用が進められている．既に，HTC 社や Oculus 社他の商用 HMD には，様々な場所の 360 度動画像を見ることが可能なアプリケーションが提供されており，疑似的な世界旅行が可能となっている．

文献[大山 2017a]において，テレイグジスタンス[Tachi 2015][舘 2015]や遠隔行動誘導[Oyama 2016]における投射・異投射[鈴木 2016]について述べた．本発表では，体験共有システムについて紹介し，体験共有における，追体験者の手から HMD 画像上の実体験者の手や追体験者の手の CG への投射・異投射について述べる．さらに，体験共有における投射・異投射について本格的実験を行うための，体験共有システム試作機を用いた準備的な評価実験の結果を報告する．

連絡先：大山英明，産業技術総合研究所，〒305-8568 茨城県つくば市梅園 1-1-1 つくば中央第二，029-861-7298，029-861-3388(FAX)，eimei.oyama@aist.go.jp

2. 体験共有技術

2.1 体験共有の概念

時間的・空間的に遠隔地にいる実体験者の体験を，追体験者が，臨場感を持って追体験するためには，先ず，実体験者の体験時の感覚情報を記録・配信する必要がある．全ての感覚情報を記録・配信することが，理想ではあるが，再生技術の普及状況の観点から，短期的には，視覚情報と聴覚情報，並びに，視覚センサと聴覚センサの位置・姿勢情報の記録が重要となる．図1に示すように，ウェアラブル(ステレオ／マルチ)カメラによって撮影された，体験者の見ている映像に近い映像を，追体験者の HMD に送って，再生し，ウェアラブルマイクロフォンアレイによって記録された，体験者の聞いている音に近い音を，ヘッドフォンに送って，再生することにより，追体験者は実体験者の体験を，高い臨場感で追体験可能である．図 1 に，体験共有の概念図を示す．

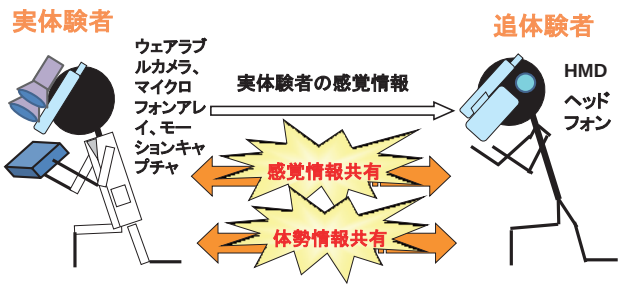


図 1 体験共有の概念図

体勢情報の共有は，主として視覚情報の共有により実現される．実体験者の視線方向は，視線方向を示す CG 図形をカメラ画像に AR 表示することにより提示し，それにより追体験者が実体験者の視線方向に追従する．実体験者の視線方向のカメラ画像に映っている身体の部位の状態や地面の状態から，模倣すべき体勢を推測し，それを体験者が真似る．実体験者のウェアラブルカメラに写らない身体情報については，ウェアラブルなモーションキャプチャ等を利用して取得し，後述する AR 表示により体勢情報の共有を図る．カメラ追体験者の HMD の視野に表示できない身体情報についても，AR 表示を利用する．

ただし，通常，追体験者は実体験者の頭部運動に十分高速・高精度に追従できるわけでは無く，追体験者の頭部姿勢と実体験者のカメラ画像との間に不整合が発生し，これは VR 酔いを発生させることが多い．また，常時追従することは疲労を伴う．画像安定化技術を利用した視覚情報の非同期共有技術[Shiroma 2010][Kondo 2011]により，これらの悪影響を低減可能である．

2.2 体験共有のための AR 表示

特に全周囲カメラを利用した場合に顕著であるが，追体験者が実体験者の視線方向をカメラ画像から把握するのは容易では無い．カメラ画像に視線方向の情報を付加することが不可欠である．体験共有のための AR 表示として，実体験者の視線方向を示す図形の表示が不可欠であり，その一例として，視線マーカーと呼ばれる実体験者の視線方向を示す CG 図形を表示する手法がある[Maeda 2011]．視線方向を示す矢印状の CG 図形でも提示可能である[Shiroma 2010]．また，カメラに映っていない，身体情報の提示技術として，実体験者の全身画像を提示する手法がある[Suzuki 2017][大山 2017b]．図 2 に体験共有のための AR 表示の一例を示す．

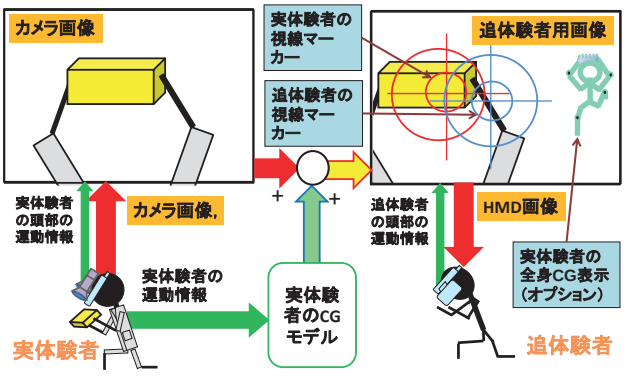


図 2 体験共有のための AR 表示

なお，遠隔行動誘導の技術を利用し，追体験者の CG 画像をカメラ画像に重畳表示する機能も容易に実現できる．追体験者の手の CG 画像があることで，より正確な模倣が可能と期待できるが，一方で，実体験者の注意が分散するため，臨場感に影響がある可能性がある．

3. 体験共有における投射・異投射

テレイグジスタンスや遠隔行動誘導と違って，体験共有の場合，HMD に表示される実体験者の身体は，追体験者の意図に従って動いてくれる分けでは無く，模倣する対象である．よって，テレイグジスタンスや遠隔行動誘導のように，追体験者の身体が実体験者の身体に単純に投射・異投射されるわけでは無い．体験共有においては，追体験者が実体験者に「なりきり」，すなわち，追体験者が，実体験者の過去の動作から，将来の動作パターンを予測し，実体験者の映像と十分に同期して動作を行うことで，「身体感／身体所有感」が向上し，投射・異投射といえる関係が生じる可能性がある．

なお，追体験者の手の CG 画像を表示する機能を利用すると，実体験者の動作により正確に同期して動くことが可能となり，実体験者の手に対する追体験者の「身体所有感」の向上が期待される一方で，自分の意志に従って動作する CG の手があることで，自分の意志通りには動かない実体験者の手に対する「身体感／身体所有感」が低下し，結果として，追体験の臨場感を低下させることも予想される．これについては，5章の評価実験で検討を進める．

現時点で，体験共有においては，追体験者への触覚フィードバックは開発途上であるが，追体験者への触覚刺激のタイミングを変化させることで，「身体感／身体所有感」を変化させることが可能となる可能性がある．

4. 準備的な評価実験

近年普及した VR デバイスを用いて，体験共有システムを試作した．これを用いて，体験共有における臨場感について，準備的評価実験を行った．

4.1 体験共有システム試作機

図 3 に，近年普及した VR デバイスを用いて試作した体験共有試作システムの構成の一例を示す．

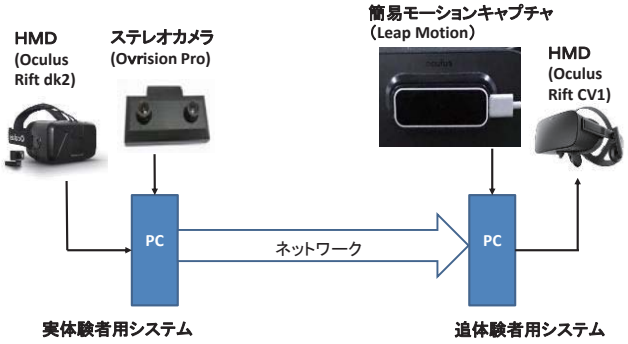


図 3 体験共有システム試作機のハードウェア構成

実体験者用 HMD は Oculus Rift dk2 で有り，追体験者用 HMD は Oculus Rift CV1 である．実体験者用 HMD はステレオカメラ Ovrvision Pro を搭載し，ステレオカメラ画像を取得して，ネットワークを通じて，追体験者用 PC に送信し，追体験者の HMD に表示することが可能である．同時に，HMD の姿勢を Oculus Rift dk2 の SDK を利用して取得し，追体験者用 PC に送る．実体験者の視線方向は，HMD の姿勢より近似的に計算する．追体験者の視線方向も，Oculus Rift CV1 の SDK を利用して取得した，追体験者の HMD の姿勢から近似的に計算する．追体験者用 HMD には，実体験者と追体験者の視線方向を示す円錐台状の視線マーカーをカメラ画像に表示可能であり，実体験者と追体験者で見る方向を同期させることが可能である．

図 2 にあるように，本来の体験共有システムでは，追体験者側の HMD に，追体験者の運動を計測するモーションキャプチャの搭載は必須ではないが，2.2 で述べたように，本試作システムでは，追体験者の HMD に，簡易な手のモーションキャプチ

ヤ Leap Motion を搭載し，それにより取得した追体験者の手の CG 画像を追体験者の HMD に AR 表示可能である．

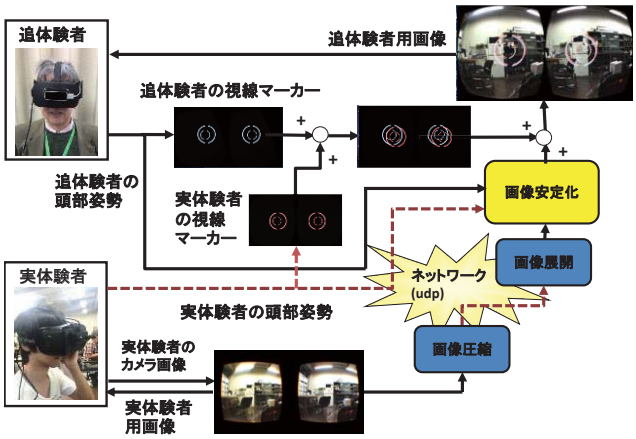


図 4　体験共有システム試作機の情報処理

本試作システムのソフトウェアは，床井が中心となって開発している，テレイグジスタンス型ロボット操縦/遠隔行動誘導/体験共有のための AR 表示のためのオープンソースソフトウェア「TED」[大山 2017][床井 2017]を用いて実現している．図 4 に体験共有システムの情報処理の概要を示す．

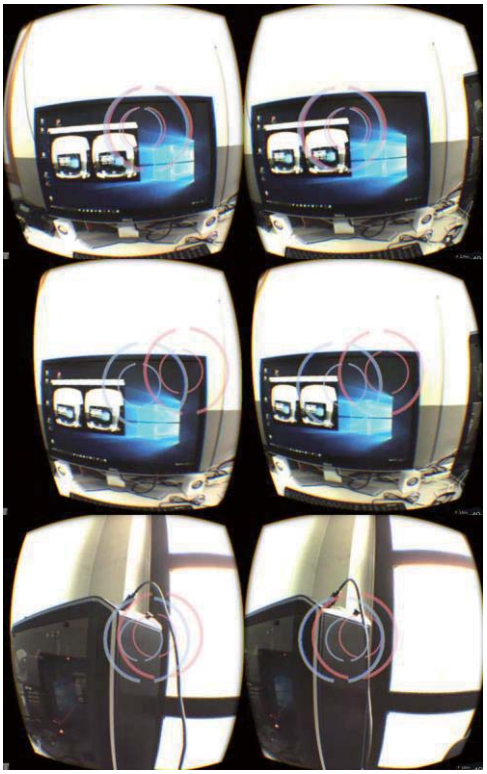


図 5　体験共有における視線誘導の一例

図 5 に体験共有において，実体験者の視線を示す赤いマーカーに，追体験者の視線を示す青白いマーカーが追従している様子を示す．

図 6 に，体験共有システムによる体験共有の様子を示す．中央にあるパーティッションを隔てて，右が実体験者で左が追体験者である．図 3 のシステムに加えて，実体験者は，ディスプレイとして片眼 HMD である VUFINE 社の VUFINE+を装着しており，ヘルメット後方に装着した，外装を一部取り外した Oculus Rift dk2 は頭部姿勢センサとして利用している．

図 7 に Leap Motion を利用して生成した追体験者の手の CG 画像を実体験者のカメラ画像に重畳した AR 表示の一例を示す．

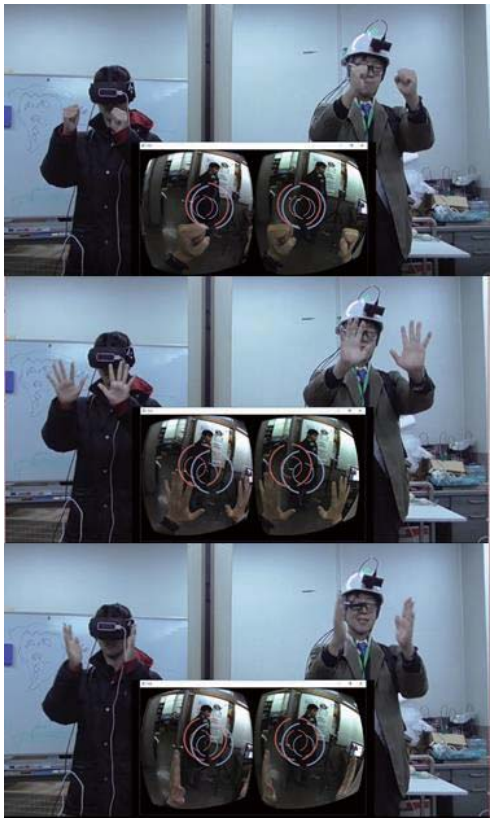


図 6　体験共有の様子

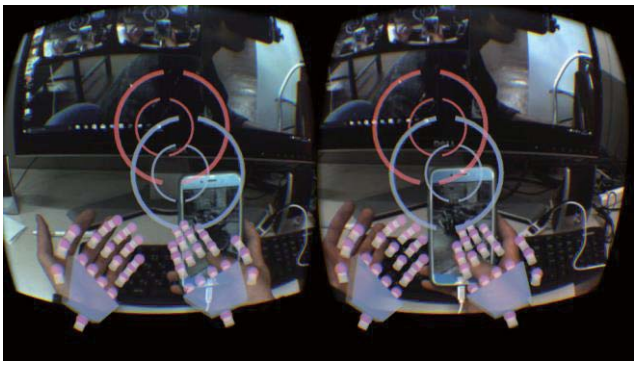


図 7　追体験者の手の CG 画像の重畳の様子

5.　準備的評価実験

体験共有システムは現時点でも開発中で有り，現状のシステムの提供する臨場感を評価するため，体験共有システム試作機の準備的な評価実験を行った．

体験として，二人組で行う少林寺拳法の約束練習を取り上げた．防御側が実体験者用システムを装着し，攻撃側の攻撃を受けて反撃する練習を繰り返し，防御側の体験を被験者が追体験した．防御側，攻撃側ともに，少林寺拳法の訓練を 3 年積み，3 段の資格を取得している．

6 人の被験者に以下の 3 つの条件で，少林寺拳法の約束練習を追体験してもらった．

【条件 1】ヘッドマウンテンドカメラで撮影した画像を固定ディスプレイで表示する.

【条件 2】(一般的な体験共有の条件) ヘッドマウンテッドカメラで撮影した画像を HMD で再生する.

【条件 3】ヘッドマウンテッドカメラで撮影した画像を HMD で再生するが, その時, 追体験者の手の CG を重ねて表示する.

体験時間を一つの条件に付き 1 分とし, 約束練習の攻撃側と防御側には, 前半 30 秒は簡単な単発の攻撃とそれに対する, 単発の反撃を行ってもらい, 後半 30 秒は連続した, 複雑な攻撃とそれに対するより複雑な反撃をしてもらった. 図 8 に体験共有システムを装着して, 追体験している様子を示す.



図 8 実験の様子

各条件を体験する順番は, 偏りが無いように, 被験者毎に順繰りに変えている. 各条件を体験する毎に, 主観的臨場感と購買欲について, アンケートに回答してもらった. 図 9 に, 質問「臨場感」について, 0(臨場感を感じない)から 100(現場にいるかのような臨場感を感じる)の間の数値で回答してもらった平均値(棒グラフ)と標準偏差(棒グラフ上端からの直線)を示す.

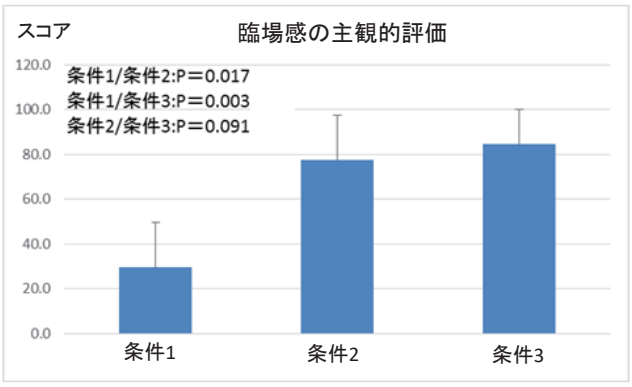


図 9 臨場感に関するアンケート結果

各条件の組に対して, 等分散を仮定した両側 t 検定を行った. 条件 1 と条件 2, 条件 1 と条件 3, 条件 2 と条件 3 について, それぞれの p 値は, 0.017, 0.004, 0.091 であった. 固定ディスプレイに対して, HMD を用いた体験共有システムの方が, 有意に臨場感が高く($p=0.017, 0.004 < 0.05$), その優位性が確認できた. 統計的有意差は確認できないが($p=0.091 > 0.05$), 追体験者の手の CG の AR 表示が, 臨場感に貢献する可能性が示唆されている. その可能性の検証のため, アンケート項目をより詳細に設計し, 被験者を増やし, より精度の高い評価実験を行う必要がある.

アンケートでは, 視野の狭さや実体験者の動作が速く, 追従が困難であったことが報告された. 現在, より広視野のステレオカメラの利用を検討中である.

6. おわりに

本稿では, 体験共有システムについて紹介し, 体験共有時における投射・異投射について述べ, 体験共有システムの準備的な評価実験について報告した. 今回試作した体験共有システムは開発中で有り, より実用性を高めたシステムの開発を進めるとともに, プロジェクション科学の知見を基づいて, 体験共有の評価を行う実験を進める予定である.

謝辞

実験に協力いただいた, 東大少林寺拳法部, 加藤 慎 正拳士と遠坂 優 正拳士に深謝いたします.

参考文献

[ASICS 2016] ASICS Japan, 平成 28 年 2 月 24 日プレスリリース, ウェアラブルデバイスを用いた 新たなスポーツ体験のシステムを公開, https://corp.asics.com/jp/press/article/2016-02-24, 2016.

[Kasahara 2014] Shunichi Kasahara, et al., LiveSphere: Immersive Experience Sharing with 360 Degrees Head-mounted Cameras, Proc. of UIST2014, 2014.

[Kondo 2011] Daisuke Kondo, et al., View Sharing System for Motion Transmission, in the 2nd Augmented Human International Conference (AH'11), 2011.

[Maeda 2011] Taro Maeda, et al., Immersive Tele-collaboration with Parasitic Humanoid: How to Assist Behavior Directly in Mutual Telepresence, ICAT 2011, Osaka, Nov. 30, 2011.

[Oyama 2016] Eimei Oyama, et al., Behavior Navigation System for Harsh Environments, Advanced Robotics, Vol. 30, Issue 3, pp. 151-164, 2016.

[大山 2017a] 大山英明, 他, プロジェクション工学からプロジェクション科学へ, JSAI2017, 2017.

[大山 2017b] 大山英明, 他, TelExistance Display System (TED):テレイグジスタンス／遠隔行動誘導／体験共有のための AR 表示オープンソースソフトウェア, SI2017, 2017.

[Shiroma 2010] Naoji Shiroma and Eimei Oyama, Asynchronous Visual Information Sharing System with Image Stabilization, Proc. of IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS) 2010, pp. 2501-2506, 2010.

[鈴木 2016] 鈴木宏昭, プロジェクション科学の展望, 016 年度日本認知科学会第 33 回大会論文集, 2016.

[Suzuki 2017] Yuuya Suzuki, et al., Omnidirectional Traveling Instruction for Behavior Navigation, Proc. of ICSR 2017, 2017.

[Tachi 2015] Susumu Tachi, Telexistence, 2nd edition, World Scientific, 2015.

[舘 2015] 舘 暲, テレイグジスタンス, 日本ロボット学会誌, Vol. 33, No. 4, pp. 215-221, 2015.

[床井 2017]Kohei Tokoi, https://github.com/tokoik/ted/, 2017.

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

文学読解は社会的能力を高めるか？
Does literary reading enhance social abilities?

米田英嗣*[1]　市村 賢士郎 [1]　西山慧 [1]　西口美穂 [1]　渡邊智也 [1]

Hidetsugu Komeda　Kenshiro Ichimura　Satoru Nishiyama　Miho Nishiguchi　Tomoya Watanabe

[1] 京都大学
Kyoto University

Story is a fundamental communication style in human being. Story comprehension is an immersed experience in the story world, and works as a simulation (or virtual experiences) in the real world. Thus, readers can learn how to understand story characters' mental states. If it is true, literary reading should be a training of social abilities in the real world. We used "strange story task" as a near transfer measurement (verbal task), and "animation task" as a far transfer measurement (nonverbal task). The results suggest that literary reading enhances social abilities in the strange story task. For future, the story comprehension in the virtual reality or augmented reality would be promising to develop the pervasive training program for stoical abilities.

1. はじめに

物語というコミュニケーションの形態は、古くから人間が求め、文字のない時代から口伝えに受け継がれてきた、人間や社会のあり方と深く結びついたものである。物語を読むことは、物語に記述された世界、登場人物が経験する出来事を疑似的に体験することであり、読者の脳の中で行われる現実世界のシミュレーションとも言える(米田, 2010; Mar & Oatley, 2008)。文学作品を読書することが、物語世界に没入し、社会的能力を高めるという報告もなされている(Kidd & Castano, 2013)。こうしたことから、今後、紙媒体の物語形式がなくなったとしても、物語形式の伝承スタイルは不滅であると考える。今後、バーチャルリアリティやオーグメンテッドリアリティなどを用いた新たな読解や物語体験が増えてくると予測されるが、テキスト形式の物語の効果を明らかにしておくことは重要であると考えられる。

本研究では、小説を読むことによって社会的能力の向上がみられるかどうかを、教育介入前のプレテスト、介入直後のポストテスト、介入一ヵ月後のフォローアップテストを用いて検討する。社会的能力を測定する際に、言語課題、非言語課題を設定し、小説読解における社会性向上の効果が言語課題に限られるのか(近転移)、あるいは非言語課題にも転移するのか(遠転移)を明らかにする。

2. 方法

2.1 実験参加者

実験群である小説読解トレーニングに 25 名(女性 10 名、男性 15 名)が参加し、能動的統制群である評論読解トレーニングに 26 名(女性 14 名、男性 12 名)が参加した。実験参加者は、大学の学部学生であった。

2.2 手続き

プレテスト(1 日目の午前)

言語を用いた心の理論課題であるストレンジストーリー課題(White et al., 2009)と、図形を用いた心の理論課題であるアニメーション課題(Zwickel, et al., 2010)を用いた。

トレーニングセッション 1(1 日目の午後)

実験群(*n*=25)は、小説を用いたトレーニングを行い、能動的統制群(*n*=26)は、論説文を用いたトレーニングを行った。トレーニング方法は、小説(能動的統制群の場合は、論説文)の問題に解答し、その後、解法を解説した。

トレーニングセッション 2(2 日目の午前)

実験群(*n*=25)は、小説を用いたトレーニングを行い、能動的統制群(*n*=26)は、論説文を用いたトレーニングを行った。トレーニング方法は、小説(能動的統制群の場合は、論説文)の問題に解答し、その後、解法を解説した。トレーニングセッション 1 とは異なった問題を用いた。

ポストテスト(2 日目の午後)

言語を用いた心の理論課題であるストレンジストーリー課題と、図形を用いた心の理論課題であるアニメーション課題を用いた。プレテストとは同じ種類であるが、異なった問題を用いた。

フォローアップテスト(1ヶ月後のテスト)

言語を用いた心の理論課題であるストレンジストーリー課題と、図形を用いた心の理論課題であるアニメーション課題を用いた。

3. 結果

ストレンジストーリー課題と、アニメーション課題の結果を分析し、小説読解トレーニングと評論読解トレーニングとの相違を検討した。

3.1 ストレンジストーリー課題

ストレンジストーリー課題は、言語を媒体とした課題であるため、言語的な課題への近転移を測るものである。文章を読んで、提示される設問に答える形式である。文章は1文ずつ提示される。4 種類の文章があり、1)心的状態に関するストーリー8 個、2)動物に関するストーリー8 個、3)関連のない文 8 個であった。ストレンジストーリー課題の得点を従属変数とし、トレーニング形式(小説・評論)を参加者間要因、テストの時期(プレ、ポスト、1 ヶ月後のフォローアップ)を参加者内要因とした分散分析を行った。

連絡先：米田英嗣
京都大学白眉センター
komeda.hidetsugu.5w@kyoto-u.ac.jp

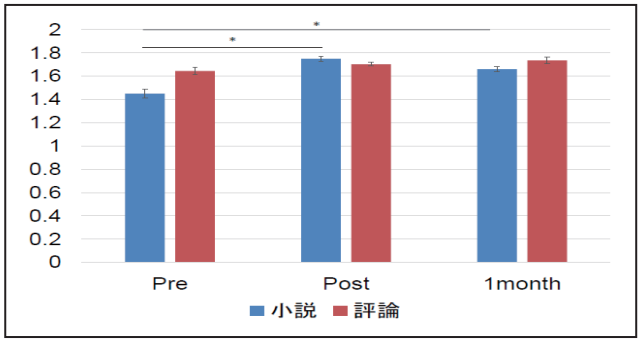


図 1 心的状態に関するストーリーの結果
2 が満点
エラーバーは標準誤差

心的状態に関するストーリーにおいて、トレーニングとテスト段階の交互作用が有意で(F (2, 98) = 3.11, p < .05)、小説トレーニングにおいて、プレテストからポストテストにおいて成績の向上が見られた。また、プレテストからフォローアップテストにおいて成績の向上が見られ、ポストテストとフォローアップテストにおいては有意な差が見られなかった(図 1)。

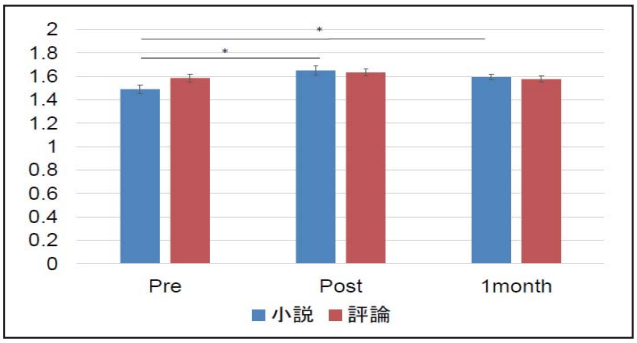


図 2 動物に関するストーリーの結果
2 が満点
エラーバーは標準誤差

動物に関するストーリーにおいて、トレーニングとテスト段階の交互作用が有意で(F (2, 98) = 3.12, p < .05)、小説トレーニングにおいて、プレテストからポストテストにおいて成績の向上が見られた。また、プレテストからフォローアップテストにおいて成績の向上が見られ、ポストテストとフォローアップテストにおいては有意な差が見られなかった(図 2)。

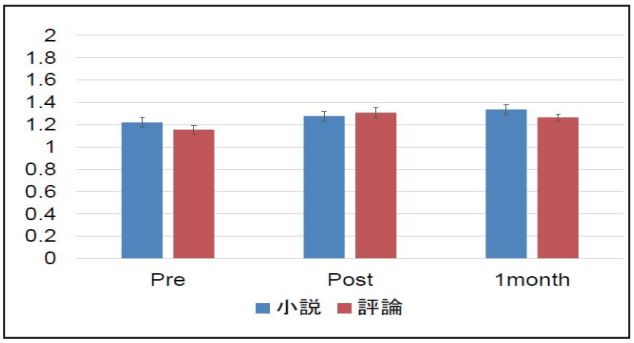


図 3 関連のない文
2 が満点
エラーバーは標準誤差

関連のない文については、すべての主効果、交互作用において有意な差が見られなかった(図 3)。

3.2 アニメーション課題

アニメーション課題は、映像を媒体とした課題であるため、非言語的な課題への遠転移を測るものである。2 つの図形が動く映像を見て、その内容を記述する形式である。0-5 点で採点され、心的状態を言及しているほど高得点である。非言語領域への遠転移を測る課題である。アニメーション課題の得点を従属変数とし、トレーニング形式(小説・評論)を参加者間要因、テストの時期(プレ、ポスト、1 ヶ月後のフォローアップ)を参加者内要因とした分散分析を行った。

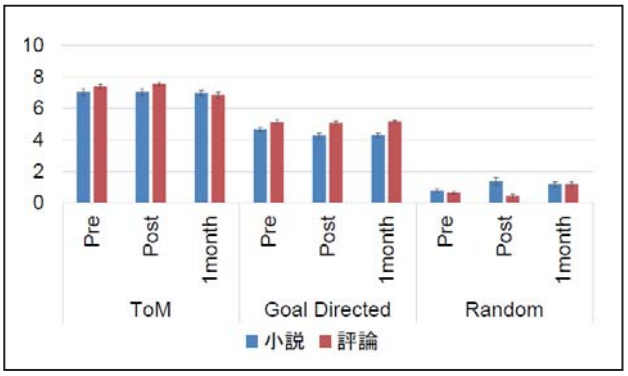


図 4 アニメーション課題の得点結果
10 が満点
エラーバーは標準誤差

アニメーションの種類の主効果のみが有意で、心的状態を示す図形の動き(ToM)、目的志向(Goal directed)、ランダム(Random)の順に心的状態への言及が大きかった (図 4)。

4. 考察

4.1 結果のまとめ

小説読解トレーニングにおいて、ストレンジストーリー課題で心情理解の成績が向上した。アニメーション課題では、介入の効果が出なかったことから、近転移のみが見られることが明らかになった。

4.2 小説読解の長期的効果

社会的能力は、小説読解によるトレーニングをしたときのみ向上することがわかった。先行研究(Kidd & Castano, 2013)でも、文学的フィクションを読んだときにのみ感情推測に基づく心的状態理解テストの成績が向上していたが、本研究では、プレ・ポストデザインを用いた小説読解トレーニングによる社会的能力向上の長期的効果を明らかにした。

4.3 生物性の知覚

小説読解トレーニングでは、心情理解の物語に加えて、動物に関する物語も成績向上した。小説を読解することによって、人間から人間以外の動物の理解にも転移した可能性が考えられる。生物性を検出する能力は、社会的能力の基盤となる(Zwickel, White, Coniston, Senju, & Frith, 2010)。

しかしながら、図形を用いたアニメーション課題では、介入の効果が出なかった。社会的能力のコンポーネントである生物性認知に、言語ドメインと非言語ドメインがあり、生物性認知にお

ける言語ドメインにのみ、小説読解による介入の効果が出た可能性がある。

4.4 今後の展開

本研究で見られなかった遠転移を起こさせるために、非言語的な社会的能力を高めるトレーニング方法の開発する必要がある。そのためには、第一に、バーチャルリアリティやオーグメンテッドリアリティを用いた介入が有用である可能性がある。特に、映像を媒体とした課題であるアニメーション課題の成績向上に、バーチャルリアリティやオーグメンテッドリアリティによる物語体験が有効であると考えられる。第二に、より長期的なトレーニングを行う介入研究の実施することを考えている。今回の介入実験では 2 日間という短期間の介入によって、少なくとも近転移の効果が得られた。長期間の介入を行うことによって、遠転移の効果が得られる可能性がある。

本研究では、一定の教育的介入を終えた大学生において結果が認められた。今後は、発達障害をもつ子どもや高齢者を対象として検討を行うことを考えている。

参考文献

[Kidd, D. C., & Castano, E. (2013, October). Reading literary fiction improves theory of mind. *Science*]

[米田英嗣 (2010). 物語理解と社会認知神経科学 楠見 孝 (編) 現代の認知心理学 第 3 巻「思考と言語」北大路書房, pp.270-290.]

[Mar, R. A., & Oatley, K. (2008). The function of fiction is the abstraction and simulation of social experience. Perspectives on Psychological Science, 3, 173-192.]

[White, S., Hill, E., Happé, F., & Frith, U. (2009). Revisiting the strange stories: revealing mentalizing impairments in autism. Child Development, 80, 1097-1117]

[Zwickel, J., White, S., Coniston, D., Senju, A., & Frith, U. (2010). Exploring the building blocks of social cognition: Spontaneous agency perception and visual perspective taking in autism. *Social Cognitive and Affective Neuroscience*, 6, 564–571.]

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

プロジェクション現象を記述する生成モデルの提案

A generative model describing the process of projection

横山裕樹 *1　岡田浩之 *2
Hiroki Yokoyama　Hiroyuki Okada

*1*2玉川大学脳科学研究所
Tamagawa University Brain Science Institute

To understand the process and mechanism of projection, it is important construct its mathematical model. In this paper, we propose a generative model that covers a wide range of phenomena involved in projection.

1. はじめに

我々を取り巻く環境や身体内部で起こった事象は脳神経系における様々な情報処理を受け，なんらかの表象としてまとめ上げられる．しかし一方で，作り上げられた表象は，我々の意識において，世界のどこかに定位されるように感じられる [鈴木 16]．例えば，棒状の物を持ってその先端で地面などに触れたとき，実際には掌の感覚器がその振動を検知しているにも関わらず，我々は棒の先端に何かがあることを，リアリティを伴って瞬時に感じ取ることができる．このように，表象を外の世界に定位させることを「投射（プロジェクション）」と呼び，そのプロセスとメカニズムを探求する新たな研究分野がプロジェクション科学である．

[鈴木 16] は投射を投射，異投射，虚投射の三つに分類しており，それぞれについて様々な例を示している．実験や理論的な考察を通して投射という現象を理解するためには，これらを統一的に記述できる数理モデルの構築が必要である．本稿では，脳の計算機構を記述するために広く用いられている生成モデルを用いて，異投射，虚投射を含む，様々なプロジェクション現象を記述するモデルを提案する．

2. 提案モデル

我々の脳は，特にこれが正しいという教師信号を与えられなくとも，感覚系から得られる情報を基に外界の状態をうまく表現する計算機構を自己組織的に獲得することができる．このようなメカニズムを生成モデルによって記述することが古くから試みられてきた．[Rao 99] は大脳皮質初期視覚野にみられる求心性，遠心性の双方向結合の役割を示すために，視覚入力として画像 $\boldsymbol{z}$ が得られたとき，ニューロン応答により表現される外界の推定状態 $\hat{\boldsymbol{s}}$ とシナプス結合により表現される基底画像 $W = (\boldsymbol{w}_1, \boldsymbol{w}_2, \cdots)$ から予測画像 $\hat{\boldsymbol{z}} = f(W\hat{\boldsymbol{s}})$（$f$ は tanh などの非線形関数）を生成しているというモデルを構築した．このモデルは，様々な自然画像について予測誤差を最小化するように $\hat{\boldsymbol{s}}$ と W を学習することで，第一次視覚野にみられる受容野形状に類似する特徴表現を自己組織的に獲得した．さらに，入力次元（画像ならば画素数）よりも多くの基底を用意しておき，各入力の表現にはそのうちの少数を用いるという，スパースな表現が視覚野で行われていることが，同様の枠組みによる自然画像の学習によって確認されている [Olshausen 96, Olshausen 97]．

連絡先: hiroki.yokoyama@okadanet.org

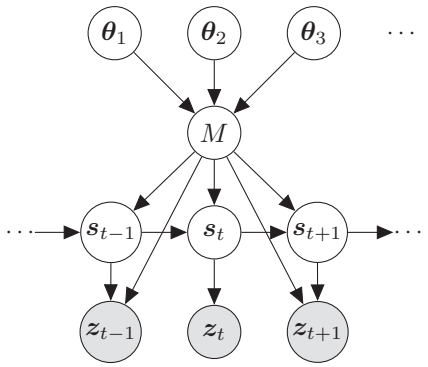


図 1: 提案モデル．

上記は視覚情報の表現の例であるが，より高次の情報表現についても同様に生成モデルで記述することが，その処理過程の理解へ繋がると期待できる．そこで，ここでは，状態遷移を伴う対象（例えば目の前の物体や，自身の身体の一部など）が分節化できたと仮定して，その一つの状態を推定するという問題を定義し，この枠組みでの投射の位置付けを示す．

注意を向けている対象のモデルを M とする．対象は，一般に（物体であれば三次元的な姿勢など）隠れ状態 $\boldsymbol{s}$ を持っており，M にはそれを推定するための状態遷移則 $P(\boldsymbol{s}_{t+1}|\boldsymbol{s}_t)$ と観測モデル $P(\boldsymbol{z}_t|\boldsymbol{s}_t)$ が含まれる．後者が実際に得られる感覚入力 $\boldsymbol{z}$ と隠れ状態 $\boldsymbol{s}$ との対応関係を表現する．

通常の隠れマルコフモデルでは，推定する対象は固定されているので，M を定数とみなし，最尤推定によって推定する．一方，一定の対象に注意を向けている間は M は一定であるが，何に注意を向けているかは文脈に応じて異なる．そこで，提案モデルではこれを確率変数ととらえ，多数のサブモデル $\boldsymbol{\theta}_1, \boldsymbol{\theta}_2, \cdots$ から少数が選択され，組み合わされて M が生成されると考える．

外界からは $\boldsymbol{z}$ のみが直接得られるので，$\boldsymbol{s}$ から生成された $\boldsymbol{z}$ の予測を実際の $\boldsymbol{z}$ に近づけることが目的となる．もし $\boldsymbol{\theta}_1, \boldsymbol{\theta}_2, \cdots$ として既知の物体等のモデルが適切に表現されていれば，短期的にはこれらを用いて M を構成し，$\boldsymbol{s}$ および $\boldsymbol{z}$ を推定することができる．また，長期的には予測誤差がより小さくなるようにサブモデルを更新することになる．予め学習によって獲得された $_i$ から $\boldsymbol{s}_t$，そして $\boldsymbol{z}_t$ を推定する過程が投射にあたると考えられる．

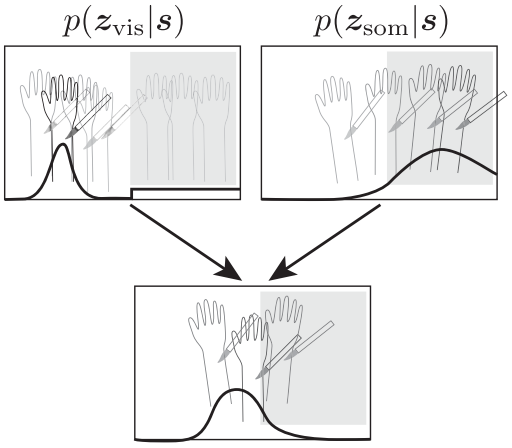


図 2: ラバーハンドイリュージョンにおける腕の状態 $\boldsymbol{s}$ に関するベイズ統合．左側の中央にラバーハンドが置かれており，右側の中央に実際の腕がある．右半分は遮蔽されている．

3. ラバーハンドイリュージョン

本節では提案モデルの適用例としてラバーハンドイリュージョン（RHI）を取り上げる．RHI では自身の腕に注意を向けているので，被験者は自身の腕の状態を推定していると考えられる．自身の腕についてはすでにモデル化されていると仮定する．すなわち腕，もしくはそのサブモデルが $\boldsymbol{\theta}_1, \cdots$ に表現されており，それらを組み合わせて M が適切に構成されているとする．腕は自身の制御や環境とのインタラクションに応じて位置を変えたりするため，その状態 $\boldsymbol{s}$ を常に推定しなければならない．これは観測モデル $P(\boldsymbol{s}|\boldsymbol{z})$ に基づいて行われる．RHI の場合，腕の位置を推定するために重要な情報は視覚情報 $\boldsymbol{z}_{\mathrm{vis}}$ と体性感覚（皮膚と筋骨格系の感覚）$\boldsymbol{z}_{\mathrm{som}}$ である．これらの処理過程で重畳されるノイズが独立であるとすると，$P(\boldsymbol{z}|\boldsymbol{s}) = P(\boldsymbol{z}_{\mathrm{vis}}|\boldsymbol{s})P(\boldsymbol{z}_{\mathrm{som}}|\boldsymbol{s})$ と書ける．視覚情報からは腕の位置に関して正確な情報が得られると考えられるが，ラバーハンドという視覚的に類似するものが存在するため，情報が不正確となっている．一方，体性感覚から得られる情報にはバイアスがかかっていないが，体性感覚の情報だけでは正確な位置がわからない（図 2）．これらを統合すると，分散の小さい視覚情報が優先されて，腕の推定位置が左にシフトすることになる．これはベイズ統合と呼ばれている [Wolpert 07, Körding 04]．

4. おわりに

本稿では，プロジェクション現象を記述する生成モデルを提案した．今後，各サブモデルにおける状態の表現や，階層モデルの上位層となる，サブモデルの統合の方法について，より具体的に検討して行く予定である．

参考文献

[Körding 04] Körding, K. P., Ku, S. P., and Wolpert, D. M.: Bayesian integration in force estimation, *Journal of Neurophisiology*, Vol. 92, No. 5, pp. 3161–3165 (2004)

[Olshausen 96] Olshausen, B. A. and Field, D. J.: Emergence of simple-cell receptive field properties by learning a sparse code for natural images, *Nature*, Vol. 381, No. 6583, pp. 607–609 (1996)

[Olshausen 97] Olshausen, B. A. and Field, D. J.: Sparse coding with an overcomplete basis set: A strategy employed by V1?, *Vision Research*, Vol. 37, No. 23, pp. 3311–3325 (1997)

[Rao 99] Rao, R. P. N. and Ballard, D. H.: Predictive coding in the visual cortex: A functional interpretation of some extra-classical receptive-field effects, *Nature Neuroscience*, Vol. 2, No. 1, pp. 79–87 (1999)

[Wolpert 07] Wolpert, D. M.: Probabilistic models in human sensorimotor control, *Human Movement Science*, Vol. 26, No. 4, pp. 511–524 (2007)

[鈴木 16] 鈴木宏昭：プロジェクション科学の展望, 2016 年度日本認知科学会第 33 回大会, No. OS03-1 (2016)

[3E2] [General Session] 8. Soft Computing

座長:松井 藤五郎（中部大学）

Thu. Jun 7, 2018 3:50 PM - 5:50 PM Room E (4F Queen)

[3E2-01] A study on application of satisfaction method of constraints based on their difficulties in many constrained optimization problems

○Kento Niwa[1], Tomohiro Yoshikawa[1] （1. Nagoya University）

3:50 PM - 4:10 PM

[3E2-02] Evolutionary Acquisition of Multiple Block Preserving Outerplanar Graph Patterns by Clustering Outerplanar Graphs

Fumiya Tokuhara[1], ○Tetsuhiro Miyahara[1], Tetsuji Kuboyama[2], Yusuke Suzuki[1], Tomoyuki Uchida[1] （1. Graduate School of Information Sciences, Hiroshima City University, 2. Computer Centre, Gakushuin University）

4:10 PM - 4:30 PM

[3E2-03] Medical image diagnosis of liver cancer using deep RBF GMDH-type neural network

○Tadashi Kondo[1], Shoichiro Takao[1], Sayaka Kondo, Junji Ueno[1] （1. Tokushima University）

4:30 PM - 4:50 PM

[3E2-04] Proposal a new feature evaluation measure for filter type feature subset selection with Evolutionary Algorithm

○Atsushi Kawamura[1], Basabi Chakuraborty[2] （1. Iwate Prefecture University Graduate School, 2. Iwate Prefecture University）

4:50 PM - 5:10 PM

[3E2-05] Three Dimensional Image Registration Using Silhouette-based Objective function and CMA-ES Including Partial Restart with Variable Fixing

○Takuto Shigenobu[1], Takuya Ushinohama[1], Hiroshi Kawasaki[2], Satoshi Ono[1] （1. Kagoshima University, 2. Kyushu University）

5:10 PM - 5:30 PM

[3E2-06] A study on Neural Network with Cell Differentiation Algorithm

○Masayuki Yoshinobu

5:30 PM - 5:50 PM

©The Japanese Society for Artificial Intelligence

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

多数制約付き最適化問題における難易度に基づく制約の充足方法に関する検討

A study on application of satisfaction method of constraints based on their difficulties in many constrained optimization problems

丹羽健斗 *1　　吉川大弘 *1
Kento Niwa　　Tomohiro Yoshikawa

*1名古屋大学工学研究科
Graduate School of Engineering Nagoya University

Due to the improvement of the performance of computers, GA is actively applied to actual engineering problems. Most of engineering problems are constrained optimization problems. Penalty method is well-known as the solution to such constrained optimization problems. The benchmarks of constrained optimization problems have only small number of constraints. Thus, the effectiveness of penalty method has not been investigated in many constrained problems. In many constrained optimization problems, penalty method has a risk that all constraints cannot be satisfied. This paper proposes the stepwise satisfaction method of constraints to satisfy many constraints. In the proposed method, the priority of constraints to be satisfied is defined based on the initial population. Furthermore, this paper studies on dividing constraints into difficult ones and easy ones and combining the proposed method with the penalty method. In the experiment, the performance of the proposed method and the penalty method was compared in two problems.

1. はじめに

近年，計算機の性能向上に伴い，遺伝的アルゴリズム (Genetic Algorithm : GA) の工学的応用が盛んになっている [Dasgupta 13]．GA を工学的応用に用いる際には，解に制約が設けられている制約付き最適化問題であることが多い．制約付き最適化問題の代表的な解法として，ペナルティ法 [Mezura-Montes 08] が知られている．しかし，多数の制約を持つ最適化問題に対してペナルティ法を適用すると，すべての制約を充足した実行可能解が獲得できないまま探索が終わってしまう危険性がある．これは，GA の性質上，全ての制約を同時に扱うと，充足が簡単な制約が先に充足され，結果的に難しい制約を充足することが困難となってしまうためである．したがって，難しい制約を充足するためには，制約に優先順位を設ける必要があると考えられる．

そこで本稿では，制約を充足する優先順位の基準として，制約の難易度に着目する．交叉における親個体選択の際に，より難易度の高い制約を充足している個体を優先して選択することで，難易度の高い制約から順に充足する，段階的制約充足法を提案する．また，提案手法ではすべての制約を充足した後に初めて評価値の最適化が行われるため，制約の充足が難しくないのであれば，従来手法よりも探索性能は悪化すると考えられる．そこで本稿ではさらに，制約の難易度により制約を分割し，段階的制約充足法とペナルティ法を融合した手法を提案する (以下，融合手法)．融合手法では，すべての制約の充足と探索性能の向上の両立を目的としている．本稿では，多数の制約を持つ最適化問題に提案手法を適用し，従来手法との比較を行うことにより，段階的制約充足法と融合手法の探索性能について検証する．

連絡先: 丹羽健斗，名古屋大学大学院工学研究科，名古屋市千種区不老町，052-789-2793，niwa@cmplx.cse.nagoya-u.ac.jp

2. 提案手法

本稿で提案する段階的制約充足法では，制約を違反している初期個体の割合に基づいて制約の難易度を決定する．そして，交叉における親個体選択において，難易度の高い制約を充足している個体を優先して選択することで，難易度の高い制約から順に充足する．すべての制約を充足した後，目的関数の最適化を行う．また，次世代個体群の選択においては，制約違反数の小さい個体を優先して次世代に選択することで，全ての制約を充足する方向に選択圧を加える．

2.1 制約の難易度の定義

ランダムに生成した初期個体において，各制約を違反している個体の割合を求める．そして，違反している個体の割合が高い順に，難易度の高い制約と定義する．この制約の難易度は，2.2 節の交叉親個体の選択や 2.3 節の制約の分割に用いる．

2.2 交叉親個体の選択

交叉のための親個体の選択では，前節で定義した制約の難易度を用いたトーナメント選択を行う．まず初めに，個体群からランダムに N_t 個 (トーナメントサイズ) の個体を選択する．次に，最も難しい制約 (対象制約) に注目し，以下のルールに従って親個体の選択を行う．

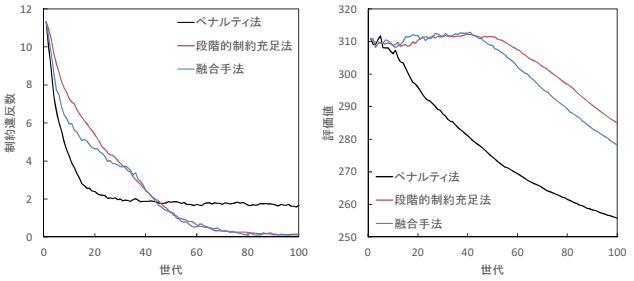
(a) 充足している個体がない場合
対象制約に対する制約違反量が最も小さい個体を親個体として選択する．

(b) 対象制約を充足している個体がある場合
一個体のみの場合は，その個体を親個体とし，複数ある場合は，それらの個体のみに対して，次に難易度が高い制約を対象制約として (a) に戻る．

(c) すべての制約を充足している個体が複数ある場合
最も評価値が優れた個体を親個体として選択する．

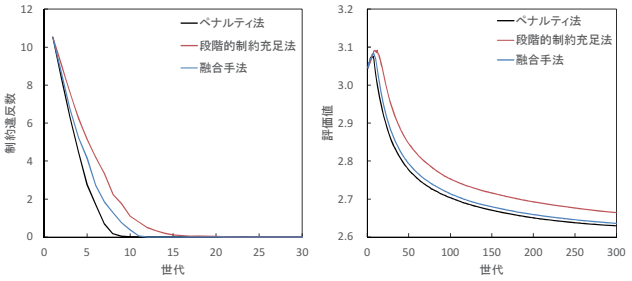
2.3 難易度に基づく制約分割

段階的制約充足法では，すべての制約を充足した後に初めて評価値の最適化が行われる．そのため，制約の充足が難しく



(a) 制約違反数の推移　(b) 評価値の推移

図 1: MOPTA08 に対する各手法の結果



(a) 制約違反数の推移　(b) 評価値の推移

図 2: 複数車種の同時最適化問題に対する各手法の結果

ないのであれば，従来手法よりも探索性能は悪化すると思われる．そこで本稿では，2.1 節で算出した違反個体割合に基づき，制約を二つのグループに分割する．その上で，充足が難しい制約には，段階的制約充足法を適用する．また，それ以外の充足が容易な制約には，ペナルティ法を適用することで，評価値の最適化と同時に充足を行う．本手法を以下では融合手法と呼ぶ．

3. 実験

本章では，提案手法として，2 章で示した段階的制約充足法および融合手法，そして従来手法としてペナルティ法を用いて実験を行った．

3.1 実験設定

適用する問題には，68 個の制約を持つ MOPTA08[*1] と，54 個の制約を持つ応答曲面法を用いた複数車種の同時最適化ベンチマーク問題 [小平 17] を用いた．二つの問題において，集団サイズは 100 とし，制約分割に用いる違反個体割合の閾値は 0.9 とした．交叉操作には SBX(分布度 $\eta_c = 10$，交叉率 $P_c = 1.0$)，突然変異操作には Polynomial Mutation(分布度 $\eta_c = 10$，交叉率 $P_c = 1.0/n$) を用いた．n は設計変数の数であり，MOPTA08 では 124，複数車種の同時最適化問題では 222 である．また，MOPTA08 においては，世代数 100，ペナルティ係数 $p = 100$ とし，複数車種の同時最適化問題では世代数 300，ペナルティ係数 $p = 1$ とした．

3.2 探索性能の比較

MOPTA08 に対する実験の結果を図 1 に，複数車種の同時最適化ベンチマーク問題に対する実験の結果を図 2 に示す．

図 1(a) から，ペナルティ法では充足できなかった制約が，段階的制約充足法や融合手法では充足可能になっていることがわかる．また，図 1(b) から，融合手法の方が段階的制約充足法よりも探索性能が優れていることがわかる．これらの結果から，難易度に基づく制約分割を行い，段階的制約充足法とペナルティ法との融合を行うことによって，すべての制約の充足が可能となり，探索性能も向上したといえる．

また図 2(a) から，すべての手法で実行可能解が獲得できていることがわかる．つまり本問題は，制約の充足が困難な問題ではないと考えられる．そのため，2.3 節で述べたように，段階的制約充足法の探索性能がペナルティ法よりも悪化していることが図 2(b) からわかる．しかし，融合手法はペナルティ法とほぼ同等の探索性能を示している．

これらの結果から，融合手法により，段階的制約充足法とペナルティ法との融合が行われているが，その探索性能は両者の中間的な位置づけではなく，段階的制約充足法が優位な問題では段階的制約充足法よりも優れた探索性能を，ペナルティ法が優位な問題ではそれとほぼ同等の探索性能を示すことが確認された．

*1 MOPTA08 `http://www.miguelanjos.com/jones-benchmark`.

4. まとめ

本稿では，初期個体により制約の難易度を定義し，より難易度の高い制約から順に段階的に充足する段階的制約充足法を提案した．提案手法では，評価値の最適化はすべての制約を充足した後に初めて行われるため，制約の充足が容易な問題において，従来手法に比べて探索性能の悪化が見られた．そこで本稿では，制約の難易度に基づいて制約を分割し，段階的制約充足法とペナルティ法とを融合する手法について検証した．融合手法では，充足が難しい制約には段階的制約充足法を適用し，充足が容易な制約にはペナルティ法を適用する．本稿では，二つの多数制約付き最適化問題にこれらの手法を適用し，ペナルティ法との比較を行った．実験結果より，段階的制約充足法はすべての制約が充足可能であることが確認できた．また，融合手法はどちらの問題においても，すべての制約を充足しつつ，段階的制約充足法より優れた探索性能を示した．今後は，制約の性質が提案手法の探索性能に与える影響の調査や，多数目的の問題に対する提案手法の適用を行っていく予定である．

参考文献

[Dasgupta 13] Dasgupta, D. and Michalewicz, Z.: *Evolutionary Algorithms in Engineering Applications*, Springer Berlin Heidelberg (2013)

[Mezura-Montes 08] Mezura-Montes, E. and Coello, C.: Constrained optimization via multiobjective evolutionary algorithms, in *Multiobjective Problem Solving from Nature*, pp. 53–75, Springer-Verlag Berlin Heidelberg, first edition (2008)

[小平 17] 小平 剛央, 釼持 寛正, 大山 聖, 立川 智章 : 応答曲面法を用いた複数車種の同時最適化ベンチマーク問題の提案, 進化計算学会論文誌, Vol. 8, No. 1, pp. 11–21 (2017)

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

外平面的グラフのクラスタリングによる 複合的なブロック保存型外平面的グラフパターンの進化的獲得

Evolutionary Acquisition of Multiple Block Preserving Outerplanar Graph Patterns by Clustering Outerplanar Graphs

徳原 史也 *1 Fumiya Tokuhara　宮原 哲浩 *1 Tetsuhiro Miyahara　久保山 哲二 *2 Tetsuji Kuboyama　鈴木 祐介 *1 Yusuke Suzuki　内田 智之 *1 Tomoyuki Uchida

*1広島市立大学情報科学研究科 Graduate School of Information Sciences, Hiroshima City University

*2学習院大学計算機センター Computer Centre, Gakushuin University

Machine learning and data mining from graph structured data are studied intensively. Many chemical compounds can be expressed by outerplanar graphs. We report a two-stage evolutionary learning method for acquiring characteristic multiple block preserving outerplanar graph patterns from positive and negative outerplanar graph data, by clustering outerplanar graphs.

1. はじめに

グラフ構造を持つデータからの機械学習やデータマイニングが注目されており，多くの化合物は外平面的グラフの構造を持つことが知られている [Horvath 10]．外平面的グラフの構造的特徴を表現するために，ブロック保存型外平面的グラフパターン（Block Preserving Outerplanar graph pattern，BPO グラフパターン）が提案され，正事例の外平面的グラフの構造的特徴を表現する BPO グラフパターンを学習する手法が報告されている [Sasaki 08, Yamasaki 09]．

我々は，正負の分類ラベルを持つグラフデータを分類する，グラフ分類問題 [Rehman 12] に取り組んでおり，正事例と負事例の外平面的グラフから，遺伝的プログラミングを用いて特徴的な BPO グラフパターンを獲得する進化的手法を実現している [Ouchiyama 15, Tokuhara 16a, Tokuhara 16b]．遺伝的プログラミング (Genetic Programming, GP)[Koza 92, Banzhaf 98] とは，遺伝的アルゴリズムの遺伝子型を木構造のような構造的表現を扱えるように拡張した進化的手法である．さらに，一つの BPO グラフパターンで特徴をとらえることが難しいような外平面的グラフデータ集合の構造的特徴を表現するため，正事例と負事例の外平面的グラフから，遺伝的プログラミングを拡張した二段階構造の進化的獲得 [Nakai 14, Yamagata 17] による特徴的な複合的 BPO グラフパターンを獲得する手法を提案し，外平面的グラフの正事例集合のクラスタリング情報が与えられた入力データを対象にした実験結果を報告している [徳原 17a, Tokuhara 17]．ここで，複合的 BPO グラフパターンとは，BPO グラフパターン集合のことをいう．

本稿では，二段階構造の進化的獲得手法のために外平面的グラフの正事例集合をクラスタリングする手法を提案する．さらに，提案クラスタリング手法を用いて，正事例と負事例の外平面的グラフから特徴的な複合的 BPO グラフパターンを獲得する進化的手法の実験結果を報告する．

関連研究として，正事例と負事例からなる木構造データまたはグラフ構造データから特徴的な木パターンまたはグラフパターンを獲得する遺伝的プログラミングによる手法 [Nagamine 07, Nagai 12, Nakai 13, Miyahara 14]，及びグラフ構造データに対する進化的手法 [Katagiri 00, Shirakawa 07] がある．

連絡先: 宮原哲浩，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，miyares18@hiroshima-cu.ac.jp

2. 準備

2.1 BPO グラフパターン

BPO グラフパターンとブロック木パターン [Sasaki 08, Yamasaki 09] の説明をする [Tokuhara 16a, Tokuhara 16b, 徳原 17b, 徳原 17a, Tokuhara 17]．

G をグラフ，Λ と Δ をアルファベットとする．ラベル付きグラフとは，頂点集合 $V(G)$ と辺集合 $E(G)$ の各要素が，それぞれ Λ と Δ の要素によってラベル付けされたグラフをいう．ラベル付きグラフのすべての頂点が外平面に接するように平面埋め込みが可能であるとき，そのグラフを外平面的グラフとよぶ．連結グラフにおいて，削除することでグラフを非連結にすることができる頂点をカット点という．外平面的グラフのブロックとは，頂点数 3 以上のカット点をもたない極大な二重連結成分をいう．ブロックに属さない辺をブリッジとよぶ．BPO グラフパターンとは，ブリッジ変数および末端変数とよばれる 2 種類の構造的変数を持つ連結な外平面的グラフである．本稿では，連結な外平面的グラフのみを扱う．以後，連結な外平面的グラフを単に外平面的グラフとよぶ．外平面的グラフ G と BPO グラフパターン p に対し，p の全ての変数を適当な外平面的グラフで置き換えることによって G が得られるとき p と G はマッチするという．外平面的グラフと BPO グラフパターンの例を図 1 に示す．図 1 において，BPO グラフパターン p のブリッジ変数 X，Y と末端変数 Z をそれぞれ外平面的グラフ g_1，g_2，g_3 に置き換えることで外平面的グラフ G を得ることができるので，p と G はマッチする．

BPO グラフパターン p のブロック部分を，ブロックの辺ラベルの情報を保持したブロック頂点へと置き換えることで得られる，根なし無順序木の構造を持つグラフパターンを p のブロック木パターンとよび，$t(p)$ で表す．ブロック木パターンの例を図 1 に示す．

2.2 遺伝的プログラミングによる複合的な BPO グラフパターンの獲得

本研究では，遺伝的プログラミングを拡張した二段階構造の進化的獲得手法により，特徴的な BPO グラフパターン集合（複合的 BPO グラフパターン）を個体として獲得する．特徴的な BPO グラフパターン集合獲得手法では，以下の特徴的な BPO グラフパターン獲得問題を解く，BPO グラフパターンを個体とする遺伝的プログラミングによる手法 [Tokuhara 16a, Tokuhara 16b] を手続きとして使う．

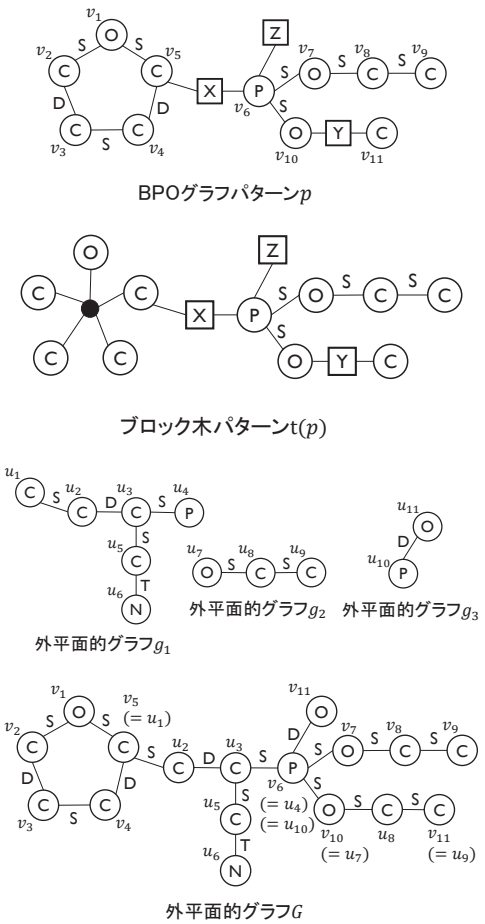


図 1: BPO グラフパターン p. p のブロック部分を変換して得られた p のブロック木パターン $t(p)$. 外平面的グラフ g_1, g_2, g_3, G. 頂点内の文字列は頂点ラベル，辺のそばの文字列は辺ラベル，正方形は変数を表すものとする．p と G はマッチする．

特徴的な BPO グラフパターン獲得問題
入力: 正事例及び負事例からなる外平面的グラフの有限集合 D.
問題: D に関する適合度の高い BPO グラフパターンを獲得する．

ここで，BPO グラフパターン p の D に関する適合度 $fitness_D(p)$ は，$fitness_D(p) = (p$ が D の正事例にマッチする割合 $+ p$ が D の負事例にマッチしない割合 $)/2$ で定義する．遺伝的プログラミングの遺伝操作は BPO グラフパターン p のブロック木パターン $t(p)$ に適用する．

以下の特徴的な BPO グラフパターン集合獲得問題を解く，特徴的な BPO グラフパターン集合を獲得するための進化的手法を提案している [Tokuhara 17, 徳原 17a].

特徴的な BPO グラフパターン集合獲得問題
入力: 正事例集合 P 及び負事例集合 N からなる外平面的グラフの有限集合 D，正整数 $c\,(1 \leq c < |P|)$.
問題: D に関する適合度の高い BPO グラフパターン集合 $\Pi\,(1 \leq |\Pi| \leq c)$ を獲得する．

ここで，集合 A の要素数を $|A|$ と表す．BPO グラフパターン集合 Π に含まれる BPO グラフパターンの少なくとも 1 つと外平面的グラフ G がマッチするとき，Π と G はマッチするという．BPO グラフパターン集合 Π の D に関する適合度 $fitness_D(\Pi)$ は，$fitness_D(\Pi) = (\Pi$ が D の正事例にマッチする割合 $+ \Pi$ が D の負事例にマッチしない割合 $)/2$ で定義する．よって，D に関する適合度の高い BPO グラフパターン集合とは，D の多くの正事例にマッチし，D の負事例にあまりマッチしないような特徴的な BPO グラフパターン集合であるといえる．BPO グラフパターン集合を獲得する進化的手法 (メインルーチン) は，特徴的な BPO グラフパターンを獲得する遺伝的プログラミングをサブルーチンとして使う二段階の構造をしている．メインルーチンでは，個体である BPO グラフパターン集合 $\{\pi_1, \pi_2, \ldots, \pi_c\}$ を，BPO グラフパターン列 $[\pi_1, \pi_2, \ldots, \pi_c]$ として扱う．

3. 外平面的グラフのクラスタリングよる複合的なブロック保存型外平面的グラフパターンの進化的獲得

特徴的な BPO グラフパターン集合獲得手法のための外平面的グラフの正事例データのクラスタリング手順の概要を以下に示す．

外平面的グラフの正事例データのクラスタリングの手順
1. ブロック木パターンの正規形表現を用いて，外平面的グラフを根付き順序木へと変換する．
2. 根付き順序木へと変換した外平面的グラフからグラム分布で特徴分布の表を作成する．
3. 特徴選択を用いて，正事例と負事例を分類するのに選択された特徴以外を特徴分布の表から削除する．
4. 正事例データの特徴ベクトルをカーネル PCA により，指定した次元の空間の点に変換し，ユークリッド距離を用いて距離行列を計算する．
5. 距離行列に対して，ソフトクラスタリングを行う．

次にこの手順の詳細を説明する．まず，外平面的グラフ間の距離を計算するために，グラム分布 (gram distribution)[Kuboyama 06] を用いる．グラム分布は木の指定した長さのパスと同型な部分木の出現頻度をベクトルにしたものである．グラム分布は頂点にのみラベルが付いた木を対象としているので，出現部分木の辺ラベルは無視して同型判定を行う．またグラム分布は根付き順序木に対して計算を行うので，外平面的グラフを根付き順序木へと変換する必要がある．外平面的グラフをブロック木へと変換し，ブロック木パターンの正規形表現 [Tokuhara 16b, 徳原 17a] を用いて，ブロック木の正規形表現を求めることで根付き順序木へと変換することができる．求めたブロック木の正規形表現に対して，パスの長さが 1 から 4 までのグラム分布を計算し特徴分布の表を作成する．特徴的な BPO グラフパターン集合獲得手法では，正事例と負事例を分類する特徴によって正事例が分類されている方がより高い適合度の個体を獲得できると考えられる．よって，CWC 特徴選択法 [Shin 15] を用いて，正事例と負事例を分類するのに必要な特徴だけ選択し，分類するのに必要のない特徴は特徴分布の表から削除する．選択された特徴のみを残した特徴分布の表から求めた正事例データの特徴ベクトルを，カーネル PCA を用いて，指定した次元 (d) の空間の点へと変換する．ユークリッド距離を用いて距離

行列を計算し，求めた距離行列に対してソフトクラスタリングを行う．特徴的な BPO グラフパターン集合獲得手法では，正事例が複数のクラスタに属することを許すのでソフトクラスタリングを行い，正事例が閾値 (m) 以上の帰属度を持つクラスタに属するものとする．

4. 実験

外平面的グラフのクラスタリングよる特徴的な複合的ブロック保存型外平面的グラフパターンの進化的獲得手法を，Intel Xeon CPU E5-2630 v2 2.60GHz プロセッサ，実装メモリ 32.0GB の Windows10 Pro 64bit OS 上に Java 言語で実装した．比較のため，特徴的な BPO グラフパターン獲得手法も同じ環境で実装した．

人工データ D を次のように生成して，実験データとした．設定した BPO グラフパターン集合 $\Pi = \{\pi_1, \pi_2, \pi_3\}$ について，人工的に生成した外平面的グラフのうち Π にマッチするものを正事例，マッチしないものを負事例として，500 個の正事例と 500 個の負事例からなる外平面的グラフの集合 D を作成した．

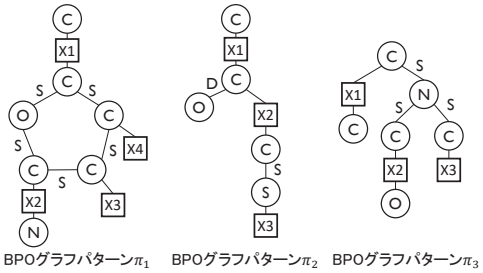


図 2: 人工データ作成のために設定した BPO グラフパターン集合 $\Pi = \{\pi_1, \pi_2, \pi_3\}$

外平面的グラフの正事例データのクラスタリング手順 4 において，変換後の正事例データ空間の次元を $d = 10$ とした．手順 5 のソフトクラスタリングを行った後に，正事例のクラスタに属すると指定する帰属度の閾値を $m = 0.2$ とした．ソフトクラスタリングは fuzzy k-means を行う R 言語のパッケージである fclust[CRAN] を用いて行った．

fclust にはクラスタ数の妥当性を評価する 6 つの指標が用意されている．その指標で評価を行ったところ，クラスタ数 $c = 2, 3, 4, \ldots$ と数を大きくするにつれ，全ての指標で妥当性の評価が低下した．よってクラスタ数 $c = 2, 3$ の 2 つの設定で実験を行った．

特徴的な BPO グラフパターン集合獲得手法 (メインルーチンの進化的手法) のパラメータを次のように設定した．BPO グラフパターンの上位数 (k):10($c = 2$ のとき),5($c \neq 2$ のとき)，集団サイズ (b):50，エリートサイズ (e):5，最大世代数 (n):200，加算適合度の最大値 (C_{add}):0.1．

特徴的な BPO グラフパターン獲得手法 (サブルーチン及び比較実験の遺伝的プログラミング) のパラメータを次のように設定した．集団サイズ (b'):50，エリートサイズ (e'):3，最大世代数:200，トーナメントサイズ:2，複製確率:0.05，交叉確率:0.50，突然変異確率:0.45．

特徴的な BPO グラフパターン獲得手法を 10 試行，特徴的な BPO グラフパターン集合獲得手法を正事例のクラスタリングのクラスタ数 c を $c = 2, 3$ として，それぞれ 10 試行の実験を行った．特徴的な BPO グラフパターン獲得手法，特徴的な BPO グラフパターン集合獲得手法（クラスタ数 $c = 2, 3$）の全 10 試行の実行時間の平均はそれぞれ，6843 秒，29341 秒，44980 秒であった．また特徴的な BPO グラフパターン獲得手法，特徴的な BPO グラフパターン集合獲得手法の各試行における最終世代の最良個体の適合度を表 1 に，各世代における最良個体の適合度の 10 試行の平均を図 3 に示す．最終世代の最良個体である BPO グラフパターン集合と BPO グラフパターンを図 4 に示す．

表 1: 各試行における最終世代の最良個体の適合度

試行	BPO グラフパターン獲得	BPO グラフパターン集合獲得	
		$c = 2$	$c = 3$
1	0.719	0.753	0.881
2	0.719	0.880	0.852
3	0.715	0.733	0.719
4	0.715	0.880	0.881
5	0.715	0.822	0.881
6	0.715	0.797	0.847
7	0.715	0.872	0.817
8	0.719	0.822	0.717
9	0.719	0.745	0.717
10	0.715	0.793	0.720
平均	0.717	0.810	0.803

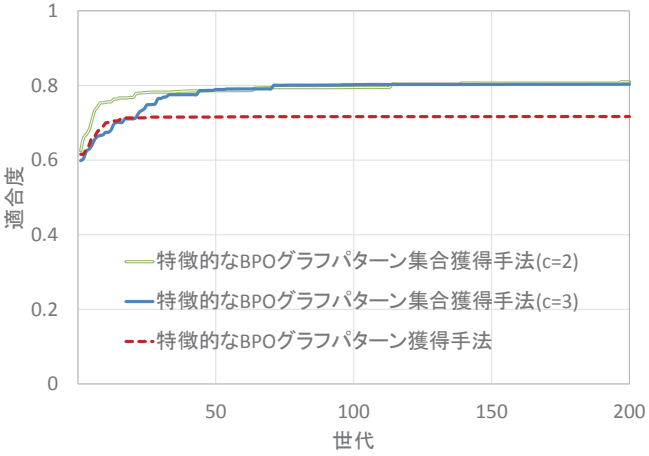


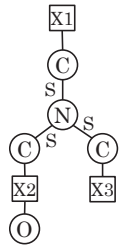
図 3: 各世代における最良個体の適合度の平均

5. おわりに

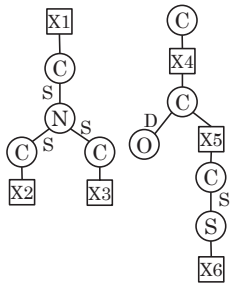
本稿では，二段階構造の進化的獲得手法のために外平面的グラフの正事例集合をクラスタリングする手法を提案し，正事例と負事例の外平面的グラフから特徴的な複合的 BPO グラフパターンを獲得する進化的手法を人工データに適用した実験結果を報告した．今後の課題として，計算時間の短縮などが挙げられる．

謝辞

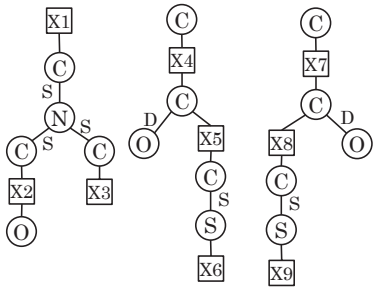
本研究は JSPS 科研費 JP15K00312, JP15K00313, JP17K00321 の助成を受けたものです．



特徴的なBPOグラフパターン
獲得手法の第1,8試行目の最終世代最良個体
適合度0.719



特徴的なBPOグラフパターン集合
獲得手法(クラスタ数$c = 2$)の
第4試行目の最終世代最良個体
適合度0.880



特徴的なBPOグラフパターン集合
獲得手法(クラスタ数$c = 3$)の
第5試行目の最終世代最良個体
適合度0.881

図 4: 獲得した特徴的な BPO グラフパターン集合と特徴的な BPO グラフパターン

参考文献

[Banzhaf 98] W.Banzhaf et al.: *Genetic Programming: An Introduction : On the Automatic Evolution of Computer Programs and Its Applications*, Morgan Kaufmann (1998)

[CRAN] CRAN: Package fclust, *https://cran.r-project.org/web/packages/fclust/index.html*

[Horvath 10] T.Horvath et al.: Frequent Subgraph Mining in Outerplanar Graphs, *Data Mining and Knowledge Discovery*, Vol. 21, pp. 472–508 (2010)

[Katagiri 00] H.Katagiri et al.: Genetic Network Programming - Application to Intelligent Agents, *Proc. IEEE SMC 2000*, pp. 3829–3834 (2000)

[Koza 92] J.R.Koza: *Genetic Programming: On the Programming of Computers by Means of Natural Selection*, MIT Press (1992)

[Kuboyama 06] T.Kuboyama et al.: A Gram Distribution Kernel Applied to Glycan Classification and Motif Extraction, *Genome Informatics*, Vol. 17(2), pp. 25–34 (2006)

[Miyahara 14] T.Miyahara and T.Kuboyama: Learning of Glycan Motifs Using Genetic Programming and Various Fitness Functions, *JACIII*, Vol. 18(3), pp. 401–408 (2014)

[Nagai 12] S.Nagai et al.: Acquisition of Characteristic TTSP Graph Patterns by Genetic Programming, *Proc. IIAI AAI 2012*, pp. 340–344 (2012)

[Nagamine 07] M.Nagamine et al.: A Genetic Programming Approach to Extraction of Glycan Motifs using Tree Structured Patterns, *Proc. AI-2007, Springer-Verlag, Vol. 4830*, pp. 150–159 (2007)

[Nakai 13] S.Nakai et al.: Acquisition of Characteristic Tree Patterns with VLDC's by Genetic Programming and Edit Distance, *Proc. IIAI AAI 2013*, pp. 147–151 (2013)

[Nakai 14] S.Nakai et al.: Acquisition of Characteristic Sets of Tree Patterns with VLDC's using Genetic Programming and Edit Distance, *Proc. IWCIA 2014*, pp. 113–118 (2014)

[Ouchiyama 15] Y.Ouchiyama et al.: Acquisition of Characteristic Block Preserving Outerplanar Graph Patterns from Positive and Negative Data using Genetic Programming and Tree Representation of Graph Patterns, *Proc. IWCIA 2015*, pp. 95–101 (2015)

[Rehman 12] S.Rehman et al.: Graph Mining: A Survey of Graph Mining Techniques, *Proc. ICDIM 2012*, pp. 88–92 (2012)

[Sasaki 08] Y.Sasaki et al.: Mining of Frequent Block Preserving Outerplanar Graph Structured Patterns, *Proc. ILP-2007, Springer-Verlag LNAI 4894*, pp. 239–253 (2008)

[Shin 15] K.Shin et al.: Super-CWC and Super-LCC: Super Fast Feature Selection Algorithms, *Proc. IEEE Big Data 2015*, pp. 61–67 (2015)

[Shirakawa 07] S.Shirakawa et al.: Graph Structured Program Evolution, *Proc. GECCO 2007*, pp. 1686–1693 (2007)

[Tokuhara 16a] F.Tokuhara et al.: Acquisition of Characteristic Block Preserving Outerplanar Graph Patterns by Genetic Programming using Label Information, *Proc. IIAI AAI 2016*, pp. 203–210 (2016)

[Tokuhara 16b] F.Tokuhara et al.: Using Canonical Representations of Block Tree Patterns in Acquisition of Characteristic Block Preserving Outerplanar Graph Patterns, *Proc. IWCIA 2016*, pp. 93–99 (2016)

[Tokuhara 17] F.Tokuhara et al.: Acquisition of Multiple Block Preserving Outerplanar Graph Patterns by an Evolutionary Method for Graph Pattern Sets, *Proc. IWCIA 2017*, pp. 191–197 (2017)

[Yamagata 17] Y.Yamagata et al.: Acquisition of Multiple Graph Structured Patterns by an Evolutionary Method using Sets of TTSP Graph Patterns as Individuals, *Proc. IIAI AAI 2017* (2017)

[Yamasaki 09] H.Yamasaki et al.: Learning Block-Preserving Graph Patterns and Its Application to Data Mining, *Machine Learning*, Vol. 76, pp. 137–173 (2009)

[徳原 17a] 徳原史也ほか : 遺伝的プログラミングによる複合的なブロック保存型外平面的グラフパターンの獲得, 2017 年度人工知能学会全国大会論文集,4H2-2 (2017)

[徳原 17b] 徳原史也ほか : 特徴的なブロック保存型外平面的グラフパターンの獲得におけるブロック木パターンの深さラベル列の利用, 2017 年度人工知能学会全国大会論文集,4E1-2 (2017)

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

ディープ RBF 型 GMDH-type ニューラルネットワークを用いた肝臓がんの医用画像診断

Medical image diagnosis of liver cancer using deep RBF GMDH-type neural network

高尾 正一郎[*1] Shoichiro Takao
近藤 明佳[*2] Sayaka Kondo
上野 淳二[*3] Junji Ueno
近藤 正[*4] Tadashi Kondo

[*1]徳島大学 Tokushima University
[*2]徳島医用情報科学研究会 Tokushima medical informatics laboratory
[*3]徳島大学 Tokushima University
[*4]徳島大学 Tokushima University

In this study, a deep Radial Basis Function (RBF) Group Method of Data Handling (GMDH)-type neural network which has the deep neural network architecture, is applied to the medical image diagnosis of liver cancer. Deep RBF GMDH-type neural network has abilities of self-selecting the number of hidden layers, the number of neurons in hidden layers and useful input variables. This algorithm is applied to medical image recognition of liver cancer and it is shown that this algorithm is useful for medical image diagnosis of liver cancer and is very easy to apply practical complex problem because deep neural network architecture with many hidden layers, is automatically organized so as to minimize the prediction error criterion defined as Akaike's Information Criterion (AIC) or Prediction Sum of Squares (PSS).

1. はじめに

ディープGMDH-type ニューラルネットワークスのアルゴリズムは、著者らのグループにより数種類のアルゴリズムが提案され[Kondo 98, 12, 15, 15]、すでに、肝臓、肺、脳、心臓、腎臓、脾臓、血管、骨などのいろいろな臓器の画像認識や領域抽出問題に応用されており、各種臓器の高精度な領域抽出結果が得られている。さらに、学習用の入力画像を変えることにより、肺がんや肝臓がんなどのがん領域の画像認識や領域抽出への応用が可能である。ディープGMDH-type ニューラルネットワークスは、進化論的計算法の一種である発見的自己組織化法を用いて、多くの中間層を持つ複雑な構造をしたディープニューラルネットワーク構造を自動的に自己組織化する。ニューラルネットワーク構造は、予測誤差評価基準(情報量基準 AIC[Akaike 74]や予測誤差平方和(PSS)[Tamura 80])を最小にするように、中間層の数、各層のニューロン数、有益な入力変数などを自己選択して最適化しており、対象の非線形システムの複雑さに適したディープニューラルネットワーク構造を自己組織している。

本研究では、ディープGMDH-type ニューラルネットワークスの一種である、ディープ RBF 型GMDH-type ニューラルネットワークを用いて、肝臓がんの画像認識とその領域抽出を行う。本研究で使用するディープ RBF 型GMDH-type ニューラルネットワークの特徴は、多項式型ニューロンと RBF 型ニューロンを組み合わせて、データ数が少ない場合でも、非線形性の強い複雑な構造をした対象システムの特徴を、高次非線形多項式(g_i)を用いて高精度に同定できることに特徴がある。ディープ RBF 型GMDH-type ニューラルネットワークスを肝臓がんの医用画像診断に応用して、その有効性を確認する.

2. 発見的自己組織化の原理

ディープ GMDH-type ニューラルネットワークスのアルゴリズム[Kondo 98, 12, 15, 15]は、GMDH 法で用いられている発見的自己組織化の原理[Farlow 84], [Ivakhnenko 70]に基づいて、ニューラルネットワークスの構造を自己組織化している。以下に発見的自己組織化の原理の概略を示す。

＊連絡先：近藤 正、徳島大学医学部保健学科
[*4] Email: kondomedsci@gmail.com

発見的自己組織化の原理では、次に示す5つのステップにより非線形システムの入出力関係式(これをシステムの完全記述式という)を構成する。

1)原データのトレーニングデータとテストデータへの分割

トレーニングデータはシステムの部分記述式(部分的なシステムの特徴を表す式)のパラメータの推定に用い、テストデータはシステムの完全記述式の構造選択に用いる。

2)入力変数の組み合わせの発生

すべての入力変数の組み合わせを発生させる。

3)最適な部分記述式の発生

各々の組み合わせに対して、システムの部分記述式を発生させる。発生したシステムの部分記述式の出力を中間変数(y)と呼ぶ。

4)中間変数の自己選択

テストデータに対する誤差(テストエラー)を小さくする L 個の中間変数を自己選択する。

5)多層構造の繰り返し計算の停止

自己選択した L 個の中間変数を、次層の入力変数にセットして繰り返し計算を行い、多層構造を構成していく。この繰り返し計算は、テストエラーが減少しなくなった層で停止する。そして、システム全体の完全記述式は、各層で自己選択した部分記述式を用いて構成する。

以上の手続きにより構成される発見的自己組織化の原理は基本的な概念が進化論的計算法と同じである。

3. ディープ RBF 型 GMDH-type ニューラルネットワークス

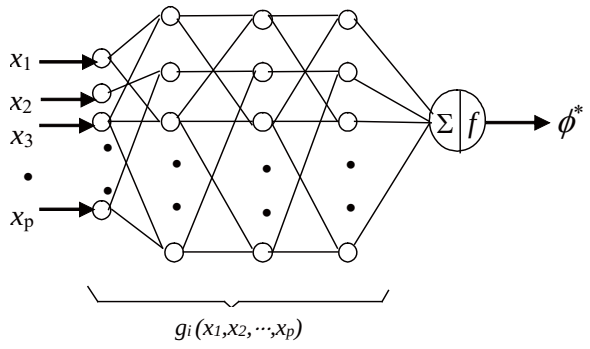
最適なネットワーク構造を自己選択するディープ RBF 型 GMDH-type ニューラルネットワークスの構造を、Fig.1 に示す。中間層の個数、各々の中間層におけるニューロンの個数、有益な入力変数、最適なニューロンの構造は、情報量規準 AIC[Akaike 74]や予測誤差平方和(PSS)[Tamura 80]を最小にするように自動的に決定する。

非線形関数 g_i は、次に示す Kolmogorov-Gabor polynomial

$$g_i(x_1,x_2,\cdots,x_p) = a_0 + \sum_i a_i x_i + \sum_i \sum_j a_{ij} x_i x_j + \sum_i \sum_j \sum_k a_{ijk} x_i x_j x_k + \cdots \quad (1)$$

を示す。この非線形関数は、多項式型ニューロンを用いて構成することができる。本研究では、多層構造の層の数、

中間層におけるニューロンの個数、有益な入力変数、最適なニューロンの構造は、予測誤差平方和(PSS)を最小にするように決定する。



$g_i(x_1,x_2,\cdots,x_p)$

Output layer:

Σ: (Nonlinear function)

$z = \sum w_i g_i(x_1,x_2,\cdots,x_p)$

f : (Nonlinear function)

$\phi^*=\exp(-z^2)$

Fig.1 Architecture of deep RBF GMDH-type neural network

本アルゴリズムの概要を以下に示す。

本アルゴリズムでは、予測誤差評価基準(PSS)を用いるので原データを 2 組に分割する必要がなく、すべてのデータをトレーニングデータとして用いる。

3.1 第 1 層

$$u_j=x_j \qquad (j=1,2,\ldots,p) \tag{2}$$

ここで、x_j はシステムの入力変数を示す。

3.2 第 2 層

入力変数(u)どうしを組み合わせて、2変数のすべての組み合わせ(u_i, u_j)を発生させる。各組み合わせに対して、ニューロンの構造は次の関数を用いる。

＜多項式型ニューロン＞

Σ: (Nonlinear function)

$$z_k=w_1u_i+w_2u_j+w_3u_iu_j+w_4u_i^2+w_5u_j^2 - w_0\theta_1 \tag{3}$$

f : (Linear function)

$$y_k= z_k \tag{4}$$

ここで、θ_1 =1、w_i (i=0,1,2,…,9)は入力層と中間層との間の重みを示す。このニューロンは多項式ニューロンで、Σ と f の2個の関数から構成され、ニューロンの重み w の値は、主成分回帰分析[Draper 81]を用いて次のように推定する。ニューロンの出力(y)を中間変数とする。

まず、各々のニューロンに対して z^{**} の値を計算する。

$$z^{**}=(-\log_e\phi')^{1/2} \tag{5}$$

ここで、ϕ はシステムの出力変数、ϕ'は 0 から 1 の間の値に規準化された出力変数を示す。

各々のニューロンに対して、トレーニングデータを用いて、主成分回帰分析により重み w を推定する。主成分回帰分析を用いることにより、層を通過すると発生していた中間変数間の多重共線性を防止することができ、高精度な学習計算を実行することができる。

主成分回帰分析を用いたニューロンの学習計算では、初めに入力変数の組み合わせに対して主成分の抽出を行う。(3)式のニューロンの場合を例にとる。

まず、固有ベクトルを計算する。

$$\underline{\boldsymbol{v}} = H \cdot \underline{\boldsymbol{u}} \tag{6}$$

ここで,

$\underline{\boldsymbol{v}}=(v_1,v_2,\ldots,v_5)$

$\underline{\boldsymbol{u}}=(u_i\ u_j,\ u_iu_j,\ u_i^2,\ u_j^2)$

$\underline{\boldsymbol{v}}$ は固有ベクトル、H は固有行列で次式により固有値問題を解くことによって計算する。

$$R \cdot H = H \cdot \Lambda \tag{7}$$

ここで、R は相関行列を表す。次に、変数 z_k を直交回帰分析により計算する。

$$z_k = \underline{\boldsymbol{w}}^{\mathrm{T}} \cdot \underline{\boldsymbol{v}} = w_1v_1+w_2v_2+\ldots+w_5v_5 \tag{8}$$

この場合、出力変数として z_k^{**} を用いる。そして、PSS を変数選択の評価基準として変数選択型重回帰分析法[Draper 81]を用いて有益な主成分のみを選択する。そして、z_kからニューロンの出力(y_k)を計算する。

次に、発生したニューロンに対して、PSS 値の小さいものを L 個選択する。L 個のニューロンの出力値(y_k)を次層の入力変数にセットして、次層の計算に移る。

$$u_k=y_k \qquad (k=1,2,\ldots,L) \tag{9}$$

3.3 第 3 層以上の層

3 層以上の層では、第 2 層と同じ計算を繰り返す。そして、L 個のニューロンの PSS の値が減少しなくなる層で隠れ層の計算を停止する。隠れ層の計算を停止した場合、最終の隠れ層を出力層とする。

出力層ではニューラルネットワークの出力変数(ϕ^*)を z_kから次のように計算する。

$$\phi^*=\exp(-z_k^2) \tag{10}$$

このため出力層では、ニューロン構造は以下のようになる。

〈RBF ニューロン〉

Σ: (Linear function)

$$z_k=\Sigma w_ig_i(x_1,x_2,\ldots,x_p) \tag{11}$$

f : (Nonlinear function)

$$\phi^*=\exp(-z_k^2) \tag{12}$$

以上の手続きによりディープ RBF 型 GMDH-type ニューラルネットワークを構成できる。

4. 肝臓がんの医用画像診断への応用

本研究では、ディープ RBF 型 GMDH-type ニューラルネットワークスを用いて、肝臓がんの画像認識とその領域抽出を行った。本研究では、医用画像としてマルチスライスCT画像を用いた。まず最初の手続きとして、肝臓の正常な領域をディープ RBF 型 GMDH-type ニューラルネットワークを用いて画像認識させ、これらの領域を抽出した。次に、画像の後処理を行うことにより肝臓がんを含んだ肝臓の全体の領域を抽出した。次に、抽出した肝臓の画像を用いて、新しいディープ RBF 型 GMDH-type ニューラルネットワークを自己組織化することにより肝臓がんの候補領域を抽出した。なお、本研究では予測誤差の評価基準として PSS を用いた。

4.1 ディープ RBF 型 GMDH-type ニューラルネットワークスによる肝臓領域の画像認識と領域抽出

Fig.2 に、ニューラルネットワークスを自己組織化するために用いた原画像を示す。ニューラルネットワークスの入力変数としては $N\times N$ 近傍領域の画像特徴量を用いた。これは、平均値、分散、標準偏差、中央値、範囲、最大値、最小値などの基本統計量と位置情報(x と y 座標)である。これらの特徴量の中から、平均値、標準偏差、分散、x 座標、y 座標の5変数がニューラルネットワークスにより有益な入力変数として自己選択された。近傍領域の大きさ N は、3 から 10 の値に対してニューラルネットワークスを自己組織化した。その結果、N が 7 の場合に、最も良い画像認識精度を得た。ニューラルネットワークスの出力変数は、0 か 1 の値をとり、対象臓器の領域内部では 1 の値を出力

するように学習させた。ディープ RBF 型 GMDH-type ニューラルネットワークスの計算は第 10 層で終了した。そして、各々の中間層では 5 個のニューロンが自己選択された。Fig.3 に、各層における PSS 値の変化を示す。層を通過することにより PSS 値は徐々に減少して予測誤差が非常に小さな値に収束した。

自己組織化されたディープ RBF 型 GMDH-type ニューラルネットワークスによって肝臓領域が出力された。Fig.4 に、ニューラルネットワークの出力画像を示す。肝臓の正常な領域が抽出されている。肝臓の内部の正常でない領域と肝臓の外部の領域（孤立点）はほとんど含まれていないことがわかる。次に、出力画像に対して画像の後処理が行われた。ニューラルネットの出力画像に対する後処理では、まず、肝臓領域の輪郭を *N*/2 画素分だけ外側に拡張した。次に、画像の膨張処理や収縮処理、周囲長処理などを行い、肝臓領域の内部に孤立した部分がある場合や、肝臓領域の外部にある孤立点が除去された。そして、肝臓がんを含んだ肝臓の全体の領域を抽出した。Fig.5 に、ニューラルネットワークスの出力画像に後処理を行った画像を示す。原画像との一致性を確認するために、原画像との重ね合わせを行った。Fig.6 に原画像と後処理後の出力画像を重ね合わせ画像を示す。この画像から、ニューラルネットワークスによって画像認識された肝臓領域は、原画像の肝臓領域によく一致していることがわかる。そして、肝臓領域を、原画像(Fig.2)から後処理後の画像（Fig.5）を差分することにより抽出した。Fig.7 に差分画像（グレー画像）を示す。

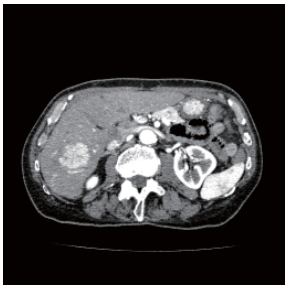


Fig.2 Original image (1)

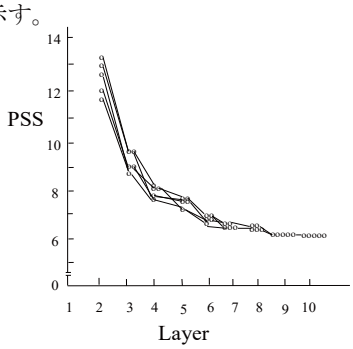


Fig.3 Variation of PSS in the deep RBF GMDH-type of NN(1)

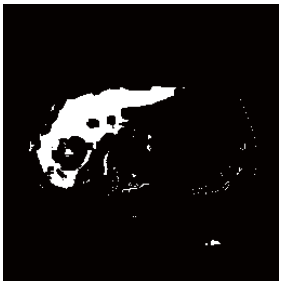


Fig.4 Output image of the neural network(1)

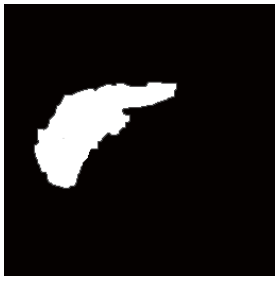


Fig.5 Output image after the first post-processing

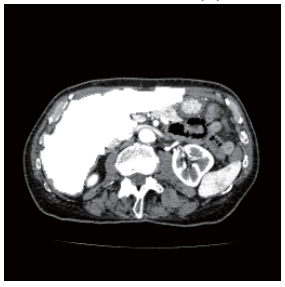


Fig.6 Overlapped image(1)

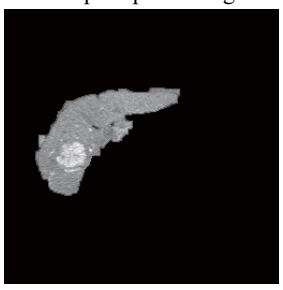
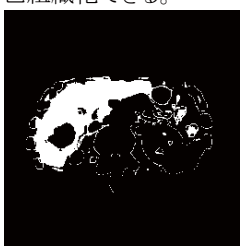


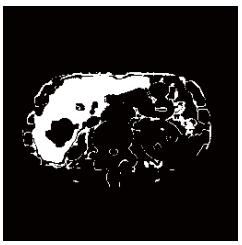
Fig.7 Extracted gray scale image

4.2　3 層構造のシグモイド関数型ニューラルネットワークによる肝臓領域の画像認識と領域抽出

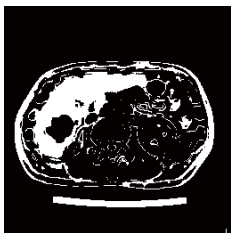
バックプロパゲーション法を用いて学習する 3 層構造のシグモイド関数型ニューラルネットワークを用いて肝臓領域の画像認識を行い、画像認識結果の比較を行った。ニューラルネットワークは、入力層、中間層、出力層の 3 層構造とした。入力変数や学習データは、ディープ RBF 型 GMDH-type ニューラルネットワークと同じものを用いた。学習では、各々の学習データを 10,000 回学習させた。結合加重の初期値は乱数により設定した。本研究では、中間層のニューロン数(*m*)を変化させて画像認識を行った。Fig.8 に、*m*=5、*m*=7 と *m*=9 の場合の出力画像を示す。出力画像は Fig.4 に対応している。これらのニューラルネットワークの出力画像には、孤立点や肝臓領域でない領域を多く含んでおり、画像認識精度が十分でないことがわかる。また、中間層のニューロン数(*m*)を変化させた場合に、異なった出力画像が得られた。このニューラルネットワークスでは、ネットワーク構造の自己選択機能を持たないため、中間層のニューロンの個数や中間層の個数などの構造パラメータを変化させて、より望ましいネットワーク構造を見つけ出す必要がある。このため、構造パラメータを変化させて、非常に多くの繰り返し計算を行う必要がある。さらに、解が局所解に収束した場合には、よい精度が得られないために結合加重の初期値を変化させてさらに多くの繰り返し計算を行う必要がある。これに対して、ディープ RBF 型 GMDH-type ニューラルネットワークでは、このような構造パラメータを変化させた繰り返し計算を必要としないため、1 回の計算で複雑な構造をしたディープニューラルネットワークを自己組織化できる。



(a) *m*=5



(b) m=7



(c) *m*=9

Fig.8 Output images of the conventional sigmoid function neural network using back propagation algorithm

4.3 ディープ RBF 型 GMDH-type ニューラルネットワークスによる肝臓がん領域の画像認識と領域抽出

Fig.7 の抽出された肝臓領域のグレー画像を原画像(Fig.9)として用いて、肝臓がんの領域抽出を目的にした新しいニューラルネットワークスを自己組織化した。ニューラルネットワークスの入力変数としては 4.1 のニューラルネットワークと同じものを用いた。近傍領域の大きさ N は、2 から 10 の値に対してニューラルネットワークスを自己組織化した。その結果、N が 2 の場合に、最も良い画像認識精度を得た。ニューラルネットワークスの出力変数は、0 か 1 の値をとり、肝臓がんの内部では 1 の値を出力するように学習させた。ディープ RBF 型 GMDH-type ニューラルネットワークスの計算は第 6 層で終了した。Fig.10 に、各層に

おける PSS 値の変化を示す。層を通過することにより PSS 値は徐々に減少して予測誤差が非常に小さな値に収束した。

Fig.11 に最終層で得られた出力画像を示す。次に、この出力画像に対して画像の後処理を行った。ニューラルネットの出力画像に対する後処理では、画像の収縮処理、膨張処理、周囲長処理などを行い、肝臓がん領域の外部にある孤立点が除去された。そして、肝臓がん領域の輪郭を N/2 画素分だけ外側に拡張した。Fig.12 に、ニューラルネットワークスの出力画像に後処理を行った画像を示す。原画像との一致性を確認するために、原画像との重ね合わせを行った。Fig. 13 に原画像と後処理後の出力画像を重ね合わせ画像を示す。この画像から、ニューラルネットワークスによって画像認識された肝臓がん領域は、原画像の肝臓がん領域によく一致していることがわかる。そして、原画像から差分を行うことにより肝臓がんの候補領域が抽出された。Fig.14 に肝臓がんの候補領域を示す。

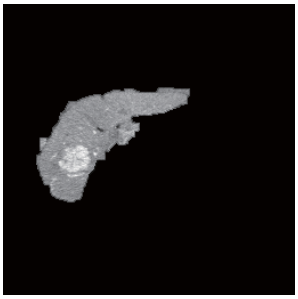


Fig.9 Original image(2) (Fig.7)

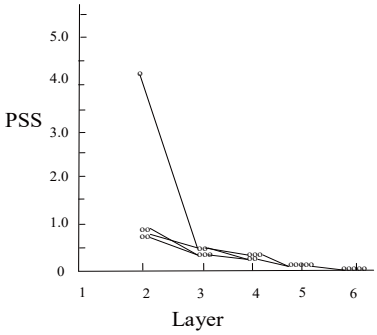


Fig.10 Variation of PSS in the deep RBF GMDH-type NN(2)

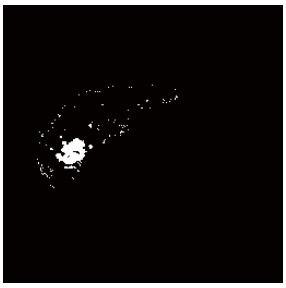


Fig.11 Output image of the neural network(2)

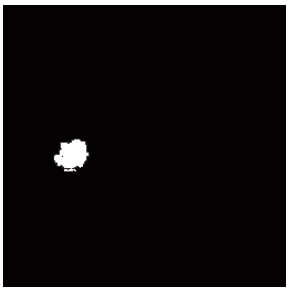


Fig. 12 Output image after the second post processing



Fig. 13 Overlapped image(2)

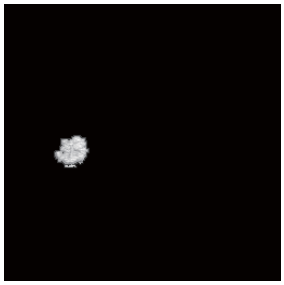


Fig.14 Candidate regions of liver cancer

5. 考察

ディープ RBF 型 GMDH-type ニューラルネットワークスのアルゴリズムを肝臓がんの画像認識とその領域抽出へ応用した。まず、肝臓領域の画像認識と領域抽出では、10 層のディープニューラルネットワークを自己組織化した。PSS 値は第 2 層では大きいが、層を通過するごとに減少して、第 10 層ではかなり小さな値になった。有益な入力変数が自己選択された。また、領域抽出された肝臓領域は実際の肝臓領域によく一致していた。次に、肝臓がん領域の画像認識と領域抽出では、6 層のディープニューラルネットワークを自己組織化した。出力層の PSS 値は非常に小さくなった。また、抽出された肝臓がんの領域は実際の肝臓がんの領域によく一致していた。また、学習に用いたデータは、学習に用いた 1 枚のスライス画像上の、約 200 点の学習ポイントが対象臓器に含まれるかどうかを、コンピュータに教えるのみでディープニューラルネットワークを自己組織化できた。自己組織化したディープニューラルネットワークは、学習に用いなかった他のスライス画像(約 150 枚のスライス画像)に対しても精度良く適用できた。

6. むすび

ディープ RBF 型 GMDH-type ニューラルネットワークスのアルゴリズムは、発見的自己組織化の原理を用いて、対象の医用画像の特徴に最も適したディープニューラルネットワークス構造を自己選択する機能を備えている。さらに、中間層の個数、中間層のニューロンの個数、有益な入力変数、最適なニューロン構造などの構造パラメータを、情報量基準(AIC)や予測誤差平方和(PSS)を最小にするように、データ数が少ない場合でも自己選択できる機能を備えている。このため実際問題への応用が非常に容易である。本研究では、肝臓がんの画像診断問題へ応用して、肝臓領域と肝臓がん領域を精度良く領域抽出してその有効性を確認した。

参 考 文 献

[Akaike 74] H. Akaike: A new look at the statistical model identification, IEEE Trans. Automatic Control, Vol.AC-19, No.6, pp.716-723, 1974.

[Draper 81] N. R. Draper and H. Smith : Applied Regression Analysis, John Wiley and Sons, New York, 1981.

[Farlow 84] S.J.Farlow ed.: Self-organizing methods in modeling, GMDH-type algorithm, Marcel Dekker, Inc., New York, 1984.

[Ivakhnenko 70] A. G. Ivakhnenko: Heuristic self-organization in problems of engineering cybernetics, Automatica, Vo.6, No.2, pp.207-219, 1970.

[Kondo 98] T. Kondo: GMDH neural network algorithm using the heuristic self organization method and its application to the pattern identification problem, Proc. of the 37th SICE Annual Conference, pp.1143-1148, 1998.

[Kondo 12] T. Kondo, J. Ueno and S. Takao: Feedback GMDH-type neural network and its application to medical image analysis of liver cancer, *International Journal of Innovative Computing, Information and Control,* Vol.8, No.3, pp.2285-2300, 2012.

[Kondo 15] T. Kondo, J. Ueno and S. Takao: Logistic GMDH-type neural network using principal component-regression analysis and its application to medical image diagnosis of lung cancer, *Artificial Life and Robotics,* Vol.20, No.2, pp.137-144 2015.

[Kondo 15] T. Kondo, J. Ueno and S. Takao: Medical image diagnosis of liver cancer by hybrid feedback GMDH-type neural network using principal component-regression analysis, *Artificial Life and Robotics,* Vol.20, No.2, pp.145-151, 2015.

[Tamura 80] H. Tamura and T. Kondo: Heuristics free group method of data handling algorithm of generating optimum partial polynomials with application to air pollution prediction, Int. J. System Sci., Vol.11, No.9, pp.1095-1111, 1980.

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

進化計算を用いたフィルター特徴選択に関する評価指標の提案

Proposal a new feature evaluation measure for filter type feature subset selection with Evolutionary Algorithm

川村 篤志[*1]
Atsushi Kawamura

チャクラボルティ バサビ[*2]
Basabi Chakuraborty

[*1] 岩手県立大学大学院
Graduate School of Iwate Prefectural University

[*2] 岩手県立大学
Iwate Prefectural University

Feature Selection is an important preprocessing step for pattern recognition and data mining problems. This process selects necessary features and removes redundant features. In this work, we propose a new fitness function for feature subset evaluation. The proposed new fitness function is used for feature subset selection with EC algorithms. Simulation experiments using the benchmark datasets have been done and the results are compared with popular methods.

1. はじめに

近年，インターネットが普及し，SNS やクラウドからは画像やテキスト，ウェアラブル端末などの IoT デバイスからセンサーデータというように，様々なメディアからデータの送出が容易になってきている．

加えて，計算機性能や解析技術，ストレージ技術の向上により膨大なデータの収集や解析が容易になってきている．また，この膨大なデータを解析することで，知見を獲得しようという動きが活発化している．このため，データマイニングや機械学習の研究領域に対して重要性が高まってきている．

データの解析を行う際に，精度や処理速度を向上させ，効率的にデータを処理することが必要である．しかし，データをすべて用いて分類を行った場合，処理コストが高く，精度も悪くなってしまう傾向がある．これは，余計な特徴がデータ内に含まれているからである．そこで，解析を行う前処理として特徴選択という手法があげられる．これは非常に重要な処理であり，これを行うことで，精度の向上や処理コストの軽減が見込める．しかし，多くの特徴を持つデータから最適な特徴の組み合わせを選択することは，非常に困難である．したがって，効率よく最適であると思われる特徴部分集合を獲得できる手法を考える必要がある．

本稿では，特徴選択の評価指標に関して新たな評価指標の提案を行う．また，提案する評価指標と進化計算を用いて特徴選択を行い，全ての特徴を用いた場合と従来手法を用いた場合の精度と比較することで，本提案手法が有用であるかを検証することを目的とする．

2. 特徴選択

特徴選択とは，データから必要な特徴部分集合を選択し，不必要な特徴部分集合を削除する手法である．これを行うことによって，精度や汎化性能の向上，次元の呪いの緩和，処理の高速化などが期待される．

特徴選択は，主に 2 つの過程に分けられる．1 つ目は特徴部分集合を選択する探索手法である．どの特徴を使用し，どの特徴を削除するかを決定する方法である．例としては Sequential Forward Selection(SFS)，総当たり法，焼きなまし法，進化計算などがあげられる．特徴数を k とすると特徴部分集合の組み合わせ数は$2^k - 1$で指数的に増加するため，特徴数が多い場合，適切な特徴部分集合の選択は困難になる．

2 つ目は，1 つ目で得られた特徴部分集合をどのように評価するかという評価方法である．評価方法は，ラッパー法とフィルター法の 2 つに大別される．

ラッパー法は，実際に使用する分類器を特徴部分集合の評価に用いる手法である．そのため，高い精度を安定して得られる．また，どのデータにも宛がうことが可能であり，汎化性も高い．しかし，逐次的に選択される特徴部分集合すべてに対して分類器を用いて評価を行うため，計算コストが高く，過剰適合を起こす可能性がある．

フィルター法は，分類器の評価を使用せずデータの性質などによって評価を行う手法である．主に情報理論や統計的手法などの指標が用いられる．基本的に単純な評価式を用いているため，選択された特徴部分集合に対しての処理が高速である．しかし，データの種類や性質によって評価が左右されるため，あまり汎化的ではない．また，情報理論などのフィルター法は主に SFS，Sequential Backward Selection (SBS)などの探索手法と併用される．そのため，特徴数が多ければ多いほど評価する特徴部分集合の組み合わせはk^2で増大し，計算コストも大幅に増大していく．また，選択する n 個の特徴(以下 n)というパラメータを設定しなければならないためヒューリスティクスである．さらに，n が適切な設定であるかはわからない．

3. 進化計算

進化計算は，主に組み合わせ最適化問題の解決に用いられるメタヒューリスティクスな手法である．例として Genetic Algorithm(GA)[Goldberg 89] や Particle Swarm Optimization(PSO)などがあげられる．進化計算は，個体からなる個体群と反復される世代で指定された評価を最適化するものである．一般的には実数に対しての最適化に多く用いられるが，0 から 1 の二値で個体内部を表現したバイナリ型の進化計算も存在する．本研究では，GA と PSO をバイナリ型にした Binary Genetic Algorithm(BGA) と Binary Particle Swarm Optimization(BPSO)[Kennedy 97]を特徴部分集合の探索手法として用いる．

4. 提案手法

既存のフィルター法は，前述の通りnを設定しなければならないアルゴリズムがほとんどである．そして，特徴数が多ければ計

連絡先:川村 篤志，岩手県立大学大学院，岩手県滝沢市巣子 152-52，g231p007@s.iwate-pu.ac.jp

算コストも多くかかる. 本研究は, これらについて解決する新しい評価指標の提案である.

4.1 提案手法について

特徴選択には Consistency という一貫性指標がフィルター法で存在している. 本研究では, 自然言語処理における各クラスタの一貫性を示す Coherence を数値データに使用できないかと考えた. そのため, Tf-idf で求められる文書中に存在する各単語の重要度の行列, 各クラスタにおける重要単語間の数値を求める UCI Coherence[Newman 10]を用いて評価を行う. それに加え各クラスタ間の距離関数として Earth Mover's Distance(EMD) [Rubner 00]を用いる.

4.2 提案手法の過程

データを 0 から 1 で正規化を行う. 0 から 1 をビンの数で分割しデータをスケーリングする. スケーリングされたデータを重要度行列に変換する. この時の重要度行列は, サンプル数 - 要素数の行列である. この重要度行列に対して Non-negative Matrix Factorization(NMF)を行う. 重要度行列を X とすると, W×H の行列に分解される. W はサンプル数-特徴行列, H は特徴-要素列である. NMF で抽出される特徴をクラス数とした場合. 各クラスタについて要素ごとの重要度が得られるので, 各クラスタの重要度上位 n 個の要素を取り出しそれぞれ Pointwise Mutual Information(PMI)を求めることで Coherence を算出する.

4.3 提案手法の説明

データのサンプル数を NS, クラス数を NC, 要素を x とする. Coherence は式(1)によって求められ, EMD は式(7)によって求められる. そして, 各クラスの Coherence の平均をS_1, 各クラスタ間の EMD の平均をS_2とした場合, S は式(11)で算出される. 本研究では, この S を進化計算によって最大化する. また, 進化計算により選択される n はメタヒューリスティクスに選択されるため n を設定しなくてよい.

$$\mathrm{Coherence} = \sum_{i,j} \mathrm{Score}(x_i, \mathrm{x_j}) \quad \ldots(1)$$

$$\mathrm{Score}_{\mathrm{UCI}(\mathrm{x_i},\mathrm{x_j})} = NPMI(x_i, x_j) \quad \ldots(2)$$

$$\mathrm{NPMI}_{(\mathrm{x_i},x_j)} = \frac{PMI(x_i, x_j)}{-\log_2(P(x_i, x_j))} \quad \ldots(3)$$

$$\mathrm{PMI}(\mathrm{x_i}, \mathrm{x_j}) = \log_2\left(\frac{P(x_i, x_j)}{P(x_i)P(x_j)}\right) \quad \ldots(4)$$

$$\mathrm{P}(\mathrm{x_i}) = \frac{NS(x_i)}{|NS|} \quad \ldots(5)$$

$$\mathrm{P}(\mathrm{x_i}, \mathrm{x_j}) = \frac{NS(x_i, x_j)}{|NS|} \quad \ldots(6)$$

$$\mathrm{EMD}(\mathrm{P}, \mathrm{Q}) = \min \sum_{i=1}^{m} \sum_{j=1}^{n} f_{ij} d_{ij} \quad \ldots(7)$$

NCombi は各クラスタ間の組み合わせである.

$$\mathrm{NCombi} = NC \times \frac{(NC-1)}{2} \quad \ldots(8)$$

$$\mathrm{S_1} = \frac{1}{NC} \sum_{c=1}^{NC} Coherence\,(\mathrm{c_i}) \quad \ldots(9)$$

$$\mathrm{S_2} = \frac{1}{NCombi} \sum_{i<j}^{NCombi} EMD(C_i, C_j) \quad \ldots(10)$$

$$\mathrm{S} = \mathrm{S_1} \times \sqrt{S_2} \quad \ldots(11)$$

5. 実験

本研究で提案した指標について, 様々なデータセットを用いて従来手法等の比較評価を行う. また, 得られた結果に対して考察を行う.

5.1 評価

実験での評価を行うベンチマークデータセットとして UCI Datasets Repository[Dua 17] , NIPS2003[NIPS 03] , WCCI2006[WCCI 06]から合わせて 12 個のデータセットを使用する. 表 1 には, データ名・特徴数・クラス数・データ数を表記する.

比較評価として, フィルター法から既存のアルゴリズムをいくつか用いる. 各データセットに対して, 特徴数を 10 で除算し, 評価の高い順にソートした特徴の添字に対して上位 10 分の 1 から 10 分の 9 までそれぞれを評価する.

実験における最終評価は LinearSVM で 10 fold cross validation を行った分類精度の平均を用いる.

実験において, 全ての検証を同じ環境で行い, 使用したアルゴリズム全てのタイムアウト時間を 48 時間とした.

表 1. データセット詳細

データ名	特徴数	クラス数	データ数
WINE	13	3	178
CANCER	30	2	569
ADA	48	2	Tr : 4147 Te : 415
SONAR	60	2	208
GAS	128	6	Tr : 6955 Te : 6955
SYLVA	216	2	Tr : 13086 Te : 1308
MADELON	500	2	Tr : 2000 Te : 600
GINA	970	2	Tr : 3153 Te : 315
HIVA	1617	2	Tr : 3845 Te : 384
ARCENE	10000	2	Tr : 100 Te : 100
DEXTER	20000	2	Tr : 300 Te : 300
DOROTHEA	100000	2	Tr : 800 Te : 350

5.2 手法

提案手法の各パラメータについては, ビンを 100, 分解するクラスタ数はデータのクラス数とし, 各クラスタの重要度上位 5 個を抽出とした. 探索手法として用いた進化計算のパラメータは, 表 2 に表記する.

従来手法として, フィルター法でよく用いられている Minimum redundancy maximum relevance(mRMR) [Peng 05][Brown 12]と Correlation Feature Selection(CFS) [Mark 99], 2 つのアルゴリズムを比較として用いる.

表 2. 進化計算パラメータ

アルゴリズム	群数	反復数	パラメータ
BGA	20	300	二点交叉 ランク法 mutation=0.05
BPSO	20	300	w=0.5 c=1.0

5.3 結果

比較として, 全ての特徴を使用して評価した結果を表 3 に表記する. 各データセットにおけるフィルター法の評価値と特徴数の一部を表 4 に表記する. また, 各データセットに対してフィルター法での精度が最大だった部分を選択された特徴数とともに表 5, 6 に表記する. 斜線は前述にあるタイムアウトを表す.

提案手法の精度と選択された特徴数を表 7, 8 に表記する.

表 3. 全特徴使用時の精度

データ名	精度
WINE	0.885185
CANCER	0.901075
ADA	0.739277
SONAR	0.746031
GAS	0.776851
SYLVA	0.980199
MADELON	0.538333
GINA	0.790791
HIVA	0.937240
ARCENE	0.830000
DEXTER	0.933333
DOROTHEA	0.931429

表 4. Cancer

	mRMR	CFS
使用添字割合	精度	
1/10	0.811891	0.649123
2/10	0.847953	0.901559
3/10	0.896686	0.919103
4/10	0.872320	0.927875
5/10	0.916179	0.922027
6/10	0.867446	0.896686
7/10	0.873294	0.928850
8/10	0.892788	0.905458
9/10	0.882066	0.877193

表 5. mRMR の結果

	精度	使用添字割合	特徴数
WINE	0.854938	9/10	11
CANCER	0.916179	5/10	15
ADA	0.768675	2/10	9
SONAR	0.809524	7/10	42
GAS	0.802181	9/10	115
SYLVA	0.984072	3/10	64
MADELON	0.53	8/10	400
GINA	0.799471	7/10	679
HIVA	0.966146	1/10	161
ARCENE	0.84	7/10	7000
DEXTER			
DOROTHEA			

表 6. CFS の結果

	精度	使用添字割合	特徴数
WINE	0.91358	9/10	11
CANCER	0.92885	7/10	21
ADA	0.781928	2/10	9
SONAR	0.793651	6/10	36
GAS	0.979415	5/10	64
SYLVA	0.981269	5/10	108
MADELON	0.536111	7/10	350
GINA			
HIVA			
ARCENE			
DEXTER			
DOROTHEA			

表 7. 提案指標＋BGA

データ名	精度	特徴数
WINE	0.896667	10.80
CANCER	0.917778	24.60
ADA	0.730040	29.33
SONAR	0.783069	52.33
GAS	0.764411	105.8
SYLVA	0.932263	149.0
MADELON	0.518000	237.5
GINA	0.801746	898.0
HIVA	0.950521	478.0

ARCENE	0.810000	451.0
DEXTER	0.803333	6116.5
DOROTHEA	0.891429	1358.5

表 8.　提案指標＋BPSO

データ名	精度	特徴数
WINE	0.834656	10.43
CANCER	0.903509	19.00
ADA	0.719663	24.40
SONAR	0.730159	40.20
GAS	0.766783	75.33
SYLVA	0.959531	116.67
MADELON	0.517500	260.67
GINA	0.797249	897.67
HIVA	0.937847	855.67
ARCENE	0.822750	492.25
DEXTER	0.908889	9874.0
DOROTHEA	0.881905	2002.33

5.4 考察

実験の結果，全特徴を用いた場合と比較すると，精度の上昇が見られたデータセットもあったが，変化がほとんど見られないデータセットや減少をしているデータセットも確認された．しかし，ほとんどのデータセットは微小な減少に留まっている．さらに，選択された特徴数については，ほとんどのデータセットに対して削減が行われている．

前述の通り，フィルター法は精度がデータセットによって左右されることも多くすべてのデータセットに対して精度を向上させることは難しい．また，進化計算に関しても汎用的な探索を行うため，ヒューリスティクスよりも精度が劣る傾向がある．

大きなデータに対して特徴数の影響をあまり受けることなく計算が可能であることが確認された．

6. おわりに

6.1 まとめ

本研究では，特徴選択のフィルター法に関して，Coherence と EMD を用いて独自の評価指標を提案した．結果として，多くのデータセットに対し良好な精度を獲得できることが確認された．

n を設定しなくてもよいこと，大きなデータセットに対しても作動することからも，本研究は有用であるということがいえる．

6.2 今後の展望

今後は，より多くのデータに適用できる指標にするため，教師無しのデータに対しても特徴選択が行えるように改良を加える．

また，今回は自然言語処理の UCI Coherence を求める過程に則って算出を行う評価指標を提案したが，様々な過程が存在するため，安定した精度，多様なデータへの汎用性の向上などを今後の目標とし，さらなる調整を行う．

参考文献

[Goldberg 89] Goldberg, David.:Genetic Algorithms in Search, Optimization and Machine Learning. Reading, MA: Addison-Wesley Professional, (1989)

[Kennedy 97] Kennedy, J. and Eberhart, R. C.: A discrete binary version of the particle swarm algorithm, Conference on Systems, Man, and Cybernetics, Piscataway. NJ: IEEE Service Center, pp. 4104-4109 (1997)

[Newman 10] David, Newman.;Jey, Han.;Lau, Karl, Grieser.; and imothy Baldwin. "Automatic evaluation of topic coherence". HLT '10 Human Language Technologies: The 2010 Annual Conference of the North American Chapter of the Association for Computational Linguistics Pages 100-108. (2010)

[Rubner 00] Rubner, Y, Tomasi, C, and Guibas, I: "The Earth Mover's Distance as a Metric for Image Retrieval", International Journal of Computer Vision, 14(3), pp.130-137, (2000).

[Dua 17] Dua, D. and Karra Taniskidou, E. (2017). UCI Machine Learning Repository [http://archive.ics.uci.edu/ml]. Irvine, CA: University of California, School of Information and Computer Science.

[WCCI 06] IEEE World Congress on Computational Intelligence 2006: Performance prediction challenge. , http://clopinet.com/isabelle/Projects/modelselect/WCCI06challengeResu.html

[NIPS 03] Neural Information Processing Systems Conference: Feature selection challenge , http://clopinet.com/isabelle/Projects/NIPS2003/ , (NIPS 2003)

[Peng 05] Peng, H. C.; Long, F.; Ding, C. "Feature selection based on mutual information: criteria of max-dependency, max-relevance, and min-redundancy". IEEE Transactions on Pattern Analysis and Machine Intelligence. 27 (8): 1226–1238. (2005).

[Brown 12] Brown, Gavin et al. "Conditional Likelihood Maximisation: A Unifying Framework for Information Theoretic Feature Selection.", In the Journal of Machine Learning Research(JMLR), (2012).

[Mark 99] M. Hall, "Correlation-based Feature Selection for Machine Learning", (1999).

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

変数固定を伴う部分リスタート戦略を導入したCMA-ESを用いたシルエットベースの3次元剛体形状位置合わせ

Three Dimensional Image Registration Using Silhouette-based Objective function and CMA-ES Including Partial Restart with Variable Fixing

重信 拓音 *1 Takuto Shigenobu　牛之濱 宅哉 *1 Takuya Ushinohama　川崎 洋 *2 Hiroshi Kawasaki　小野 智司 *1 Satoshi Ono

*1鹿児島大学大学院 理工学研究科 情報生体システム工学専攻
Department of Information Science and Biomedical Engineering, Graduate School of Science and Engineering, Kagoshima University

*2九州大学大学院システム情報科学研究院 情報知能工学専攻
Department of Advanced Information Technology, Graduate School of Information Science and Electrical Engineering, Kyushu University

A three-dimensional (3D) entire shape reconstruction method, which performs simultaneous 3D registration of multiple depth images obtained from multiple viewpoints, is proposed in this paper. Unlike most other 3D registration methods, the proposed method fully utilizes a silhouette-based objective function taking out-of-view and non-overlapping regions between two models into account as well as depth differences at overlapping areas. With the combination of the above functions and evolutionary computation algorithms, the entire shape reconstruction from small number (two or three) of depth images, which do not involve enough overlapping regions for other 3D registration methods, can be realized. A CMA-ES algorithm with partial restart strategy to speed up the registration process is proposed in thispaper.

1. はじめに

近年，医療やエンタテインメント，文化財保護などの多様な分野において 3 次元形状の計測，表示技術の利用は増加の一途にある．形状取得にはレンジセンサが広く用いられるが，一度に対象の全周を取得できないため，複数視点から計測した形状の位置合わせが必要である．局所的な位置合わせ ICP[Besl 92] がよく知られているが，相対位置関係が完全に未知の状態から位置を合わせる大域的位置合わせは，有効な手法が確立されておらず多くの研究が行われている．

大域的位置合わせの方式はマッチングベースとパラメータベースに大別できる．前者は形状特徴などを利用して位置・姿勢を推定する方式であり，特徴点を対応付けさせる手法 (SACIA)[Rusu 09] や，形状の輪郭線同士をそれぞれ一致させる手法 (M-ICC)[Wang 14] などが提案されている．パラメータベースは形状の位置と姿勢をパラメータとし，進化計算アルゴリズムなどによってパラメータを最適化する方式で，計測環境に対して頑健である．牛之濱らは重複領域のきわめて小さい場合であっても全周復元が可能な手法を提案した [Ushinohama 14]．この方式は，Self-Adaptive Differential Evolution (jDE) [Brest 06] を最適化に使用しているが，安定した位置合わせを行うために個体数を 200 程度必要としており，個体評価の計算回数が多いことが課題である．また，2 形状の位置合わせを行う場合は，対象形状によって，形状同士が過剰に接近してしまう局所解が生じる問題がある．

本論文では，入力形状同士の過剰な接近を避けるように [Ushinohama 14] の目的関数を改良する．また，Covariance Matrix Adaptation Evolution Strategy(CMA-ES)[Hansen 06] を基に変数固定を伴う部分リスタート戦略を追加し，高速で大域的最適解に到達するアルゴリズムを提案する．実験により jDE に比べ高速に最適解に到達することを確認する．

連絡先: 重信拓音，鹿児島大学大学院理工学研究科情報生体システム工学専攻，〒 890-0065 鹿児島市郡元 1-21-40，sc114021@ibe.kagoshima-u.ac.jp

2. 関連研究

剛体形状位置合わせの手法では，大まかな初期位置合わせを手動で行い，その後マッチングした対応点間の距離を最小にすることで正確に位置合わせを行う ICP や Simultaneous ICP が最もよく知られている．しかし，これらの手法は初期位置合わせが十分に正確でない場合には，誤った対応点をマッチングしてしまい位置合わせに失敗する．そのため，様々な方法で初期位置合わせを必要としない大域的位置合わせ手法の開発が試みられている．典型的な方法は 3D 特徴点を用いたマッチングベースの手法である．代表的なアルゴリズムとして，Fast Point Feature Histograms に基づいてキーポイントを抽出し，キーポイント同士を対応付けする Sample Consensus Initial Alignment (SACIA) が挙げられる．この手法は形状特徴を利用して対応点を得る手法であるため，形状間の重複領域が小さい位置合わせ問題には適用できない．近年，距離画像から抽出されるひとつなぎの輪郭線の長さを最大化し，対応する輪郭線間の距離を最小化する M-ICC が提案されている．この手法では，他のマッチングベース手法に比べ少ない重複領域での位置合わせが可能であり，物体の全周復元は最低 4 回の計測で可能である．マッチングベースの問題を解決するために，パラメータベースの手法が提案されている [Santamaría 13]．パラメータベースの手法は初期位置が不要で，ノイズにも頑健であるが，探索空間の大きさと多くの局所的な最適解のために計算コストが大きいという問題がある．

3. 提案手法

3.1 基本的なアイデア

アイデア 1： シルエットベースのコスト関数の改善

[Ushinohama 14] で提案されたコスト関数は，剛体位置合わせが正しく完了したならば，ある 1 つの測定形状 (ソース) のシルエットの外側にその他の形状 (ターゲット) がはみ出すことはないという考えに基づいている．つまり，ソース形状のシルエットの外にあるターゲット形状のシルエットに大きなコストを加算し，シルエットの重複領域

は 2 形状間の距離によって小さなコストを加算する．しかし，ソースの計測視点からターゲットを見たときにターゲットの表面が裏を向く領域がソースに過剰に接近してしまう場合がある．そこで，本研究ではソースとターゲットのシルエット重複領域のピクセルの法線を比較し，法線間の角度が直角以上，すなわち背中合わせになっている場合のコストを無視することで上記の欠点を改善する．この改善により，2，3 回とごく少ない回数の計測から得た形状による全周復元であっても対象形状によらず位置合わせが可能になる．

アイデア 2： 変数固定を伴う部分リスタート戦略

[Ushinohama 14] のコスト関数は多くの局所解をもつ多峰性であり，進化計算アルゴリズムに jDE を採用しているが，大域的な探索に必要な個体数が多く，収束の速度が遅いことから多くの個体評価回数が必要である．全体の処理時間は個体評価数に比例するため，位置合わせを行う形状数が多くなると，指数関数的に処理時間が増大する．このため，本論文では処理時間を短縮するために，高速に収束する CMA-ES を基に一部の変数のみを対象とする部分リスタートを行う処理を追加する．CMA-ES は収束が高速であるが，局所解に陥りやすいため，局所解に陥った際に探索をリスタートする．この時，ある 2 形状間で位置合わせが完了している場合は，この 2 形状に対応する設計変数を固定する．これにより，探索次元の削減によって有望な領域を集中的に探索でき，部分リスタートを繰り返すことで最適解を発見することが可能となる．

3.2 シルエットベースの目的関数

本問題の設計変数は，形状ごとに並進ベクトルと四元数で表される回転ベクトルとして定義される．実際に位置合わせを行う際には，入力形状の内 1 つを位置合わせの基準となる形状として固定するため，目的関数は入力 N 形状ならば $7(N-1)$ 次元の関数である．目的関数は，入力形状の各計測視点からソース形状とターゲット形状を撮影した距離画像の対応によって式 (1)〜式 (4) のように定義される．ここで，S_k は入力 k 番目のソース形状，T_{k_l} は S_k に対する入力 l 番目のターゲット形状を示す．

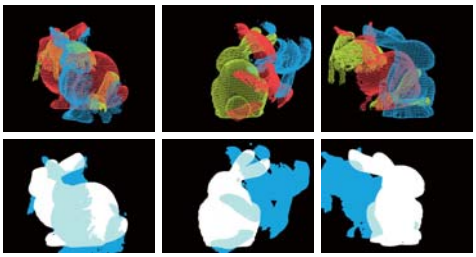
$$F(x) = \frac{1}{N(N-1)} \sum_{k=1}^{N} \sum_{l=1}^{N} f(S_k, T_{k\_l}) \tag{1}$$

$$f(S_k, T_{k\_l}) = \frac{1}{N_{P_{ol}}} \sum_{c=1}^{N_{P_{ol}}} C_{dup} dist_z(s_c, t_c) + \frac{N_{P_{nol}}}{N_{P_{all}}} + C_{out} N_{P_{oov}} \tag{2}$$

$$C_{dup} = \begin{cases} C_1 & (z(t_c) < z(s_c)) \\ C_2 & (\psi(n(t_c), Z_{scan}) < 90^\circ) \\ C_3 & (otherwise) \end{cases} \tag{3}$$

$$dist_z(s_c, t_c) = |(z(s_c) - z(t_c)| \tag{4}$$

s と t はソースとターゲットの距離画像であり，$z(s_c)$ と $z(t_c)$ はそれぞれ s と t におけるピクセル c での深度値である．C_{dup} は重複領域の $z(s_c)$ と $z(t_c)$ の位置関係に対するコストを表す．C_1 はターゲットがソースより手前にある場合のコストである．C_2 はターゲットの法線とソースの法線がなす角が 90° 以上となる場合のコストである．条件式に用いられている $n(t_c)$ はピクセル c の法線ベクトルであり，Z_{scan} はソースの計測視点における z 軸を示すベクトルである．$\psi(n(t_c), Z_{scan})$ は $n(t_c)$ と Z_{scan} の角度差を表す．C_3 はターゲットがソースより奥にある場合のコストである．



(a) View 1 (S_1: red)　(b) View 2 (S_2: green)　(c) View 3 (S_3: blue)

図 1: 位置合わせ状況 (上図) とシルエット画像 (下図)

$N_{P_{ol}}$, $N_{P_{nol}}$, $N_{P_{oov}}$, $N_{P_{all}}$ はそれぞれ s と t のシルエットを比較することで得られる重複領域のピクセル数，非重複領域のピクセル数，そして t の画像外へのはみ出しピクセル数，距離画像全体のピクセル数となっている．そのため，ソースの距離画像からはみ出したターゲットピクセルのコストである C_{out} は，C_{dup} に比べ高い重みに設定する．図 1 に 3 形状の剛体変換後のソース計測視点からの撮影画像と，シルエット画像を示す．シルエット画像は，ソースシルエットのみの領域を白色，ターゲットシルエットのみの領域を青色，シルエットが重複している領域を水色で示している．

3.3 提案手法の詳細アルゴリズム

提案手法は [Hansen 06] を基に設計されている．詳細な処理を以下に示す．後述する式 (6) のように停滞判定が真になってから，次に真になるまでの期間を 1 サイクルと定義する．

STEP 1： 初期化

平均ベクトル $\boldsymbol{m}$, ステップサイズ σ, 共分散行列 C を初期化する, 他に生成する探索個体数 λ, 選択個体数 μ などのパラメータを定める．

STEP 2： 個体生成

個体生成は以下の式に従って生成される．

$$\boldsymbol{x}_k^{(g+1)} \sim \mathcal{N}\left(\boldsymbol{m}^{(g)}, \left(\sigma^{(g)}\right)^2 \boldsymbol{C}^{(g)}\right) \tag{5}$$

$k = 1, ..., \lambda$，ここで $\mathcal{N}(\boldsymbol{m}, C)$ は平均 $\boldsymbol{m}$ および共分散行列 C を有する正規分布に従うランダムなベクトルである．

STEP 3： 評価

3.2 節に示した目的関数に従い，生成した個体を評価する．

STEP 4： パラメータ更新

評価した個体の内上位 μ 個体を用いて，[Hansen 06] に従って平均ベクトル $\boldsymbol{m}$ や C，σ などを更新する．

STEP 5： 探索停滞判定

任意の G 世代ごとに，以下の式 (6) を用いて探索が停滞しているかチェックを行う

$$\frac{F(\boldsymbol{x}_{recent\_best})}{F(\boldsymbol{x}_{recent\_best}^{prev})} \geq T_{local} \tag{6}$$

$F(\boldsymbol{x})$ は目的関数，$\boldsymbol{x}_{recent\_best}$ は現在のサイクルで発見した最良個体，$\boldsymbol{x}_{recent\_best}^{prev}$ は前回停滞チェックを行った

ときの $\boldsymbol{x}_{recent\_best}$ を示す．上記の式を満たした場合には，3.4 節のように部分的な変数の固定とリスタートを行う．

3.4 部分的な変数の固定とリスタート

STEP 1： 基準形状との部分評価

基準形状とその他すべての形状の間で部分的に評価を行う．このときに得られる 2 形状間の部分評価値をペア評価値と呼ぶ．集団全体における最良のペア評価値を組み合わせた剛体変換パラメータを $P_i(i = 2,..., N)$ とする．

STEP 2： 形状固定

最も悪い形状に対する比が，任意の閾値 T_{fix} よりも小さい形状があれば，以降の処理においてその形状の変数の値を固定する．

$$\frac{f(\boldsymbol{x}_i)}{f_{worst}(\boldsymbol{x})} < T_{fix} \quad (i = 2,..., N) \tag{7}$$

STEP 3： 固定解除処理

式 (7) によって十分に位置合わせを行えていない形状を固定してしまう場合がある．そこで $T_{release}$ サイクルの間の探索によって，最良個体が更新されない場合に固定形状を 1 つ解放する．解放された形状は，すべての固定形状が解放される，または新たに形状が固定されるまで再度固定されることはない．

STEP 4： 探索分布再設定

3.2 節で示した目的関数は，シルエットに収まらない箇所に大きなコストを課すため，探索が停滞した時点では平行移動パラメータは正解に近い位置にある．そのため，探索の中心となる $\boldsymbol{m}$ は変更せず，平行移動分布の範囲を初期値の半分程度とし，回転分布の範囲を初期化する．提案手法では 2 形状の位置合わせの際には固定が行われないため，停滞時処理は探索分布の再設定のみとなる．

3.5 最良解付近での局所的探索

1 形状を除いてすべて固定されている際に，残る 1 形状が基準形状に十分値が近づいたために式 (7) を満たす形状がなくなり，すべての形状の固定が解除される場合がある．この場合，すべての形状は基準形状との位置合わせがほぼ完了している．よって，S_{local} サイクルの間すべての平均ベクトルの初期値を P_i として，すべての探索分布の範囲を初期値の $\frac{1}{10}$ 程度に設定して局所的探索を行う．この操作により，微小な位置ずれを高速に調整することが可能となる．

4. 評価実験

評価実験として，第一に形状間の重複領域を変更した場合の 2 形状位置合わせを従来の位置合わせ手法と比較した．第二に提案アルゴリズムと，[Ushinohama 14] で使用された jDE，さらに代表的なリスタート戦略 CMA-ES の IPOP-CMA-ES を比較した．第三に実際にレンジセンサによって計測されたモデルの位置合わせ結果を示す．提案手法のパラメータは $\lambda = 8$，$\mu = 4$，$T_{fix} = 0.3$，$T_{local} = 0.99$，$T_{release} = 3$，$G = 30$，$S_{local} = 3$ とした．実験で用いた仮想物体を図 2 に示す．

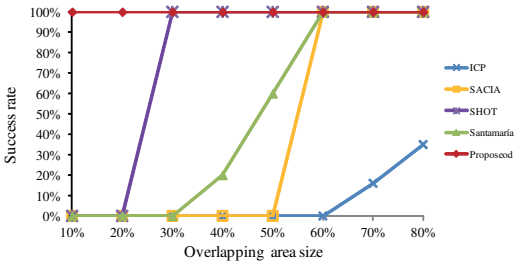
4.1 実験 1：従来の位置合わせ手法との比較

形状間の重複領域を変えて，従来の位置合わせ手法と 2 形状位置合わせを比較する．比較対象として，SACIA，SHOT[Tomvari10]，ICP，Santamaría が提案した手法 [Santamaría 13] を選択した．実験は V_2 と V_3 を使用し，重複領域は 10%～80%まで 10 %ずつ変更した．試行回数は提案手法を 20 試行，従来手法は 100 試行行った．実験結果を図 3 に示す．実験結果より，提案手法のみが小さな重複領域での位置合わせが可能であることがわかる．

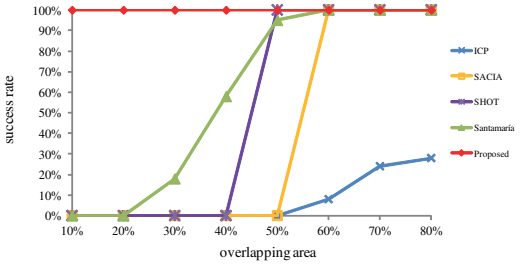


(a) V_1　(b) V_2　(c) V_3

図 2: 実験に用いた仮想物体



(a) V_2



(b) V_3

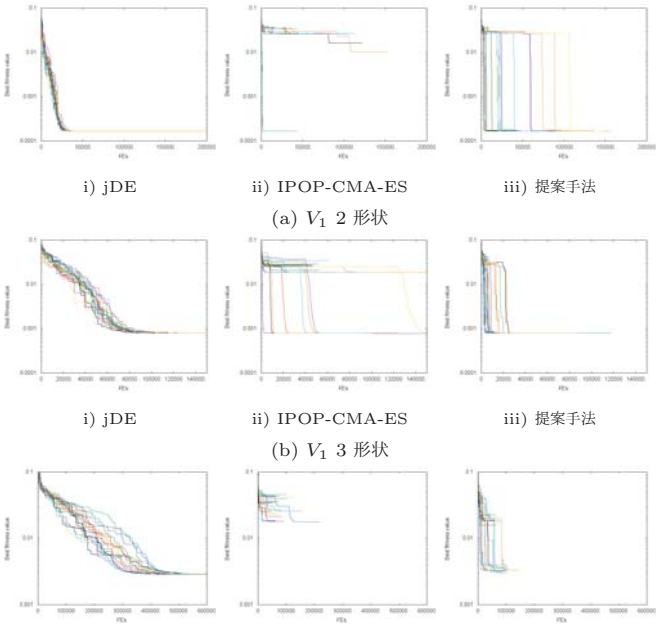
図 3: 重複領域によるの成功率の変化

4.2 実験 2：アルゴリズム速度比較

提案手法の性能を明らかにするために，jDE，IPOP-CMA-ES と比較した．入力形状として N 形状の位置合わせを行う場合には $\frac{360°}{N}$ ずつ角度を変えて計測した形状を与えた．jDE の個体数を 200，IPOP-CMA-ES は $\lambda = 10$，$\mu = 5$ とし，$\left(10 + \lceil \frac{30 \times 7(N-1)}{\lambda} \rceil\right)$ 世代の間評価値の更新がない場合にリスタートとした．位置合わせの成功率を図 4 に，評価値の推移を図 5 に示す．図 5 の横軸はコスト関数の評価回数 (FE)，縦軸は得られた最良の評価値を示す．

図 4 から，jDE が最も高い成功率を示し，提案手法は jDE に多少劣るがほぼ同程度の成功率を示した．V_1 と V_3 において IPOP-CMA-ES は提案手法と比べると成功率が低く，部分リスタート戦略の有効性を示している．入力形状数に焦点を当てると，3 形状では jDE と提案手法は全試行，全仮想モデルで位置合わせに成功している．2 形状では，V_1 と V_2 では位置合わせが成功しているが，重複領域が非常に少ない V_3 では jDE のみが低い成功率ではあるが成功している．すなわち，多峰性関数の探索能力は jDE が優れている．

図 5 は，提案手法と jDE の収束の速さと収束性の違いをよく示している．V_2 および V_3 においても V_1 と同様の傾向がみられた．提案手法を jDE と比べると，FE が $\frac{1}{7}$～$\frac{1}{18}$ 程度の回



i) jDE　ii) IPOP-CMA-ES　iii) 提案手法

(a) V_1 2 形状

i) jDE　ii) IPOP-CMA-ES　iii) 提案手法

(b) V_1 3 形状

i) jDE　ii) IPOP-CMA-ES　iii) 提案手法

(c) V_1 4 形状

図 5: 位置合わせ終了までの評価値推移

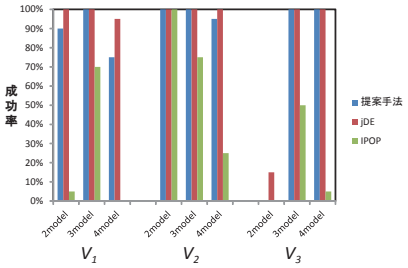


図 4: 位置合わせ成功率

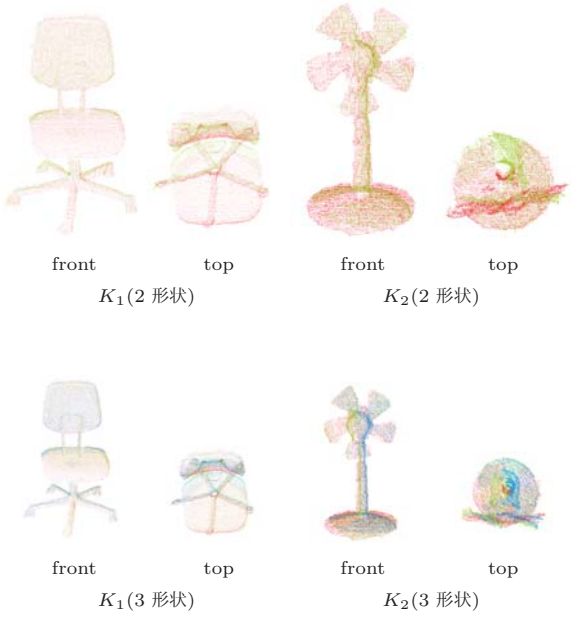
数で位置合わせが完了している．これは，提案手法が探索空間の有望な領域に達すると急激に収束することに対し，jDE は常に一定の速度で収束するためである．

4.3　実験 3：実計測形状の位置合わせ例

Microsoft Kinect で計測した実形状データ K_1 と K_2 を対象とし，提案手法を用いて位置合わせの実験を行った．各実形状データは入力形状数 N の場合 $\frac{360}{N}°$ ずつ角度を変えて計測した形状を与えた．図 6 に示す結果から，提案手法は重複領域が小さく，また，形状にノイズを含む場合であっても位置合わせが可能であることを確認した．

5.　結論

本論文では，少数の計測から 3 次元形状の全周を復元することが可能な剛体位置合わせ手法を提案した．この手法は，シルエットに基づく目的関数と進化計算アルゴリズムの組合せによって実現される．実験結果から，提案手法は 180° の角度差で 2 回計測することで 3 次元形状の全周を復元できることを示した．さらに，関数評価の回数を先行研究の $\frac{1}{7}$〜$\frac{1}{18}$ まで削減した．今後，制御パラメータを削減し，自己適応メカニズムを導入する．



front　top　front　top

K_1(2 形状)　K_2(2 形状)

front　top　front　top

K_1(3 形状)　K_2(3 形状)

図 6: Microsft Kinect で計測した形状の位置合わせ結果.

参考文献

[Besl 92] P.J.Besl., and N.D.McKay. ”Method for registration of 3-D shapes.” Sensor Fusion IV: Control Paradigms and Data Structures. Vol. 1611. 1992.

[Rusu 09] R.R.Bogdan, N.Blodow, and M.Beetz. ”Fast point feature histograms (FPFH) for 3D registration.” Robotics and Automation, 2009. IEEE Int’l Conf 2009.

[Wang 14] R.Wang, J.Choi, and G.Medioni. ”3D modeling from wide baseline range scans using contour coherence.” IEEE Conf Computer Vision and Pattern Recognition. 2014.

[Ushinohama 14] T.Ushinohama, et al. ”Simultaneous Entire Shape Registration of Multiple Depth Images Using Depth Difference and Shape Silhouette.” Asian Conf Computer Vision. 2014.

[Brest 06] J.Brest, et al. ”Self-adapting control parameters in differential evolution: A comparative study on numerical benchmark problems.” IEEE Trans evolutionary computation 10.6 (2006): 646-657.

[Santamaría 13] J.Santamaría, et al. ”Self-adaptive evolution toward new parameter free image registration methods.” IEEE Trans Evolutionary Computation 17.4 (2013): 545-557.

[Hansen 06] N.Hansen.”The CMA evolution strategy: a comparing review.” Towards a new evolutionary computation. Springer Berlin Heidelberg, 2006. 75-102.

[Tomvari10] F.Tombari, S.Salti, and L.D.Stefano. ”Unique signatures of histograms for local surface description.” European Conf computer vision. 2010.

細胞分化アルゴリズムを適用したニューラルネットワークに関する考察

A Study on Neural Network with Cell Differentiation Algorithm

吉信　真之

Masayuki　YOSHINOBU

This paper discusses about the characteristics of the Neural Network with Cell Differentiation Algorithm by assuming a simplified model as a virtual software and examines its characteristics. Several conditions were found for making them larger and possible to acquire various recognition abilities.

1. はじめに

細胞分化アルゴリズムを適用したニューラルネットワーク[吉信 10]は、遺伝的アルゴリズム（以下ＧＡ）でニューラルネットワーク（以下ＮＮ）のハイパーパラメータを改善する方法として、細胞の分化・発生の仕組みを応用し、異なる特徴を持つ個体を交配して新しい特徴を持つ個体生成を可能にする手法である。本稿では実装による評価の前段階として、本手法の特徴・課題について簡易的に検討した。

2. 細胞分化アルゴリズムを適用したニューラルネットワークについて

細胞分化アルゴリズムを適用したＮＮは発生の仕組みを利用したもので、ＧＡを用いてＮＮの構成の最適化を測る手法である。発生モデルを用いることで、通常のＮＮでは困難であった規模の大きなＮＮにＧＡを用いることを可能にすることなど、いくつかの利点を有する。詳細については参考文献[吉信 10]に譲る。

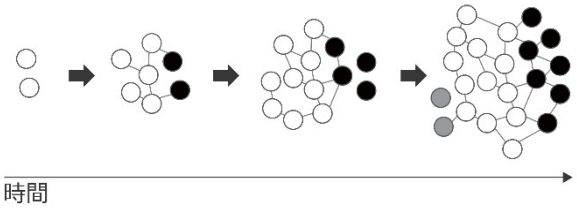


図 1:「細胞分化アルゴリズムを適用したニューラルネットワーク」のイメージ　幹細胞から発生しNNを自己組織化する

3. ニューラルネットワークの課題

ＮＮは通常、学習を始めるに当たって発火閾値の初期値をランダムな値にするなどのプロセスが行われ、その都度初期状態から学習を始める必要がある。また、ＮＮではＧＡを用いる場合に以下のような課題がある。遺伝子としてそのまま表現型を用いる直接エンコーディングの場合は、計算可能な組み合わせ数となる規模に抑える必要がある。仮に部分をいくつかのニューロンによるモジュール化をしたとしても、より規模が大きくなれば同じ問題が生じる。さらに、追加的な学習が困難であることや、構成の改良や規模の拡大を図る場合についても、再設計、再学習の工程が必要となるとともに、学習成果の再利用が困難なことが挙げられる。

実際の生物においては、受精卵となる時点において遺伝子の交叉が行われ、発生のプロセスを経ることによりこのような問題は生じていない。細胞分化アルゴリズムを適用したＮＮではこの発生の仕組みをＮＮに導入して従来のＮＮが有する課題を解決し、構成の制御を容易にするものである。

4. モデルによる検討

簡易的なモデルを仮想的なソフトウェアとして想定し課題を検討した。検討を簡単にするため小規模な構成の二次元のリカレントニューラルネットワークとした[図 2]。

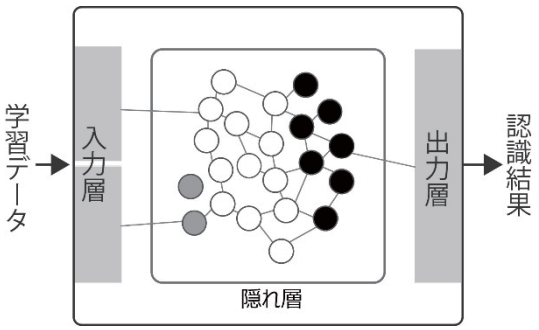


図 2:モデルイメージ

簡易的な検討のため2入力1出力としている

ノードの分裂や分化に必要な条件は参考文献[金子 03]に倣うものとした。

遺伝子は各ノードに１つずつ配置するものとし、反応する仮想分子、仮想触媒（酵素）の番号、および反応レートを持たせることとする（図３）。

連絡先:吉信真之，m.yoshinobu89vn[at]gmail.com

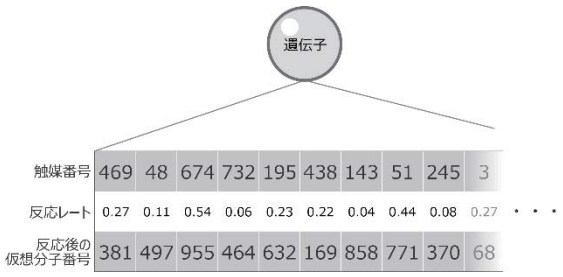


図 3:遺伝子データのイメージ
遺伝子は各ノードに1つずつ配置し、反応する仮想触媒、反応レート、反応後の仮想分子番号を遺伝子データとする

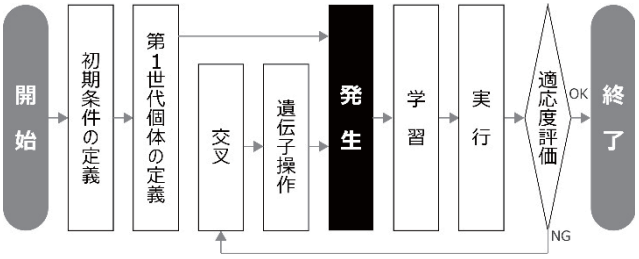


図 4:動作フロー。発生プロセスを導入(黒地部)。

5. 結果

想定したモデルにて生成プロセスを検討し、以下の点が挙げられた。

(1) 十分な計算リソースが必要
・ノード内成分同士の反応処理、成分の発火閾値等へのパラメータ調整動作、軸索の伸長・接続処理等の計算に十分な計算リソースが必要

(2) 仮想栄養分子の供給量が一定の場合、ノードが増加するにつれてノードの分裂速度が抑制される

(3) 初期条件によっては分化が適切に進まない
・遺伝子長、仮想分子がノードのパラメータへ調整を与える方法が適切でない

(4) 過学習となる場合
・特定の学習に最適化してしまう

(5) 分化・形態形成が進行しない場合

(6) 信号伝達異常となる場合

6. 考察

前述の検討結果を踏まえ対策を検討した。

(1) **計算リソース**
・計算手法の見直し
・将来的な計算機の能力向上
・計算リソースの多寡を淘汰圧に用いる
・進化の方向や速度を調整することで全体としての計算量の削減すること[Turing 1950]

(2) **分裂速度の抑制**
・発達段階に合わせた仮想栄養分子の供給。課題正答への報酬として栄養を供給

(3) **分化不良**
・作成初期段階では学習成果による適応度の評価の前に適正な動作を行うことを適応度とした評価を行う

(4) **過学習**
・発達段階に応じた計画的な学習プロセスの整備[Turing 1950]

(5) **分化・形態形成の不足**
・生物の形態形成、再生医療などの知見の利用
・他のディープラーニングや知識データベース等とのハイブリッドな構成

(6) **信号伝達異常**
・ノードの状態の追跡
・遺伝子データのノックアウトによる振る舞いの観察

7. 結論

本稿では簡易的な検証であるため前述の結果にとどまるが、これを踏まえ具体的なモデル化を行うと共に、部分的な計算機上で動作するモデルによる検証を行うことにより、さらに大規模、多様な認識に対応するネットワークの構成の生成に向けた知見が得られると考えられる。

参考文献

[吉信 10] 吉信真之: 細胞分化アルゴリズムを適用したニューラルネットワーク, 人工知能学会全国大会, 2010.
[金子 03] 金子邦彦: 生命とは何か, 東京大学出版会, 2003
[Turing 1950] Alan Turing: Intelligent Machinery of Computing, 1950.

[3E1] [General Session] 13. AI Application

座長:桂樹 哲雄（豊橋技術科学大学）

Thu. Jun 7, 2018 1:50 PM - 3:10 PM Room E (4F Queen)

[3E1-01] Predicting the protein stability changes upon single-point mutation using BPE Sequence to Sequence

○Keisuke Kawano[1], Satoshi Koide[1], Imamura Chie[1] （1. TOYOTA CENTRAL R&D LABS., INC）

1:50 PM - 2:10 PM

[3E1-02] Material discovery by AI

○Seiji Takeda[1], Hsiang Han Hsu[1], Toshiyuki Hama[1], Toshiyuki Yamane[1], Koji Masuda[1], Daiju Nakano[1] （1. IBM Research - Tokyo）

2:10 PM - 2:30 PM

[3E1-03] Automatic Tracking of Honeybee Dancer’ and Follower’ Walking Trajectories

○Shinya Takahashi[1], Sakashi Maeda[1], Koji Hashimoto[1], Naoyuki Tsuruta[1], Hiroyuki Ai[1] （1. Fukuok University）

2:30 PM - 2:50 PM

[3E1-04] Molecular Hypergraph Grammar

○Hiroshi Kajino[1] （1. IBM Research）

2:50 PM - 3:10 PM

©The Japanese Society for Artificial Intelligence

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

BPE Sequence to Sequence を利用した単変異によるタンパク質耐熱性変化予測

Predicting the protein stability changes upon single-point mutation using BPE Sequence to Sequence

河野 圭祐　小出 智士　今村 千絵
Keisuke Kawano　Satoshi Koide　Chie Imamura

(株) 豊田中央研究所
Toyota Central R&D Labs. Inc.

We consider the problem of predicting the improvement of protein stability by a single mutation. Unlike the existing prediction methods based on supervised learning with a small labeled dataset, we propose a new approach that first learns a latent representation for each protein in a massive, unlabeled protein databank (UniRef90), and then constructs a prediction model based on the learned representation. To obtain the latent representation of a protein, we employ *Byte-Pair encoding sequence to sequence* (BPE-Seq2Seq). The experimental results show that our method can more accurately predict than the existing methods.

1. はじめに

タンパク質の中には工業的にも有用なものがあるが，熱に弱く耐久性が低いものが多いという課題がある．タンパク質の耐熱性を向上させる方法の 1 つとして，タンパク質のアミノ酸配列の一部を別のアミノ酸へと置換する方法 (変異) がある．しかし，数百程度の長さの配列の中の 1 つのアミノ酸を別の 19 種類のアミノ酸に変異させる，という単純な変異の導入でさえ，可能な組み合わせは膨大であり，かつ，実際に耐熱性が向上する変異はごく一部である．多大な実験工数などのコストを避けるために，これまで行われた他のタンパク質に対する変異の結果などから，まだ実験されていない新規のタンパク質 (未知のタンパク質) における変異と耐熱性の関係について予測することが必要である．

変異によるタンパク質耐熱性変化予測 (以下では耐熱性変化予測) では，fold 時と unfold 時の自由エネルギーの差 (ΔG) が変異の前後でどのように変化したか ($\Delta\Delta G$) を予測する．一般に予測のための入力として，対象とするタンパク質のアミノ酸配列とその 3 次元構造，変異させた位置と変異後のアミノ酸，および，実験時の環境 (温度と pH) が与えられる．

これまで，機械学習による耐熱性変化予測手法がいくつか開発されている [Capriotti 05, Pires 14, Quan 16, Fariselli 15, Cang 17]．[Capriotti 05] は，タンパク質の構造やアミノ酸配列から，変異近傍にある他のアミノ酸の数を表す特徴量を作成し，Support Vector Machine による予測を行った．さらに，[Pires 14] は変異近傍の原子を表す特徴量によって，より精度の高い予測を行った．[Fariselli 15] は進化的な情報として，類似するアミノ酸配列中の，変異を導入した位置と同じ位置におけるアミノ酸の頻度を特徴量とした．[Quan 16] はタンパク質の 3 次元構造を得られないときに，アミノ酸配列から 3D 構造を推定し，構造に関する特徴量を作成する方法を提案した．[Cang 17] は幾何学的な情報を畳み込みニューラルネットワークで学習させ，耐熱性変化予測を含む複数のタスクで精度の良い予測を行った．また，[Capriotti 08] は耐熱性変化データの可逆性に着目し，逆向きに変異したときのデータを学習データに加えることで予測精度を向上させた．逆向きに変異したときのデータとは，例えば A というタンパク質を B に変異させた結果，Δ だけ耐熱性が変化したというデータがあるとき，B から A に変異すると $-\Delta$ だけ耐熱性が変化するというデータのことである．

多くの既存手法では予測モデルの性能評価のために，データセットを学習データと検証データにランダムに分割する交差検証 (変異レベルの交差検証) を行っている．しかし，データセットには同じタンパク質に関するデータが複数含まれているため，この評価方法では学習データに含まれていないタンパク質に対する性能を，適切に評価することはできない．そこで，同じタンパク質を 1 つのグループとしてデータセットを分割し，交差検証する方法 (タンパク質レベルの交差検証) が提案されている [Pires 14]．しかしながら，学習データに含まれない未知のタンパク質に対する予測は，より困難であることが報告されている [Pires 14, Quan 16, Fariselli 15]．本研究では，未知のタンパク質に対しても適用可能な，つまりタンパク質レベルの交差検証での予測精度が高い耐熱性変化予測モデルの開発を目的とする．

耐熱性変化予測の難しさの 1 つにデータ数の不足がある．予測で用いることができる実験データとして，変異による耐熱性変化に関する最大のデータベース ProTherm [Bava 04] があるが，そこに含まれる単変異のデータは数千程度であり，さらにユニークなタンパク質は数百程度と少量である．一方で，ラベルなしデータは豊富にあり，例えば UniRef90 [Consortium 10] に登録されている，タンパク質のアミノ酸配列のデータは約 7 千万ある．このようなラベルなしデータを上手く利用することは耐熱性変化予測において重要であり，実際に多くの耐熱性変化予測モデルで利用されている特徴量 Position-Specific Scoring Matrix (PSSM)[Kumar 09] は，大量の配列データから対象のタンパク質の配列と類似する配列を検索し，それらの配列の中で変異させる位置のアミノ酸の頻度を求めるものである．PSSM は有効な特徴量であるが，類似配列間のアミノ酸の頻度情報のみを表すものであり，改良の余地がある．

本研究では，学習データに含まれない未知のタンパク質に対しても適用可能な耐熱性変化予測のために，新規特徴量を提案する．本研究の貢献は以下である．(1) 大量のタンパク質アミノ酸配列データを用いて，アミノ酸配列全体に関する情報を十分に含む特徴量を提案した．(2) 提案法をタンパク質レベルの交差検証を用いて評価し，提案法によって既存手法よりも高い精度で耐熱性変化を予測できることを示した．

連絡先: 河野圭祐，kawano@mosk.tytlabs.co.jp
愛知県長久手市横道 41 番地の 1　豊田中央研究所

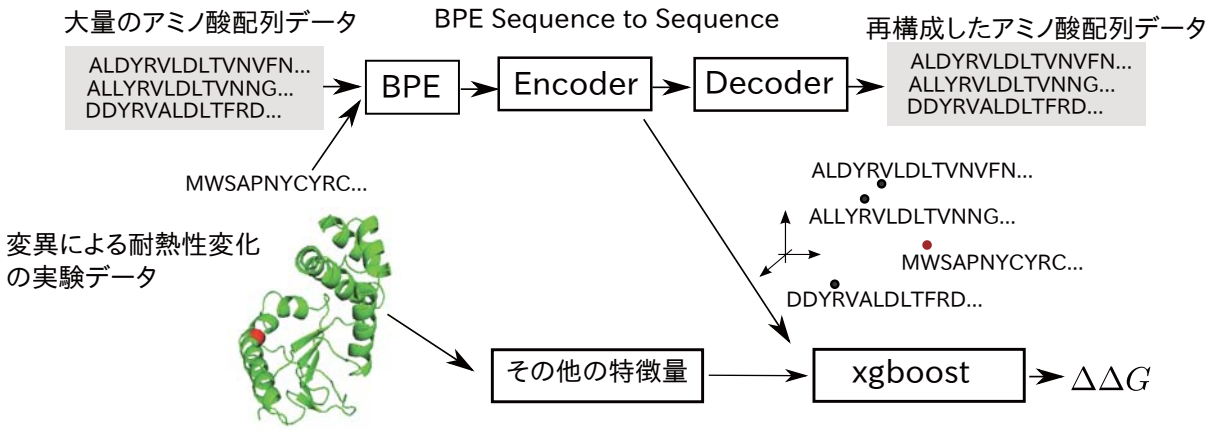


図 1: 提案法の概要図．提案法では耐熱性変化の実験データの他に大量のアミノ酸配列のデータを用いる．大量のアミノ酸配列のデータによって BPE Seq2Seq モデルを学習し，得られた encoder を特徴量抽出器として用いる．学習後の encoder によって，可変長の離散系列であるアミノ酸配列を，固定長の連続値ベクトルへと変換することができる．この特徴量と既存の特徴量とを組み合わせて，xgboost によって耐熱性変化を学習，予測する．

2. 手法

提案法の概要図を図 1 に示す．提案法では始めに，大量のタンパク質アミノ酸配列を，Seq2Seq モデルの一種である BPE Seq2Seq モデルによって学習する．その後，学習後の encoder を特徴量抽出器とし，既存の他の特徴量抽出器と組み合わせて，耐熱性変化の実験データから特徴量を作成する．勾配ブースティング決定木の一種である xgboost [Chen 16] を用いて作成した特徴量から耐熱性変化を予測する．以下では提案する BPE Seq2Seq によるアミノ酸配列の学習，および，用いた既存の特徴量について説明する．

2.1 BPE Seq2Seq を利用した特徴量生成

化合物の物性値予測において，[Xu 17] は化合物の構造を表す大量の SMILES と呼ばれる配列を Sequence to Sequence (Seq2Seq)[Sutskever 14] によって学習させ，それによって得られた encoder を特徴量抽出器として用いる手法を提案した．Seq2Seq では入力した配列を encoder によって一旦，固定長のベクトルへと変換した後，decoder によって同じ配列を再構成することを学習する．このため，学習後に得られる encoder によって，可変長の離散系列である配列データを，配列を再構成するために十分な情報を持った固定長の連続値ベクトルへと変換することができる．本研究では同様に，大量のタンパク質アミノ酸配列データを Seq2Seq によって学習させ，学習後の encoder を特徴量抽出器として用いる．しかし，事前評価の結果，文における単語列や SMILES と比較して，タンパク質アミノ酸配列は配列が長いため，Seq2Seq で学習することは難しいことがわかった．そこで，本研究では自然言語処理において未知語の学習 [Sennrich 15] などに用いられる Byte Pair Encoding (BPE) Seq2Seq モデルによってアミノ酸配列を学習する方法を提案する．BPE は与えられたデータの中から，出現頻度の高い bi-gram を順に別の 1 つの文字に置換していく方法であり，BPE Seq2Seq では BPE で圧縮後の配列を用いて Seq2Seq モデルを教師なし学習する．

2.2 その他の特徴量

本研究では，BPE Seq2Seq の encoder から得られる特徴量の他に，表 3 に示す特徴量を入力として用いる．これらの特徴量は大きくわけて 5 種類に分けられる．(1) 実験条件．変異による耐熱性変化を計測した際の温度と pH といった実験時の環境を表す．(2) 変異前後のアミノ酸の性質変化．例えばアミノ酸の側鎖の大きさが大きくなったなどの情報が含まれる．(3) 球殻状の特徴量．変異近傍のアミノ酸の環境を表すための特徴量である．変異位置から 7.5Å 以内を 1.25Å ごとの球殻状の範囲に分割し，範囲内に含まれるアミノ酸の性質を合計したものを特徴量とするものである．(4) Mutation Energy．分子動力学シュミレータの機能をもつ Discovery Studio [Dassault Systémes BIOVIA 17] を利用して，変異前後のエネルギーを求めたものである．(5) Position-Specific Scoring Matrix (PSSM)．大量のアミノ酸配列データから類似する配列を検索し，それらの配列の中で，変異させる位置のアミノ酸の頻度を特徴量とするものである．本研究では PSI-BLAST [Altschul 98] を Uniref90 に対して適用し，類似する配列を検索した．

また，本研究では [Capriotti 08] と同様に，逆向きに変異したときのデータを学習データに加えることでデータを増強した．本研究ではこの操作を Reverse Augmentation (RevAug) と呼ぶ．

3. 実験

本章では始めに，大量のアミノ酸配列データを Seq2Seq モデルで学習する際の，BPE による圧縮の有用性について，実際に圧縮前後の配列を Seq2Seq モデルに学習させ，再構成結果を比較することで検証する．その後，本研究の目的である，変異によるタンパク質耐熱性変化予測を，学習後の encoder による特徴量を用いて行う．既存のデータセットを用いて，提案法の性能を既存手法の性能と比較する．

3.1 Seq2Seq と BPE Seq2Seq のアミノ酸配列の再構成誤差比較

本研究では Uniref90[Consortium 10] に登録されているタンパク質アミノ酸配列のうち，計算コストの制約から，配列の長さが 300 以下のもの (約 3000 万配列) からランダムにサンプリングした約 600 万配列を学習データとして，Seq2Seq モデルによる教師なし学習を行う．用いた Seq2Seq モデルおよび学習法の詳細を表 1 に示す．この Seq2Seq モデルにアミノ酸配列を入力 (以後このモデルを Seq2Seq)，または，BPE で圧縮した後のアミノ酸配列を入力 (BPE Seq2Seq) し，encoder による符号化と decoder による再構成を学習する．学習後のモデルにテスト用のアミノ酸配列 (約 6 万配列) を入力し，再構成誤差を評価し，比較する．それぞれのモデルについて，初期値を変更して 7 回ずつ学習を行い，再構成誤差の中央値を比較した．条件を揃えるために，BPE Seq2Seq で再構成された配列 (BPE によって圧縮された状態) は，BPE で獲得され

表 1: Seq2Seq モデルの詳細

パラメータ名	値
リカレントセル	bi-directional GRU
encoder の隠れ層数 (ノード数)	1 (128)
decoder の隠れ層数 (ノード数)	1 (256)
Attention	あり
誤差関数	パープレキシティ
エポック数	2
最適化手法	Adam
勾配のクリッピング	絶対値 5 以上をクリップ
学習率 (固定)	0.001

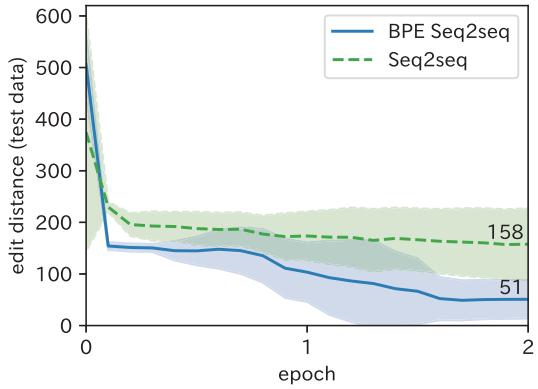


図 2: 編集距離による再構成誤差の比較

る置換ルールを用いて，再構成された配列をデコードした上で再構成誤差を編集距離によって評価した．また，事前の検討から，ルール数を増やしても配列長がほとんど変化しなくなる語彙数 (2000) を，BPE によって増加させる語彙数として設定した．

学習途中のテストデータに対する編集距離の推移を図 2 に示す．図中実線 (青色) は BPE Seq2Seq，破線 (緑色) は Seq2Seq の再構成誤差の平均値を表す．また，それぞれの薄い色の領域は標準偏差を表している．編集距離の平均値は BPE Seq2Seq で 51，Seq2Seq で 158 であった．実際にテスト配列を再構成した例を表 2 に示す．表では再構成された配列の末尾のみを示し，また，わかりやすさのため，出力された配列を部分的に揃えて表示している．表において青字は誤って再構成された部分であり，”-”は再構成すべき文字を再構成せずに飛ばした部分を意味する．BPE Seq2Seq と比較して，Seq2Seq では同じ文字を不要に繰り返し再構成する傾向が見られた．これは BPE Seq2Seq と比較して再構成すべき文字数が多いため，再構成が困難であったことが原因と考えられる．以上から，アミノ酸配列を Seq2Seq によって学習する際に，BPE によって事前に配列を圧縮することで，配列をより正確に再構成できることが確認できた．

3.2 変異によるタンパク質耐熱性変化予測

提案する BPE Seq2Seq の encoder を用いた特徴量によって，変異によるタンパク質耐熱性変化予測を行い，既存手法と性能を比較した．BPE Seq2Seq モデルの encoder は 3.1 節の実験により学習したものを用いた．本実験では encoder から出力される固定長ベクトル (128 次元) を主成分分析によって 20 次元に変換したものを特徴量とした．また，[Capriotti 05, Fariselli 15] では RevAug が行われている一方で， [Pires 14, Quan 16, Cang 17] では行われていない．これらの既存手法と比較するために，本研究では RevAug を行った場合と行わなかった場合の予測性能をともに評価する．

既存手法との予測性能の比較を可能とするために，S2648 データセット [Dehouck 09] を用いて提案法を評価する．S2648 は，ProTherm[Bava 04] のデータから 2648 個の単一変異を選んだデータセットであり，131 のタンパク質についてのデータが含まれる．本研究では S2648 データセットを用いて，タンパク質レベルの交差検証と変異レベルの交差検証を行う．交差検証の fold 数は既存手法 [Pires 14, Quan 16] と同様に 5 とした．また，タンパク質レベルの交差検証におけるデータ分割は，既存手法 [Pires 14] と同じ分割を用いた．ただし，S2648 データセットに含まれるタンパク質には，3D 構造が不完全なものも含まれており，Mutation Energy を求める際に利用した Discovery Studio [Dassault Systémes BIOVIA 17] の制約から，2648 個のうち 42 の変異について，特徴量を求めることができなかったため除外して評価した．評価指標として，ピアソン相関係数 (PCC) と Root Mean Squared Error (RMSE) を用いる．

既存手法との比較を表 4 に示す．タンパク質レベルの交差検証において，提案法の PCC は 0.55, RMSE は 1.23 であった．これは既存手法の予測精度を上回るものであり，提案した Seq2Seq の encoder を利用した特徴量と RevAug を組み合わせることで，従来法と同様もしくは高い精度で耐熱性変化を予測できていることが確認できる．一方で，変異レベルの検証では，提案法の PCC は 0.65, RMSE は 1.12 であり，既存手法の予測精度を下回った．特に RevAug はタンパク質レベルでは予測精度を向上させた一方で，変異レベルでは逆に予測精度を低下させた．

RevAug によって，変異レベルの検証での予測精度が悪化した原因として，データセットに含まれるタンパク質ごとの傾向がなくなったことが考えられる．変異によるタンパク質耐熱性変化のデータは主に，文献等で報告されている実験結果を集めて作成されているため，タンパク質によって耐熱性変化結果の

表 2: BPE Seq2Seq と Seq2Seq 再構成結果の比較 (末尾のみ)

	配列
正解	...VTQIVV NLL D NAIKYARDAEDKTI
BPE Seq2Seq	...VTQIVV NLL D NNLLDNAIDNHKT-
Seq2Seq	...VTQIIVVNLLLDDNAAIKIKYKYYAARAARARRDRD...

表 3: Seq2Seq 特徴量以外の特徴量一覧．カッコ内は各特徴量の次元数

カテゴリ	内容
実験条件 (2)	pH 温度
変異前後のアミノ酸の性質変化 (17)	側鎖の大きさの変化 側鎖の角度の変化 水素結合ドナー数の変化 疎水性の変化 親水性の変化 極性の変化 等電点の変化 電荷の変化
球殻状の特徴量 (102)	(変異前後のアミノ酸の性質変化と同じ特徴量) 変異位置から 0.0Å から 7.5Å まで，1.25Å ずつ．
Mutation Energy (1)	Discovery Studio [Dassault Systémes BIOVIA 17] により計算
PSSM (4)	変異前アミノ酸の PSSM のスコア 変異後アミノ酸の PSSM のスコア 変異位置での情報量 変異位置でのギャップの入りやすさ

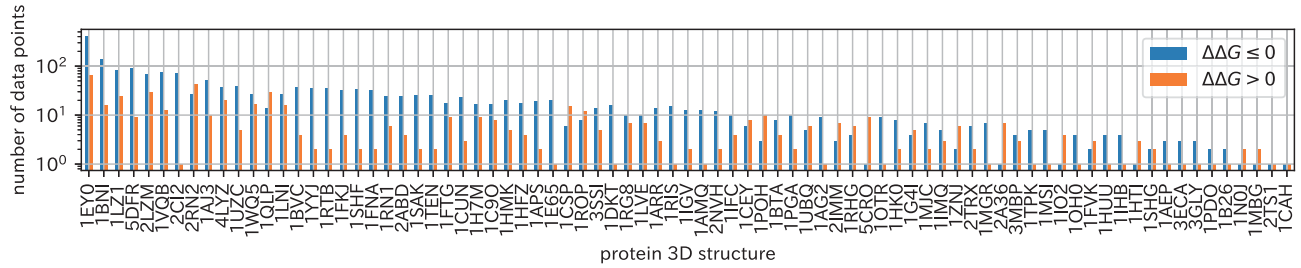


図 3: タンパク質 3D 構造ごとのデータ数

表 4: 交差検証の結果 (RevAug = Reverse Augmentation)

手法	タンパク質レベル		変異レベル	
	PCC	RMSE	PCC	RMSE
提案法 (RevAug)	**0.55**	**1.23**	0.65	1.12
STRUM	0.54	1.25	**0.77**	**0.94**
提案法	0.52	1.26	0.70	1.05
INPS	0.52	1.26	0.56	1.26
mCSM	0.51	1.26	0.69	1.07
TopologyNet	-	-	**0.77**	**0.94**
I-Mutant3.0	-	-	0.60	1.19

分布に大きな偏りがある．図 3 にタンパク質 3D 構造ごとのデータ数を示す．図中，青棒は変異によって耐熱性変化が悪化した (または変化しなかった) データ，オレンジ棒は向上したデータを表す．図より，タンパク質ごとに耐熱性が向上したものと悪化したものの割合に，大きく差があることがわかる．変異レベルの検証では，検証データのタンパク質の傾向を，学習データから事前に知ることができ，予測精度を向上させることができる．しかし，RevAug を行うと，耐熱性が向上したデータと悪化したデータの割合が等しくなるため，タンパク質ごとの傾向を学習データから知ることができなくなる．このため，変異レベルの検証では，RevAug によって精度が悪化したものと考えられる．一方で，タンパク質レベルの検証では，タンパク質ごとにデータが分割されるため，RevAug をしない場合でも，このような傾向を学習することはできない．このため，RevAug によってデータを増強できた分だけ，予測精度が向上したと考えられる．

4. おわりに

変異によるタンパク質の耐熱性変化予測精度向上のために，アミノ酸配列を学習した BPE Seq2Seq の encoder を利用した特徴量作成を提案した．未知のタンパク質に対する予測性能を評価するために，タンパク質ごとにデータを分割する交差検証による評価を行い，提案法が既存手法の予測精度を上回ることを示した．今後の課題として，既存の他の特徴量との組み合わせによる予測精度の向上や，バイアスのある実験データを用いた機械学習予測精度の統計的検定などがある．

参考文献

[Altschul 98] Altschul, S. F. and Koonin, E. V.: Iterated profile searches with PSI-BLAST—a tool for discovery in protein databases, *Trends in biochemical sciences*, Vol. 23, No. 11, pp. 444–447 (1998)

[Bava 04] Bava, K. A., Gromiha, M. M., Uedaira, H., Kitajima, K., and Sarai, A.: ProTherm, version 4.0: thermodynamic database for proteins and mutants, *Nucleic Acids Res.*, Vol. 32, No. Database issue, pp. D120–121 (2004)

[Cang 17] Cang, Z. and Wei, G.: TopologyNet: Topology based deep convolutional and multi-task neural networks for biomolecular property predictions, *PLoS Computational Biology*, Vol. 13, No. 7, p. e1005690 (2017)

[Capriotti 05] Capriotti, E., Fariselli, P., and Casadio, R.: I-Mutant2.0: predicting stability changes upon mutation from the protein sequence or structure, *Nucleic Acids Res.*, Vol. 33, No. Web Server issue, pp. W306–310 (2005)

[Capriotti 08] Capriotti, E., Fariselli, P., Rossi, I., and Casadio, R.: A three-state prediction of single point mutations on protein stability changes, *BMC bioinformatics*, Vol. 9, No. 2, p. S6 (2008)

[Chen 16] Chen, T. and Guestrin, C.: Xgboost: A scalable tree boosting system, in *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, pp. 785–794ACM (2016)

[Consortium 10] Consortium, U., et al.: The universal protein resource (UniProt) in 2010, *Nucleic acids research*, Vol. 38, No. suppl 1, pp. D142–D148 (2010)

[Dassault Systémes BIOVIA 17] Dassault Systémes BIOVIA, : Discovery Studio (2017)

[Dehouck 09] Dehouck, Y., Grosfils, A., Folch, B., Gilis, D., Bogaerts, P., and Rooman, M.: Fast and accurate predictions of protein stability changes upon mutations using statistical potentials and neural networks: PoPMuSiC-2.0, *Bioinformatics*, Vol. 25, No. 19, pp. 2537–2543 (2009)

[Fariselli 15] Fariselli, P., Martelli, P. L., Savojardo, C., and Casadio, R.: INPS: predicting the impact of non-synonymous variations on protein stability from sequence, *Bioinformatics*, Vol. 31, No. 17, pp. 2816–2821 (2015)

[Kumar 09] Kumar, P., Henikoff, S., and Ng, P. C.: Predicting the effects of coding non-synonymous variants on protein function using the SIFT algorithm, *Nature protocols*, Vol. 4, No. 7, p. 1073 (2009)

[Pires 14] Pires, D. E., Ascher, D. B., and Blundell, T. L.: mCSM: predicting the effects of mutations in proteins using graph-based signatures, *Bioinformatics*, Vol. 30, No. 3, pp. 335–342 (2014)

[Quan 16] Quan, L., Lv, Q., and Zhang, Y.: STRUM: structure-based prediction of protein stability changes upon single-point mutation, *Bioinformatics*, Vol. 32, No. 19, pp. 2936–2946 (2016)

[Sennrich 15] Sennrich, R., Haddow, B., and Birch, A.: Neural machine translation of rare words with subword units, *arXiv preprint arXiv:1508.07909* (2015)

[Sutskever 14] Sutskever, I., Vinyals, O., and Le, Q. V.: Sequence to sequence learning with neural networks, in *Advances in neural information processing systems*, pp. 3104–3112 (2014)

[Xu 17] Xu, Z., Wang, S., Zhu, F., and Huang, J.: Seq2seq fingerprint: An unsupervised deep molecular embedding for drug discovery, in *Proceedings of the 8th ACM International Conference on Bioinformatics, Computational Biology, and Health Informatics*, pp. 285–294ACM (2017)

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

AIによる新物質探索手法

Material discovery by AI

武田 征士[*1] Seiji Takeda
Hsiang Han Hsu[*1] Hsiang Han Hsu
濱 利行[*1] Toshiyuki Hama
山根 敏志[*1] Toshiyuki Yamane
益田 幸治[*1] Koji Masuda
中野 大樹[*1] Daiju Nakano

[*1]IBM 東京基礎研究所
IBM Research - Tokyo

Discovering new materials that possess on-demand properties is the central demand in every industrial domain. We constructed the first material discovery system with end-to-end pipeline consisting of several technical pieces; feature encoding, regression, solution search, and structure generation. Those pieces are coordinated to coherently work together by newly defining two kinds of feature vectors; data-driven feature and pre-defined feature, and developing an algorithm to generate molecular structures by using those feature vectors. The capability of the system to discover new small organic molecules is demonstrated by a public dataset of commercial drugs.

1. 序論

あらゆる産業は，新物質の発見によってこそもたらされる非連続な飛躍を繰り返すことで，今日にみる巨大な発展を遂げてきた．航空宇宙産業，自動産業など重工業から，医薬・バイオ産業，ナノテクノロジー産業，情報産業に至るまで，任意の製品性能を実現するためには，その性能の要求する材料物性（たとえば機械的・熱的・電気的特性など）を備えた物質を新規かつ高速に発見・開発し，製品に取り込むことが極めて重要である．

今日の一般的な材料（物質）開発のプロセスは，技術者の知識や直観に基づき，実験やスーパーコンピュータによる物理化学計算を繰り返す伝統的な試行錯誤に依る部分が大きい．しかしながら物質の探索空間は極めて膨大であり，化学構造のトポロジーや用いる原子の種類に強い制約を設けても，10^{60} 種類を優に上回る未知の物質が存在し得るとされている[Bohacek 96]．このため，新材料開発には10年から20年ほどの期間を要するというのが一般的な通念である．加えて，得られる新材料も，各材料分野固有の知見に基づいて開発・デザインされるため，既存材料から大きく離れた構造や特性を備えた物質が得られることは困難であった．

このような人間の知見や発想による制約を離れ，物質デザインの自由度を飛躍的に高め開発速度を向上させるために，近年 AI（機械学習・統計）を活用した物質探索の研究開発が加速している．AI を物質探索に取り込むアプローチは，一般にケモインフォマティクス，あるいはマテリアルズ・インフォマティクスとも呼ばれる．AI による物質探索の目標は，所望の物性値を持ち得る化学構造をデザインすることである．ここで対象とする物質を有機化合物（薬品，ポリマー，発光材料など）とすると，解くべき課題は，化合物の分子構造，特徴ベクトル，物性値の3要素を双方向的に繋ぐシステムを設計することである（図1）．すなわち，化合物を特徴ベクトルにエンコードし，それを用いて物性値を予測する「順問題」と，所望の物性値が得られる特徴ベクトル候補を出力し，その特徴ベクトルから分子構造を列挙する「逆問題」の両方を達成すべく，各要素間を繋ぐアルゴリズムを適切に設計する必要がある．特に，特徴ベクトルへのエンコード手法と分子構造へのデコード（構造生成）手法の設計が重要である．

これまで報告されてきた多くのアプローチは，順問題のみにフォーカスしたものや，化合物の形状に強い制約を設けた上での逆問題の解法などであった．本研究では，分子構造の部分構造に着目することで，順問題を十分な精度を以って解き，かつ逆問題にも対応可能なアルゴリズムを設計した．

連絡先： 武田征士，IBM 東京基礎研究所，
seijitkd@jp.ibm.com

2. 関連研究

2.1 バーチャル・スクリーニング

順問題のみを対象とする研究は，多くの場合バーチャル・スクリーニングと呼ばれる物質探索手法を想定している．これは，高精度の物性値予測モデルに，物性値が未知の多様な分子構造を数万～数千万個単位で投入し，所望の値に近い物性値を持つ物質を選別（スクリーニング）する手法である．高い予測精度が要求されるため，特徴ベクトルには，部分構造の出現を one-hot エンコードした Morgan Fingerprint [Pyzer-knapp 15a] や，原子間クーロン相互作用をエンコードした Coulomb Matrix [Rupp 12]が用いられる．また多くの場合，大量の化合物をディープラーニングにより学習する[Pyzer-knapp 15b]．学習後のモデルに投入する新規化合物は，部分構造の網羅的な組み上げや，遺伝的アルゴリズムにより生成され[Vership 13]，これら仮想的な化合物の集合をバーチャル・ライブラリーと呼ぶ．

本手法はシンプルながらも強力で，高効率な有機 LED 材料の発見が報告されている[G.-Bombarelli 16]．一方で，試行錯誤の AI 版ともいえる網羅性ゆえに，バーチャル・ライブラリー生成やディープラーニングにかかる計算コストが大きい．

2.2 生成モデル

変分オートエンコーダによる分子構造の生成モデルが近年提案された[G.-Bombarelli 18]．あらゆる分子のトポロジカルな構造は，SMILES（Simplified Molecular Input Linear Entry System）という文法に基づき，文字列による表記が可能である． G.-BomBarelliらは，SMILESを入力とし，SMILESおよびそれに帰

属する物性値を出力とする，数10万個の化合物により学習させた変分オートエンコーダを構成した．ガウス過程により，所望の物性値に相当し得る潜在空間上の点を選択し，それをSMILESにデコードすることで，候補化合物を得るという手法である．本手法はディープラーニングによる生成モデルの，分子構造への最初の適用事例であり大きな注目を集めたが，SMILES 文法が破綻した文字列を多く出力するという問題があるため，文法生成ルールを適用するなど改良の途上にある[Kusner 17].

2.3 部分構造の連結生成

順問題と逆問題の両方を扱う直感的な手法として，部分構造を部品と見なし連結することで化学構造を組み上げる(生成する)アプローチがある．[Arakawa 05] および[Huan 15] では，事前に定義した構造ユニットの個数を特徴ベクトルとして予測モデルを構築し，逆問題求解時にはそれらユニットを連結することで新構造を生成する．この手法は構造ユニットが事前に定義されているため，それを含まない物質に対応できず，また組み上げのパターンすなわち部分構造同士の連結ルールが決まっているため，限定的な構造しか生成できないという課題がある．

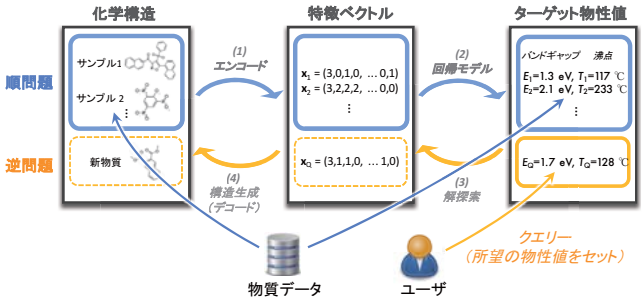


図1： 本提案手法の概要図．化学構造からターゲット物性値を予測する「順問題」と，所望の物性値を満たす新規な化学構造をデザインする逆問題を解く必要がある．

3. 提案手法

提案手法の概要を図1に示す．本手法の主な特徴は以下の2点である:

- 部分構造の個数カウントからなるデータ駆動特徴量と，構造生成に必要な事前定義特徴量の2種類を提案し，それらを同時に用いることで，順問題と逆問題を解くことを可能とした．
- 事前定義特徴量を基に分子構造を生成し，かつ部分構造を変形させながらデータ駆動特徴量によりフィルタする生成手法を提案することで，効率的な構造生成を可能とした．

3.1 特徴エンコード

分子構造の物質探索に用いる特徴量は，以下の性質を兼ね備えている必要がある:(1)分子構造の特徴を十分に捉え，高精度の予測モデルが作成可能であること，(2) 与えられた物質データ集合により柔軟に定義されること(データ駆動であること)，(3)それを用いて化学構造を広く逆生成できること，(4) 専門家が中身を理解できること．これらを満たす特徴量を，以下に定義する．

3.1.1 データ駆動特徴量

分子構造をノード(原子)とエッジ(結合)からなるグラフとみなしたとき，部分構造とは部分グラフと同義である．既存物質として与えられた分子構造 m_n の集合を $\mathcal{M} = \{m_1, m_2, \dots m_N\}$ とし，分子構造 m_n を構成する部分構造の集合を $S^{(n)}=\{s_1, s_2, \cdots\}$ とする．ただし，$S^{(n)}$は m_n を構成するあらゆる部分構造(最小は原子，最大は m_n 自体)からなる．集合$\mathcal{M}$の全ての要素に対して，網羅的に抽出された部分構造の集合は，$\mathcal{S}^{Full} = \bigcup_{i=1}^{N} \mathcal{S}^{(i)}$ で得られる．ここで，m に含まれる部分構造 s の個数を $N_D(m, s)$とし，分子構造 m_nを表現する特徴 $\boldsymbol{x}_D$を以下で定義する．

$$\boldsymbol{x}_{\mathrm{D}}^{(n)} \coloneqq \left(N_D\left(m_n, \mathcal{S}_1^{Full}\right), N_D\left(m_n, \mathcal{S}_2^{Full}\right), \dots\right) \qquad (1)$$

$\boldsymbol{x}_D$ は出現頻度の低い部分構造カウントを多く含み冗長であるため，特徴選択を行う．本手法では目標物性値 y への LASSO 回帰: $\mathcal{L}: \boldsymbol{x}_D \mapsto y$ により特徴選択し，$\boldsymbol{x}_D^{Select}$を得る．これをデータ駆動特徴量と呼ぶ．

3.1.2 事前定義特徴量

上記により得られたデータ駆動特徴量は，既に順問題に対応出来ているが，これらの情報のみでは具体的な分子構造を生成できない．なぜなら部分構造同士の連結や包含関係に関する情報を持たないからである．そこで，構造生成可能な特徴量を事前に定義し，データ駆動特徴量は，生成された構造から尤もらしいものを選別するフィルタリングに利用する．

構造の骨格生成に必要な情報として，x_{HA}, x_5, x_6(重原子，5員環，6員環の個数)，原子情報として，x_A (原子 A の個数)，結合情報として，$x_{||}$, $x_{|||}$, x_{arom} (二重結合，三重結合，芳香環の個数)を要素にもつ特徴量 $\boldsymbol{x}_P$を定義し，これを事前定義特徴量と呼ぶ．

データ駆動特徴量と事前定義特徴量を連結した以下のベクトルを，分子構造を表現する特徴ベクトルと定義する．

$$\boldsymbol{x} = (\boldsymbol{x}_D^{Sel}, \boldsymbol{x}_P) \qquad (2)$$

3.2 回帰モデル

上記の特徴ベクトル $\boldsymbol{x}$ を用いて物性値 y を予測する回帰モデル $\mathcal{L}: \boldsymbol{x}_D \mapsto y$ を構築する．カーネルリッジ回帰，サポートベクター回帰，ランダムフォレスト回帰などの一般的なモデルにより十分な精度が得られている．

物理シミュレーションによりバーチャル・ライブラリーの物質の物性値を計算した，人工データが大量にある特別な例[G.-Bombarelli 16]を除き，材料開発の分野において多くの場合利用可能なデータ数は数十から数百程度である．したがって，大量のデータを必要とするディープニューラルネットワークは必ずしも最良の選択ではない．

3.3 解探索

上記のモデル$\mathcal{L}$ の逆問題を解くことで，所望の物性値 y を満たす特徴ベクトルの候補 $\boldsymbol{x}_{cand}$を得る．$\mathcal{L}^{-1}$ を直接求めることは不可能なので，最適化アルゴリズムによる解探索を行う．ここでは一般的な PSO (Particles Swarm Optimization:粒子群最適化)アルゴリズムを用い，$\arg\min \left|y_{target} - \mathcal{L}(\boldsymbol{x})\right|^2 + \beta_r(\boldsymbol{x})$ を求める．$\beta_r(\boldsymbol{x})$はペナルティで，事前定義特徴量の重原子の個数，各原子の個数，環状構造の個数間の関係に化学構造として矛盾が生じた際に，任意の高い値$10 < \beta_r$ を与える．

3.4 構造生成

上記で得られた特徴ベクトル候補 $\boldsymbol{x}_{cand}$ を満たす分子構造を生成する．生成の流れは，事前特徴量 $\boldsymbol{x}_P$ の各情報をもとに，分子構造の骨格(グラフトポロジー)生成，原子情報(各原子個数)の導入，結合情報の導入を順次実施することで，徐々に構造を具体化してゆく．生成は SMILES の文字列操作により行う．得られた構造を，データ駆動特徴量 $\boldsymbol{x}_D^{Select}$ に含まれる部分構

造個数と照合することで，構造の選択すなわちフィルタリングをする．

ここで問題は，各ステップが進行するたびに生成される構造の個数が指数関数的に増大・発散するため，計算負荷が増え生成が困難になることである．そこで発散を抑えるために，各ステップごとに$\boldsymbol{x}_D^{Select}$の情報によるフィルタリングを行うことを考える．ただし$\boldsymbol{x}_D^{Select}$の示す部分構造の多くは，酸素原子や窒素原子，芳香環などを含むため，生成の初期ステップでは利用することができない．そこで各ステップに応じて，これらの部分構造をフィルタとして利用可能な形に変形する．そのワークフローを図2に示す．すなわち，最初は$\boldsymbol{x}_D^{Select}$に出現するすべての部分構造を，トポロジカルな骨格構造のみに還元し，各原子情報や結合情報の導入ステップに応じて，もし元の部分構造が対応する原子や結合を持っている場合は，それらを復元することにする．こうして変形された各部分構造が生成構造に含まれる個数をカウントし，それを$\boldsymbol{x}_D^{Select}$と照合することで，不適切な構造を除外するというフィルタリングを行う．

以上のプロセスを逐次的に実行することで，事前定義特徴量とデータ駆動特徴量の両者をともに満たす構造が生成され，かつ途中経過における個数の発散を抑えることが可能となる．

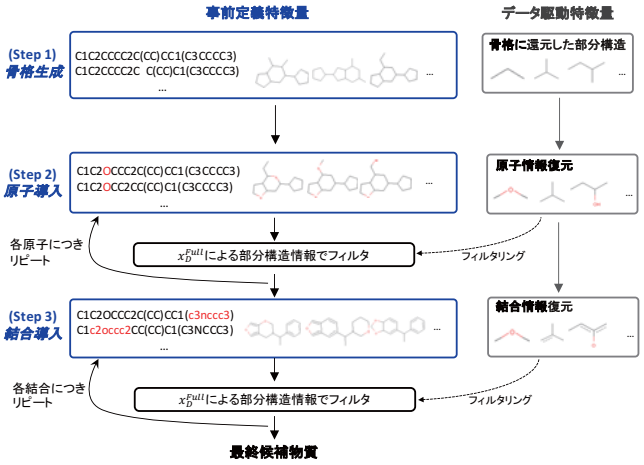


図2：構造生成のワークフロー．事前定義特徴量の情報から構造を生成し，各ステップに応じて変形させた部分構造の個数カウントとデータ駆動特徴量を比較し，構造を選別する．

4. 評価実験

本手法の実装に際し，分子からの部分構造抽出，分子に含まれる部分構造の個数カウント，および SMILES から分子構造への変換・描画，の3点については化学構造解析用のオープンツールである RDKit [GitHub 18]を用いた．

4.1 データセット

薬物の公開データベース ZINC15 中の，FDA-approved drugs データセットを用いて評価実験を実施した．本データセットに含まれる1,562 個の分子構造につき，目標物性値として，脂溶性および細胞膜透過性の指標となる logP（オクタノール/水 分配係数）および TPSA (Topological Polar Surface Area : 極性表面積) を原子団寄与法により計算した．図3にその分布を示す．A から D までの各象限に含まれる分子構造のうちランダムに取り出した5つずつの分子構造を描画しているが，logP や TPSA が高くなるにつれ，構造が大きく（原子数が多く）かつ複雑になることが確認される．本実験では，最も構造が複雑な象限 B における物質，具体的には目標物性値として$\{(y_{logP}, y_{TPSA}) \mid 3.0 \leq y_{logP} \leq 3.2 \cap 230 \leq y_{TPSA} \leq 240\}$を満たす分子構造を新規にデザインする．

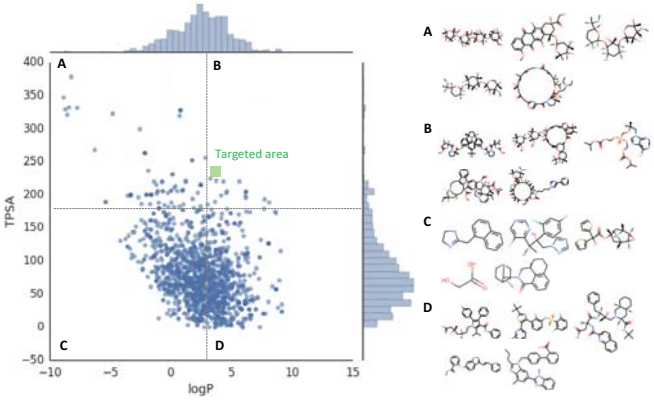


図3：物質データセットの logP および TPSA の分布．右に各象限内の化合物の例を示している．

4.2 特徴エンコード

1,562 個の分子構造につき，最大半径が2の Morgan Fingerprint を適用することで，3,760 個の網羅的な部分構造 S^{Full} を得た．3.1.1 節に従い，logP および TPSA について独立の Lasso 回帰モデル$\mathcal{L}_{logP}$および$\mathcal{L}_{TPSA}$を構築した．各々5-fold cross validation による L1 正則化項の最適化，特徴選択を行い，重複する部分構造を取り除いたところ，104 種類の部分構造が得られた．各分子構造に含まれるこれら部分構造の個数をカウントすることで得られる$\boldsymbol{x}_D^{Sel}$および，別途計算した$\boldsymbol{x}_P$を連結して，114 次元の特徴ベクトル $\boldsymbol{x}$ を得た．

4.3 回帰モデル

得られた特徴ベクトル $\boldsymbol{x}$ を用いて，logP および TPSA に対する回帰モデル$f_{logP}: \boldsymbol{x} \mapsto y_{logP}$ および $f_{TPSA}: \boldsymbol{x} \mapsto y_{TPSA}$ を構築した．モデルはリッジ回帰，ランダムフォレスト，サポートベクター回帰を用い，それぞれ 5-fold cross validation によりハイパーパラメータを最適化した．図4に，最良の結果が得られたリッジ回帰の結果を示す．本モデルにおいては，テストセットに対するスコア(R^2, RMSE) が，logP と TPSA に対して (0.98 ,0.36), (0.99, 3.4)がそれぞれ得られた．以降の節では本モデルを予測モデルとして用いる．

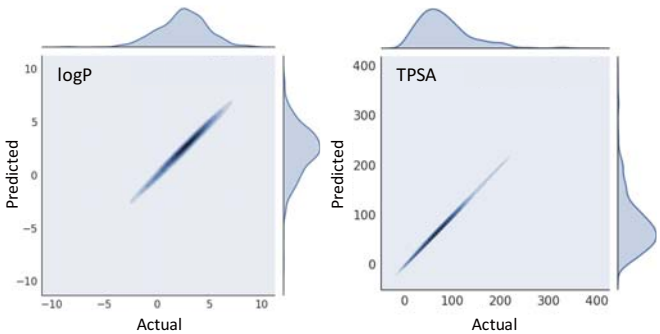


図4：回帰結果のカーネル密度分布．

4.4 解探索

f_{logP}およびf_{TPSA}を用いて，PSOにより4.1で設定した目標物性値を満たす特徴ベクトルを求める．探索範囲は，データセットの各特徴量ごとの最大・最小値の範囲内とした．1,000個の粒子による探索を実施し，特徴ベクトル候補を見つけるたびに粒子の位置をランダムに初期化することで，100個の候補を発見した時点で終了とした．

4.5 構造生成

得られた特徴ベクトル候補$\boldsymbol{x}_{cand}$を用い，3.4節のワークフローに従って分子構造を生成した．最終的に得られた分子構造の一部を図5に示している．いずれも原子数が多く複雑な形状を有しており，また構造の多様性にも富んでいる．人間の技術者がこのような構造を高速に列挙するのは極めて困難である．ここで提案する手法による生成時間（図2のワークフローに要する時間）は，構造の大きさにもよるが1分子あたり0.1から1秒程度である．したがって，従来的な試行錯誤による分子構造のデザインプロセスと比べ，速度と構造の多様性において高い優位性を実現している．また，所望の物性値から逆問題を解くため，バーチャル・スクリーニングを用いた手法と比べ，無用な構造を生成する必要がないため，探索効率が高いといえる．

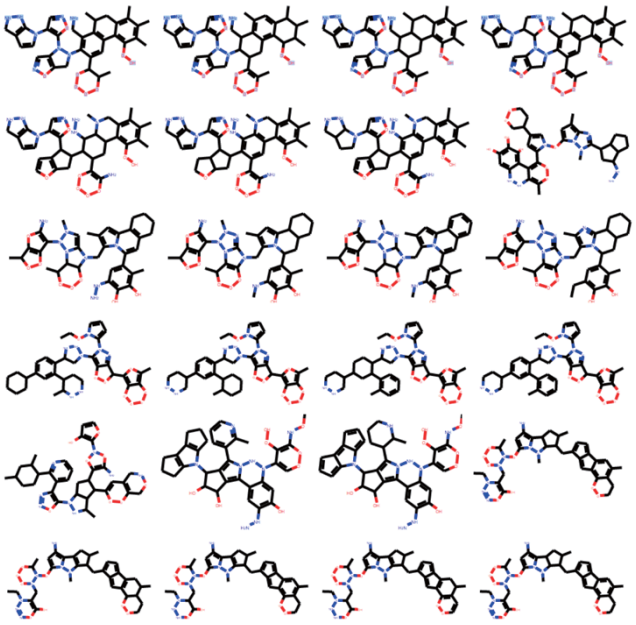


図5：生成された分子構造の一部．

5. 結論

本研究では，特徴エンコードから構造生成までend-to-endで動作するAIを活用した物質探索手法を提案した．与えられた物質データに含まれる部分構造カウントからなるデータ駆動特徴量と，構造生成に適用の容易な事前定義特徴量を組み合わせることで，順問題と逆問題の両方に対応可能なワークフローを構築した．ZINC15の薬物データを用いることで，複数の目標物性値を満足するような複雑な分子構造を高速に生成可能であることを実証した．

謝辞

本研究の一部成果に関しましては，IBM Research Frontiers Instituteの参画企業である，JSR株式会社，株式会社本田技術研究所，日立金属株式会社，長瀬産業株式会社，キヤノン株式会社の皆様から，積極的な意見を頂きました．また本研究のアルゴリズム構築にあたり，IBMアルマデン研究所のDr. Jed PiteraとDr. Victoria Piunovaから有意義なアドヴァイスを頂きました．

参考文献

[Bohacek 96] Bohacek, R.S., McMartin, C., and Guida, W.C.: The art and practice of structure-based drug design: A molecular modeling perspective, *Medicinal Research Reviews*, 16 (1), 3-50 (1996)

[Pyzer-knapp 15] Pyzre-knapp, E.O., et al., What is high-thoughput virtual screening? A perspective from organic materials discovery, *Annual Review of Materials Research*, 45, 195-216 (2015).

[Rupp 12] Rupp, M., et al., Fast and accurate modeling of molecular atomization energies with machine learning, *Phys. Rev. Lett.*, 2018, 053801 (2012).

[Pyzer-knapp 15] Pyzer-Knapp, E.O., Li, K., and A-Guzik, A., Learning from the Harvard Clean Energy Project: The Use of Neural Networks to Accelerate Materials Discovery, *Materials Review*, 25, 6495-6502 (2015).

[Vership 13] Virship, A.M., et al., Stochastic Voyages into Uncharted Chemical Space Produce a Representative Library of All Possible Drug-Like Compounds, *Journal of the American Chemical Society*, 135, 7296-7303 (2013).

[G.-Bombarelli 16] Gomez-Bombarelli, R., et al., Design of efficient molecular organic light-emitting diodes by a high-throughput virtual screening and experimental approach, *Nature Materials*, 15, 1120-1128 (2016).

[G.-Bombarelli 18] Gomez-Bombarelli, R., et al., Automatic chemical design using a data-driven continuous representation of molecules, *ACS Central Science*, 4(2), pp.26 8-276 (2018).

[Kusner 17] Kusner, M. J., Paige, B., Miguel, J., Hernández-Lobato, Grammar Variational Autoencoder, *Proceedings of the 34th International Conference on Machine Learning, PMLR*, 70, 1945-1954 (2017)

[Arakawa 05] Arakawa, M., Yamada, Y., Funatsu, K., Development of the computer software for automatic chemical structure generation using group contribution method, *Journal of Computer Aided Chemistry*, 6, 90-96 (2005).

[Huan 15] Huan, T.D., M.-Kanakkithodi, A., and Ramprasad, R., Accelerated materials property predictions and design using motif-based fingerprints, *Physical Review B*, 92, 014106 (2015).

[GitHub 18] GitHub and SourceForge, RDKit: Open-Source Cheminformatics Software (http://www.rdkit.org/)

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

ミツバチの尻振りダンス軌跡およびダンス追従軌跡の自動検出手法の検討

Automatic Tracking of Honeybee Dancer' and Follower' Walking Trajectories

高橋 伸弥[*1] 前田 佐嘉志[*1] 橋本 浩二[*1] 鶴田 直之[*1] 藍 浩之[*2]
Shinya Takahashi Sakashi Maeda Koji Hashimoto Naoyuki Tsuruta Hiroyuki Ai

[*1] 福岡大学工学部電子情報工学科 Dept. EECS, Fukuoka University
[*2] 福岡大学理学部地球圏科学科 Dept. ESS, Fukuoka University

Analyzing communications between the honeybee waggle dancers and their followers in their hive is one of the most important and interesting issues to reveal a mechanism of honeybee's language. In general, these behavior analyses have been usually conducted by extracting honeybee's walking trajectories from recorded long-time video data manually. To decrease the hard work of observers and their artificial errors, we have previously proposed an automatic tracking algorithm of multiple honeybees using image processing. Besides, we have constructed an automatic recording system for long-term tracking of honeybee behaviors in an observation hive using several high-resolution camera modules connected to multiple small-size single board computers. Using this system, we recorded the hive and its corridor to the field from 6:30 am to 7:30 pm over 4 weeks in June 2016. The colony had about 800 honeybees including a queen. Finally, we obtained video data over 20TB per a month. Analyzing honeybee's behavior from this enormous amount of data is required an extremely long time even if using a high spec computer. In order to deal with this issue, we first extracted the area and time of waggle dance from the recorded video data using a preprocessing based on frame-difference approach. Then we applied our tracking algorithm for the extracted partial video data. In the preliminary experiment, we conducted the automatic tracking of the waggle dancers and their followers for 13-hour video data and confirmed that our approach can detect their trajectories.

1. はじめに

採餌後，帰巣したミツバチは，尻振りダンス(waggle dance)で蜜源の位置を仲間に伝えることが知られている．このようなミツバチ個体間での情報交換のメカニズムを解明するため，著者らはこれまで，ミツバチの巣内における採餌関連行動を観察するシステムを開発してきた[高橋 2017]．このシステムを使用して記録した巣板上の観察動画像に複数個体同時追跡アルゴリズム[高橋 2015]を適用し，追跡結果の軌跡から特徴的な動きをしているもののみを抽出することで，尻振りダンスおよび周辺個体の軌跡を抽出すればミツバチの採餌関連行動の分析が可能となる．このとき，巣箱を撮影した高解像度かつ長時間の動画像に対して直接，軌跡検出を行うと撮影時間の 10 倍以上（Intel Core i7-2700 使用時）の計算時間が必要であることから，軌跡検出処理の前処理として，ミツバチの尻振りダンス領域とその区間（時間範囲）を事前に切り出しておき，切り出した部分動画像に対して軌跡検出を行うことを考える．この前処理については既に[高橋 2018]で検討を行っているため，本稿では，前処理を行ったあとのダンス軌跡および周辺個体の軌跡の検出について検討する．

2. ミツバチ巣内行動観察システムの概要

巣板上の行動は複数台のシングルボードコンピュータ（Raspberry Pi）に接続された CMOS 小型カメラモジュールにより，巣板の表側・裏側のほぼ同じ範囲を分割して両側から記録した．動画は 1296×730 画素，49fps で撮影されたものであり，10 分ごとのファイルとして記録されている．

撮影される動画はカメラ 1 台につき 1 日あたり約 80~100GB のファイル容量となることから，巣箱全体をカバーする範囲を撮影する6台で 1 ヶ月記録すると 20TB 近くの量になる．これらの動画像から尻振りダンス軌跡を自動検出することを考えると，1 台分の映像でも半年近く処理に時間がかかることになるため，尻振りダンスが発生している領域とその区間（時間範囲）を予め自動処理で切り出しておき，その後，詳細処理として軌跡検出を行うことを考える．

連絡先：高橋伸弥，福岡大学工学部電子情報工学科，福岡市城南区七隈8－19－1，takahasi@tl.fukuoka-u.ac.jp

3. 尻振りダンス区間の切り出し

尻振りダンスでは，翅を振動させ尻を振りながら蜜源を示す方向へと直進歩行したのち，右または左にターンして元の位置に戻り，再び直進歩行をするというサイクルを何度も繰り返す．従って尻振りダンス軌跡は，大きな画素変化が断続的に含まれている軌跡であると考えられる．そこで，フレーム間の差分画像を重み付け加算した画像に対し，2 値化処理，膨張収縮処理，ラベリング処理を行い，最大面積の領域を尻振りダンス領域の候補として検出する．

ここで，各フレームを複数領域（ブロック）に分割し，それぞれに対して，画素変化量（検出された尻振りダンス候補領域の面積）の時系列データを得ることとする．本実験では，各フレームの左端及び上端を除去して 1280×720 画素としたものを 320×240 画素の大きさのブロックで 4×3 の領域に分割し，それぞれのブロックに対して動的計画法による区間分割を行い，分割された領域全体での平均画素変化量が閾値以上の区間を尻振りダンス区間として切り出した[高橋 2018]．使用したデータは，2015 年 9 月に 4 週間撮影した動画のうち，比較的ダンスが多く観察された，9/27 の 6:30 から 19:30 までの 13 時間分のデータである．ここでは，閾値を 100 画素，分割区間長の閾値を 500 フレーム（約 10 秒）とした．

以上の前処理により切り出された 269 ブロックを対象に，軌跡検出を行った．

4. 尻振りダンス軌跡とダンス追従軌跡の検出

前処理により切り出した，尻振りダンス区間を含む動画像に対して，複数個体同時追跡アルゴリズム[高橋 2015]を適用し，歩行軌跡を求める．このアルゴリズムは，各フレームにおいて，

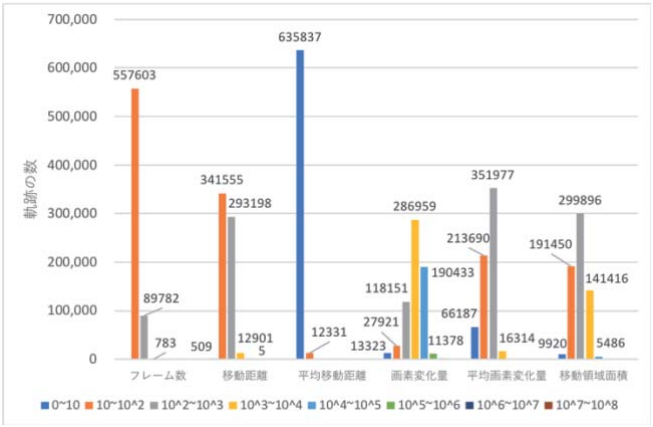


図 1　検出された軌跡の諸元に対するヒストグラム

事前に学習しておいた分類器によりミツバチの腹部領域を検出し，フレーム間でそれぞれの領域の対応付けをとることにより，軌跡を追跡するものである．ここで，入力とした動画像は隣接する分割領域との境界付近の軌跡を検出するため，上下左右に重なりを持たせ 480×360 画素の大きさとした．各ブロックにおいて検出された軌跡のうち，3節で示した処理により計算したミツバチ腹部領域の画素変化量の平均を求め，この値が閾値θ_v以上のものをダンス軌跡とする．次に，求めたダンス軌跡と同時間帯において検出された軌跡のうち，ダンス軌跡全体のα%で距離r以内に軌跡が存在し，かつ，フレーム長が閾値θ_d以上のものを周辺個体軌跡として抽出する．

上記の手順によって求められたダンス軌跡には，尻振りダンスだけではなく，その場で羽を震わせる行動や体を前後に激しく動かす行動なども含まれることが予想されるが，ここでは区別することはせず，特異な行動として同時に検出することとした．また周辺個体軌跡についても明確にダンスに追従している個体ばかりではなくたまたま周辺にいた個体の軌跡も含まれると予想されるが，今回の実験ではそれらの相違を確認することとした．

5.　実験結果

前処理によって切り出された 269 の動画(平均フレーム数 4900)に対して，複数個体同時追跡アルゴリズムを適用し，最小フレーム数 10 以上の軌跡を検出した結果，総数にして 65 万の軌跡が検出された．1 動画あたりの平均は 2410 であり，最小で 309，最大で 7963となった．これらの軌跡のフレーム長の平均は 57.4 フレーム，移動距離の平均は 185.0 画素となった．図 1 は，これらの軌跡に対するフレーム数等諸元のヒストグラムである．フレーム数の分布から，65 万のうち 8 割近くは短時間で細切れになった軌跡だったことが分かる．

これらの軌跡の中から，画素変化量の平均が$\theta_v = 1000$以上で，かつフレーム長がθ_d=100 以上の軌跡だけを抽出すると，その総数は 16302（1動画あたり 60.6 個）となり，軌跡のフレーム長の平均は 45.5 フレーム，移動距離の平均は 304.4 画素となった．また平均画素変化量の平均は 1222 画素であったことから，多くは短時間の軌跡ではあるものの，激しい動きを伴って移動する軌跡が抽出できていることがわかる．次に，以上のダンス軌跡に対して，距離r=100（画素），α＝40%，θ_d==100 として周辺個体の軌跡を抽出した結果，総数 9320（1動画あたり 34.6）の軌跡が抽出された．軌跡のフレーム長の平均は 231.4 フレーム，移動距離の平均は 780.3 画素，平均画素変化量の平均は 383 画素となった．一般に，尻振りダンスを行なっている個体には複数の追従個体が見られることから，今回の実験結果では，ダンス個体の検出が過剰であること，また周辺個体の軌跡検出が不十分であることが推測される．

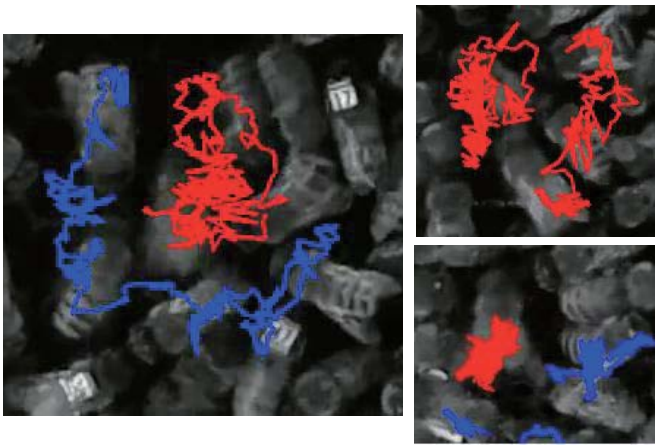


図 2　ダンス軌跡およびダンス追従軌跡の検出例
（左：成功例、右上：失敗例、右下：振身ダンス）

図 2 に，提案手法により検出した尻振りダンス軌跡とその周辺個体軌跡の検出結果を示す．図左は，ダンス個体（赤色）に対して，その周辺を回り込むように追従している軌跡（青色）が検出できていることがわかる．図右上は，追従個体の軌跡も，その画素変化量が大きくなっているため，ダンス個体と混同してしまっている結果である．また右下は，画素変化量が大きい軌跡だが移動量が少ない場合ということで，その場で体を激しく震わせる振身ダンスの個体が検出されている様子である．閾値θ_vの値を調整することで，ダンス軌跡の過検出を抑制することが可能だと考えられるが，より高精度な判定を実現するには，閾値ではなく軌跡の特徴を利用すべきだと考えられる．

6.　まとめ

本稿では，ミツバチ巣内の行動を長時間撮影した入力動画像からミツバチの尻振りダンス軌跡とダンス追従軌跡とを検出することを目的として，ダンスを行っている区間を事前に分割しておき，それらに対して詳細な軌跡検出処理を行うことを試みた．実験の結果，ダンス軌跡とその周辺個体の軌跡を検出できることが確認できたが，ダンス追従軌跡や振身ダンス軌跡を判別するには，異なるアプローチが必要であることが示唆された．しかし，今回試行した手法により，観察者の目視による詳細な分析の手がかりを示すことは可能だと思われる．今後は，軌跡検出の高精度化と合わせ，有用な観察ツールとして提供することも検討したい．

謝辞

本研究は，JSPS 科研費 17K00422 および福岡大学研究推進部の研究経費（課題番号：171031）の助成を受けた．本研究のデータ分析に協力頂いた，楠目晃大氏，目崇志氏，田中聡至氏，牛島実佑氏に深く感謝する．

参考文献

[高橋　2015]　高橋他，“ミツバチ歩行軌跡の複数個体同時追跡アルゴリズムを用いた尻振りダンス軌跡の抽出”，人工知能学会全国大会論文集，第 29 巻，pp.1-4, 2015.

[高橋　2017]　高橋他：“ミツバチコロニーの巣内行動観察システムの開発”，人工知能学会論文誌，32(4), pp. B-GC2_1-11, 2017.

[高橋　2018]　高橋他：“フレーム間差分動画像を用いたミツバチ尻振りダンス自動検出手法の検討”，福岡大学工学集報，Vol.100，(in press)，2018.

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

化学構造式のためのハイパーグラフ文法

Molecular Hypergraph Grammar

梶野　洸 *1
Hiroshi Kajino

*1日本アイ・ビー・エム株式会社東京基礎研究所
IBM Research - Tokyo

This paper is concerned with a graph grammar that can be inferred from data and always generates valence-consistent molecular graphs. Our result is that the requirement above can be satisfied by a hyperedge replacement grammar inferred from *molecular hypergraphs*, which we call a *molecular hypergraph grammar* (MHG). By substituting MHG for SMILES (a grammar generating a string representation of a molecule) in a generative model of molecules, we can generate novel molecules without decoding errors, which have been one of the common issues when using SMILES.

1. はじめに

化学分子の最適設計問題は、分子に関する所望の性質を入力したとき、それに最も近い性質を持つ分子を出力する問題である．例えば、なるべく効率の高い有機発光ダイオードを設計する問題などが考えられる [Gómez-Bombarelli 16]．この問題では、分子集合という構造が明らかではない離散集合の上で最適化を行わなければいけない点で難しいと考えられている．近年では変分自己符号化器 (VAE) を用いてこの最適化問題に取り組みやすくする研究が行われている [Gómez-Bombarelli 18]．この研究では、分子グラフとその潜在ベクトルを繋ぐ符号化器と復号化器に加えて、潜在連続空間から分子の性質を予測する予測器を学習する方法を提案している．3つめのモデルを使うことで分子の最適設計を連続空間上での最適化問題として定式化でき、復号化器を用いることで、最適化問題を解いて得られた潜在ベクトルに対応する分子グラフを得ることができる．

この研究を元に様々な方向性の拡張が行われる中で，本研究では分子の表現方法に着目する．ほとんどすべての研究では分子のグラフ表現を元にしているが，VAE の入出力としてグラフを直接使った研究はほとんどなく，その代わりとして分子グラフを文字列表現した SMILES [Weininger 88] という表現が用いられる．その理由として，文字列を出力できるニューラルネットワークとして LSTM や GRU など様々なものが知られている一方で，グラフを出力できるニューラルネットワークがあまり一般的でないことが考えられる．

SMILES を用いた VAE の欠点として，出力された SMILES 文字列が必ずしも分子グラフにならないという問題が上げられる．これを**復号化エラー問題**と呼ぶ．この問題をフェノールを例に説明する．フェノールは SMILES では `c1c(O)cccc1` と表される．ここで数字は環の始点・終点を，括弧は枝分かれを表し，水素原子は省略される．例えば復号化器が最後の数字を出力しなかった場合，`c1c(O)cccc` という文字列が得られるが，この文字列では環が閉じないため文字列を分子グラフに変換できない．また復号化器が複数の括弧を出力して `c1c(O)(O)cccc` という文字列を得た場合，炭素原子の原子価を超えてしまうため，不正な分子グラフとなる．このような問題を解決するため，出力が分子グラフとなることが保証されるような手法の開発が必要である．

連絡先: 梶野　洸，KAJINO@jp.ibm.com

本研究では，原子価を守った分子グラフを必ず生成できる**分子ハイパーグラフ文法** *(molecular hypergraph grammar; MHG)* と MHG を分子の集合から学習するアルゴリズムを提案する．MHG を文法利用型変分自己符号化器 [Kusner 17] と組合せることで，復号化エラー問題のない分子グラフの生成モデルが実現できる．MHG では，分子を**分子ハイパーグラフ**という形で表現する．通常の分子グラフとは異なり，原子をハイパーエッジ，結合をノードとして表現する．ハイパーグラフの集合からハイパーエッジ置換文法を学習するアルゴリズム [Aguiñaga 16] にある前処理を加えたアルゴリズムを用いることで，分子ハイパーグラフの集合から MHG を学習できるアルゴリズムが得られる．本研究の主な貢献は，上のアルゴリズムが MHG を正しく学習できること，つまり上のアルゴリズムで得られたハイパーエッジ置換文法は，原子価を守った分子グラフを必ず生成するということを示した点にある．

2. 導入

本章ではハイパーエッジ置換文法 (hyperedge replacement grammar; HRG) をデータから学習するアルゴリズム [Aguiñaga 16] の紹介をする．ハイパーグラフの木分解と HRG の構文木に対応関係があることに着目したアルゴリズムで，入力したハイパーグラフのすべてを生成できる HRG が得られるのが特徴である．

2.1 ハイパーグラフと木分解

ハイパーグラフ $H = (V_H, E_H)$ は，ノード集合 V_H とハイパーエッジ集合 E_H からなる．ハイパーエッジとは V_H の非空部分集合である．ハイパーグラフの木分解（定義 1）は，ハイパーグラフをなるべく木に近いグラフに分解したものである．図 3 は，図 2b のハイパーグラフの木分解の一つである．

定義 1. ハイパーグラフ $H = (V_H, E_H)$ の木分解は，木 $T = (V_T, E_T)$ と二つのラベル付け関数 $\ell_T^{(V)} \colon V_T \to 2^{V_H}$, $\ell_T^{(E)} \colon V_T \to 2^{E_H}$ で，以下の条件を満たすものである．

1. 各 $v_H \in V_H$ について， $v_H \in \ell_T^{(V)}(v_T)$ を満たすノード $v_T \in V_T$ が少なくとも一つ存在する．
2. 各 $e_H \in E_H$ について， $e_H \subseteq \ell_T^{(V)}(v_T)$ かつ $e_H \in \ell_T^{(E)}(v_T)$ を満たすノード $v_T \in V_T$ がただ一つ存在する．

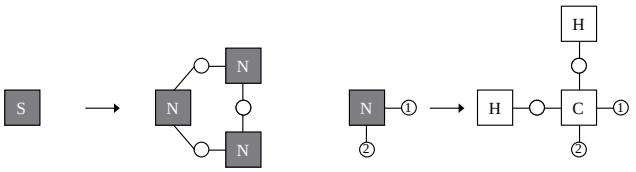


図 1: 図 2b のハイパーグラフから抽出された生成規則の一部. 塗りつぶした四角は非終端記号，塗りつぶしていない四角は終端記号，丸はノード，丸と四角の間の線はハイパーエッジに含まれるノードを示している．ノードの中の番号は，取り除かれるハイパーエッジと置換されるハイパーグラフのノードの対応を示す.

3. 各 $v_H \in V_H$ について，$\{v_T \in V_T \mid v_H \in \ell_T^{(V)}(v_T)\}$ が T 内で連結である.

ノード $v_T \in V_T$ 上のハイパーグラフを $H(v_T) := (\ell_T^{(V)}(v_T), \ell_T^{(E)}(v_T))$ と書く.

2.2 ハイパーエッジ置換文法 (HRG)

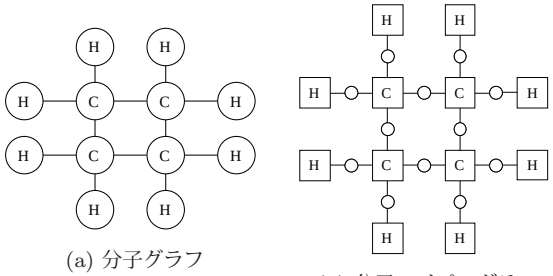
HRG は，ラベル付きハイパーエッジを持つハイパーグラフを生成する文脈自由文法である (定義 2，図 1)．開始記号 S からなるハイパーグラフ H からはじめ，非終端記号 A でラベル付けされたハイパーエッジをハイパーグラフ R で置き換えることを繰り返し，すべてのハイパーエッジが終端記号でラベル付けされた時点で終了する.

定義 2. ハイパーエッジ置換文法 $\mathcal{G} = (N, T, S, P)$ は，以下の四つの要素で定義される.

1. N は，非終端記号の集合である.
2. T は，終端記号の集合である.
3. $S \in N$ は開始記号である.
4. P は生成規則の集合で，
   - $p = (A, R)$ は生成規則，
   - $A \in N$ は非終端記号，
   - R は，$|A|$ 個の外部ノードを持ち，$T \cup N$ でラベル付けされたハイパーエッジを持つハイパーグラフである．ハイパーエッジ A の各ノードと外部ノードは対応付けされており，その対応付けに従ってハイパーエッジ A がグラフ R に置換される.

2.3 HRG 学習アルゴリズム

最後に，ハイパーグラフの集合から HRG を学習するアルゴリズム [Aguiñaga 16] を紹介する．ノード $v_T \in V_T$ について，$\mathrm{pa}(v_T)$ を v_T の親ノード，$\mathrm{ch}(v_T)$ を v_T の子ノード集合とする．このアルゴリズムの基本的なアイデアは，各ペア $(v_T, \mathrm{pa}(v_T))$ を共通するノードで繋いでいくと元のハイパーグラフを作れるというところにある．例えば図 3 で各ノード上のハイパーグラフを繋いでいくと図 2b のハイパーグラフが得られる．これを HRG の言葉で言い換えると，木分解は HRG の構文木と解釈できる [Chiang 13] ということである．実際，アルゴリズムでは三つ組 $(\mathrm{pa}(v_T), v_T, \mathrm{ch}(v_T))$ から一つの生成規則を抽出するが，その生成規則は，「$H(\mathrm{pa}(v_T))$ に $H(v_T)$ を貼り付けつつ，子ノードから得られる生成規則を適用可能なように非終端記号を追加する」という操作に対応する．アルゴリズムの詳細に関しては原論文を参照されたい.



(a) 分子グラフ　(b) 分子ハイパーグラフ

図 2: シクロブタンの二つのグラフ表現.

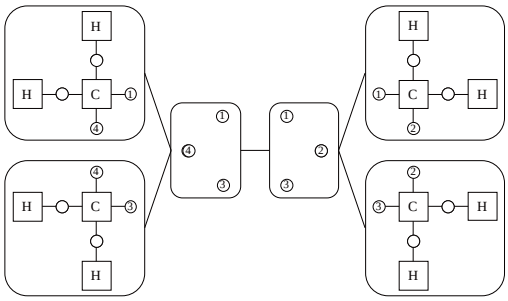


図 3: 図 2b のハイパーグラフの非冗長木分解.

3. 分子ハイパーグラフ文法

本論文の主貢献である，**分子ハイパーグラフ文法** (molecular hypergraph grammar; MHG) とその学習アルゴリズムを紹介する．以下の二つのアイデアからなる。(i) 分子は通常の分子グラフ (図 2a) ではなく，**分子ハイパーグラフ** (図 2b) で表現する．(ii) HRG の学習の際に，通常の木分解ではなく**非冗長木分解**を用いる．この二つのアイデアを用いることで，学習された文法は原子価を守った分子グラフを必ず生成するということが示される.

3.1 分子ハイパーグラフ

分子ハイパーグラフ（定義 3）では，原子をハイパーエッジで表現し，二つの原子間の結合を二つのハイパーエッジで共有されたノードとしてモデル化する．実際の分子との対応については，$L^{(E)}$ は原子集合に対応し（例えば $\mathrm{C}, \mathrm{H} \in L^{(E)}$），$c^{(E)}$ は各原子の原子価に対応する (例えば $c^{(E)}(\mathrm{C}) = 4$).

定義 3. $L^{(E)}$ をハイパーエッジのラベル集合とし，$c^{(E)}\colon L^{(E)} \to \mathbb{N}$ をノード数制約関数とする．ハイパーエッジラベル付きハイパーグラフ $H = (V_H, E_H, \ell_H^{(E)})$ が以下の条件を満たすとき分子ハイパーグラフであるという.

1. H の各頂点は必ず二つのハイパーエッジに含まれる.
2. 各 $e \in E_H$ について，$|e| = c^{(E)}(\ell_H^{(E)}(e))$ が成り立つ．ここで $|e|$ はハイパーエッジ e に含まれるノード数を表す.

一つめの条件は、分子ハイパーグラフが通常の分子グラフに変換できることを保証する。また二つめの条件が成立している場合，ハイパーグラフが**原子価一致**していると定義する．HRG で，常に分子ハイパーグラフを生成するものを**分子ハイパーグラフ文法** (MHG) と定義する.

3.2 非冗長木分解

本論文で用いる木分解の性質である**非冗長性**（定義 4）について紹介する．この性質は，HRG で生成されたハイパーグラ

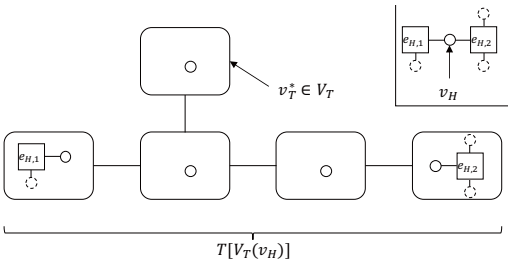


図 4: **冗長**木分解 T の例．右上の図は元のハイパーグラフ H の一部を表し，左下にその木分解の一部（$V_T(v_H)$ によって誘導された部分グラフ）を図示した．非冗長にするためには v_T^* から v_H を取り除く必要がある．

フを通常のグラフに変換できることを保証するのに必要である．直感的には，木分解の各ノードのハイパーグラフに自明に取り除けるノードが含まれていない場合に非冗長であるという．図 3，図 4 はそれぞれ非冗長，冗長な木分解を図示している．

定義 4. $H = (V_H, E_H)$ をハイパーグラフとし，$(T, \ell_T^{(V)}, \ell_T^{(E)})$ をその木分解とする．$V_T(v_H) = \{v_T \in V_T \mid v_H \in \ell_T^{(V)}(v_T)\}$ を T のノードで $v_H \in V_H$ を含むノード集合とする．木分解が次の条件を満たすとき，非冗長であるという．

$$\forall v_H \in V_H,\ \forall v_T \in V_T(v_H)$$
$$\ell_T^{(E)}(v_T) \neq \emptyset \Leftrightarrow v_T \text{が } T[V_T(v_H)] \text{ の葉.} \quad (1)$$

ここで $T[V_T(v_H)]$ は $V_T(v_H)$ により誘導される部分グラフである．

任意の木分解は多項式時間で非冗長なものに変換可能である．各 v_H について，各 $\ell_T^{(E)}(v_T)$ $(v_T \in V_T(v_H))$ が条件 (1) を満たしていなければ v_H を取り除くことを繰り返せばよい．

3.3 MHG 学習アルゴリズム

2.3 章で議論した HRG 学習アルゴリズムと 3.2 章で議論した木分解を非冗長木分解に変換するアルゴリズムを組合せたものが MHG 学習アルゴリズムである．つまり，HRG 学習アルゴリズムで木分解から生成規則を抽出する前に木分解を非冗長木分解に変換するというものが提案アルゴリズムである．

3.4 アルゴリズムの正当性

最後に，提案アルゴリズムの正当性に関する結果を定理 5 に示す．この定理は，提案アルゴリズムから学習された HRG は入力分子ハイパーグラフすべてを生成でき，その HRG によって生成されたハイパーグラフは必ず分子ハイパーグラフになる（つまりこの HRG は MHG である）ということを述べている．

定理 5. $\mathcal{L}_H(L^{(E)}, c^{(E)})$ を分子ハイパーグラフ全体の集合とし，$\hat{\mathcal{L}}_H \subseteq \mathcal{L}_H(L^{(E)}, c^{(E)})$ をその部分集合とする．提案アルゴリズムを $\hat{\mathcal{L}}_H$ に適用して学習される *HRG* が生成するハイパーグラフ全体の集合を $\mathcal{L}_{\mathrm{HRG}}(\hat{\mathcal{L}}_H)$ とする．$\mathcal{L}_{\mathrm{HRG}}(\hat{\mathcal{L}}_H)$ は次の関係を満たす．

$$\hat{\mathcal{L}}_H \subseteq \mathcal{L}_{\mathrm{HRG}}(\hat{\mathcal{L}}_H) \subseteq \mathcal{L}_H(L^{(E)}, c^{(E)}).$$

$\hat{\mathcal{L}}_H \subseteq \mathcal{L}_{\mathrm{HRG}}(\hat{\mathcal{L}}_H)$ に関してはすでに示されている [Aguiñaga 16] ため，定理 5 を証明するためには $\mathcal{L}_{\mathrm{HRG}}(\hat{\mathcal{L}}_H) \subseteq \mathcal{L}_H(L^{(E)}, c^{(E)})$ が成り立つことを示せばよい．$\mathcal{L}_{\mathrm{HRG}}(\hat{\mathcal{L}}_H) \subseteq \mathcal{L}_H(L^{(E)}, c^{(E)})$ は，補題 7，8，9 を組合せることで示される．補題 7，8 は，提案アルゴリズムが分子ハイパーグラフの第一条件を保存することを示しており，補題 9 は，提案アルゴリズムが分子ハイパーグラフの第二条件を保存することを示す．

条件 6. 各生成規則 $p = (A, R)$ について，R の外部ノードの次数は 1 で，内部ノードの次数は 2 である．

補題 7. すべてのノードの次数が 2 のハイパーグラフ集合に対して提案アルゴリズムを適用して得られた *HRG* は条件 *6* を満たす．

補題 8. *HRG* が条件 *6* を満たすならば，生成されるハイパーグラフのすべてのノードの次数は 2 である．

補題 9. 原子価一致したハイパーグラフ集合に対して提案アルゴリズムを適用して得られた *HRG* は常に原子価一致したハイパーグラフを生成する．

本稿では証明は省略する．

4. 関連研究

最適分子設計に関する既存研究を紹介し，その分野における本研究の貢献を議論する．

最適分子設計は特に創薬の分野において長い歴史を持つ．数理的な手法の研究では組合せ的最適化に基づく手法を用いて所望の性質を持つ新しい分子を発見する研究が行われてきた [Jorgensen 09]．近年の研究では，VAE を用いて分子グラフの空間と連続潜在空間との間の符号化器と復号化器を学習し，連続空間上で分子の最適化を行った後，復号化器を用いて分子グラフを出力するという手法が取られている [Gómez-Bombarelli 18]．2016 年にプレプリントが公開されて以来，この枠組に則った手法が盛んに研究されている．

この手法の欠点の一つに分子の表現方法がある．1 章で議論したように，殆どの研究では SMILES という分子グラフの文字列表現を用いており，最適化の結果得られた分子の連続ベクトルが正しい SMILES 文字列に復号化できないという復号化エラー問題がある．この問題に対する解決策の方針は主に二つある．一つの方針は，復号化器のニューラルネットワークに工夫を施しなるべく正しい SMILES 文字列を生成するようにする方法である [Kusner 17, Dai 18]．もう一つの方針は，SMILES 以外の分子の表現方法で，出力が必ず正しい分子グラフになることが保証できるものを用いる方法である [Jin 18]．本研究は後者に属する．出力が必ず原子価を守った分子グラフになるようなグラフ文法とその学習方法を提案した．

我々の知る限りでは，後者の方針を取った研究は他に一つしか知られていない [Jin 18]．この研究では，分子グラフの木分解を分子表現の一つとして用いている．HRG と木分解の対応関係を鑑みると，この研究と我々の研究は似たような方針を取っているが，次の二つの点で異なる．一点目に，Jin らの研究では通常の分子グラフに対する木分解を用いているが，我々の研究では分子ハイパーグラフに対する木分解を用いている点が異なる．分子グラフに対する木分解から HRG を学習することは可能だが，その HRG は原子価を破る分子グラフを生成しうるため，本研究で得られたような保証は得られない．Jin らは文法を経由しないグラフの組上げアルゴリズムを用いてこの問題を回避しているが，その分アルゴリズムやモデルが複雑になっている．二点目に，研究目的が異なる．Jin らの研

究ではある固定された方法で木分解を行っている一方，ニューラルネットワークの構造に多くの工夫を加えている．我々の研究では文法をデータから学習している一方，ニューラルネットワークに関する検討を行っていない．このように我々の研究と Jin らの研究は相補的であるため，我々の手法と Jin らの手法を組合せることでさらなる性能向上が期待される．

5. 結論と今後の展望

本研究では，原子価を守った分子グラフを常に生成する HRG をデータから学習するアルゴリズムを提案した．学習された HRG を文法利用型変分自己符号化器などと組合せることで，従来手法で問題となっていた復号化エラー問題を解決することができる．

今後の展望として，MDL 原理 [Jonyer 04] やベイズ規準 [Chen 95] などに基づく文法の最適化が挙げられる．定理 5 を満たす文法の中からよりコンパクトなものを選ぶことによって，後段のニューラルネットワークの学習が容易になることが期待される．

謝辞

この研究は一部，科研・基盤 (S) 15H05711 のサポートを受けている．本研究に関して議論頂いた石畠正和氏に感謝する．

参考文献

[Aguiñaga 16] Aguiñaga, S., Palacios, R., Chiang, D., and Weninger, T.: Growing graphs from hyperedge replacement graph grammars, in *Proceedings of the 25th ACM International on Conference on Information and Knowledge Management (CIKM '16)*, pp. 469–478 (2016)

[Chen 95] Chen, S. F.: Bayesian Grammar Induction for Language Modeling, in *Proceedings of the 33rd Annual Meeting on Association for Computational Linguistics (ACL '95)*, pp. 228–235 (1995)

[Chiang 13] Chiang, D., Andreas, J., Bauer, D., Hermann, K. M., Jones, B., and Knight, K.: Parsing graphs with hyperedge replacement grammars, in *Proceedings of the 51st Annual Meeting of the Association for Computational Linguistics (ACL '13)*, pp. 924–932 (2013)

[Dai 18] Dai, H., Tian, Y., Dai, B., Skiena, S., and Song, L.: Syntax-directed variational autoencoder for structured data, in *International Conference on Learning Representations (ICLR '18)* (2018)

[Gómez-Bombarelli 16] Gómez-Bombarelli, R., Aguilera-Iparraguirre, J., Hirzel, T. D., Duvenaud, D., Maclaurin, D., Blood-Forsythe, M. A., Chae, H. S., Einzinger, M., Ha, D.-G., Wu, T., Markopoulos, G., Jeon, S., Kang, H., Miyazaki, H., Numata, M., Kim, S., Huang, W., Hong, S. I., Baldo, M., Adams, R. P., and Aspuru-Guzik, A.: Design of efficient molecular organic light-emitting diodes by a high-throughput virtual screening and experimental approach, *Nat Mater*, Vol. 15, No. 10, pp. 1120–1127 (2016)

[Gómez-Bombarelli 18] Gómez-Bombarelli, R., Wei, J. N., Duvenaud, D., Hernández-Lobato, J. M., Sánchez-Lengeling, B., Sheberla, D., Aguilera-Iparraguirre, J., Hirzel, T. D., Adams, R. P., and Aspuru-Guzik, A.: Automatic Chemical Design Using a Data-Driven Continuous Representation of Molecules, *ACS Central Science* (2018)

[Jin 18] Jin, W., Barzilay, R., and Jaakkola, T.: Junction Tree Variational Autoencoder for Molecular Graph Generation, Technical report, arXiv:1802.04364v1 [cs.LG] (2018)

[Jonyer 04] Jonyer, I., Holder, L. B., and Cook, D. J.: MDL-based context-free graph grammar induction and applications, *International Journal on Artificial Intelligence Tools*, Vol. 13, No. 1, pp. 65–79 (2004)

[Jorgensen 09] Jorgensen, W. L.: Efficient Drug Lead Discovery and Optimization, *Accounts of chemical research*, Vol. 42, No. 6, pp. 724–733 (2009)

[Kusner 17] Kusner, M. J., Paige, B., and Hernández-Lobato, J. M.: Grammar variational autoencoder, in *Proceedings of the 35th International Conference on Machine Learning (ICML '17)* (2017)

[Weininger 88] Weininger, D.: SMILES, a chemical language and information system. 1. Introduction to methodology and encoding rules, *Journal of Chemical Information and Computer Sciences*, Vol. 28, No. 1, pp. 31–36 (1988)

Oral presentation | Organized Session | [Organized Session] OS-12

[3F1-OS-12a] [Organized Session] OS-12

Thu. Jun 7, 2018 1:50 PM - 2:50 PM Room F (4F Garreria)

[3F1-OS-12a-01] PCSA: Probabilistic Causal Semantic Analysis

○Koji Nomori[1] （1. Analytics Design Lab Inc.）

1:50 PM - 2:10 PM

[3F1-OS-12a-02] Consideration of Visualizing Word Meanings in Word2Vec Space

○Yoshiyuki Mori[1], Yasufumi Takama[1] （1. Tokyo Metropolitan University）

2:10 PM - 2:30 PM

[3F1-OS-12a-03] Personality Estimation of Twitter Users by Using Deep Learning

○Yuki Wakamiya[1], Wataru Sunayama[2], Yuji Hatanaka[2], Kazunori Ogohara[2] （1. Graduate School of Engineering, The University of Shiga Prefecture, 2. School of Engineering, The University of Shiga Prefecture）

2:30 PM - 2:50 PM

©The Japanese Society for Artificial Intelligence

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

確率的因果意味解析（PCSA）
－テキストデータを用いたターゲット事象の要因トピックの抽出－

PCSA: Probabilistic Causal Semantic Analysis
Extracting Effective Topics of a Target Event Using Text Data

野守　耕爾[*1]
Koji Nomori

[*1] 株式会社アナリティクスデザインラボ
Analytics Design Lab Inc.

This study proposes a new method extracting topics from text data named PCSA (Probabilistic Causal Semantic Analysis). It enables to extract effective topics of a target event. This paper shows the effectiveness by applying the method to patent data.

1. はじめに

ビジネスにおけるアクションを検討するうえでターゲットとなる事象の要因を探ることは重要であり，例えば商品の顧客満足度の要因を探ることで新商品の企画や現商品のプロモーションを検討したり，店舗来店の要因を探ることで来店を促進する DM を検討したり，サービスの解約や会員退会の要因を探ることで顧客を維持する対応やサービスを検討することができる．

高次元なビッグデータから何かある事象の要因を探る場合，教師なし学習と教師あり学習を組み合わせる手段が有効となることがある．つまり多量な変数を類似したいくつかの特徴に教師なし学習で次元圧縮（グルーピング）し，それを説明変数として目的変数との関係を教師あり学習でモデル化するというアプローチである．従来よく用いられてきたものとして，主成分分析や因子分析をしてその因子を説明変数に回帰分析を実行する手法がある．例えばアンケートの多量な設問項目を因子分析でいくつかの因子にまとめ，顧客満足度などのターゲット設問とその因子との関係を回帰分析して顧客の価値観を理解し，マーケティングの検討に適用されるケースが挙げられる．近年急発展しているディープラーニングも教師なし学習と教師あり学習を組み合わせてモデル化するものである．ディープラーニングでは教師なし学習で特徴量（中間層）を抽出するが，教師あり学習でその特徴量を調整しながら，モデル全体を見直していく手法であり，識別精度を高めることに特化した特徴量が抽出される．

テキストデータの解析でも教師なし学習と教師あり学習を組み合わせることで，テキストデータに潜む要因関係をモデル化する手法が提案されている[野守 2014]．この手法ではテキストマイニングで抽出された単語群に確率的潜在意味解析（PLSA）を適用して教師なし学習によりトピックを抽出し，そのトピックを確率変数としてベイジアンネットワークを適用して教師あり学習によりモデルを構築している．例えば旅行の口コミデータに適用して口コミの評点とトピックとの関係をモデル化したり[野守 2016]，特許の要約文のデータに適用して，技術のトピックと用途のトピックとの関係をモデル化している[野守 2018]．

このように教師なし学習と教師あり学習を組み合わせることで，高次元なビッグデータでも，次元圧縮された特徴量の変数を用いてターゲット事象との関係をシンプルに理解することができる．しかし，このようなアプローチでは教師なし学習と教師あり学習はそれぞれ独立しており，まず教師なし学習を完了してからその結果を教師あり学習に引き継ぐものである．つまり教師なしで抽出された特徴量はどれもターゲット事象と強い関係を示すものではなく，教師あり学習によりその中から関係を示すものが有効な特徴量として選択される．こうした分析をビジネス業務で活用することを考えると，特にターゲット事象に影響を与える要因に集中して抽出することが望ましいとされることが考えられる．ディープラーニングでは先述の通り，教師なし学習と教師あり学習は独立しておらず，教師あり学習が教師なし学習に連携し，ターゲット事象を識別するのに適した特徴量が調整されるが，その特徴量は識別精度を高めることに特化して最適化計算されているため，人間にとって理解しにくいことが多く，しばしばブラックボックスと言われる．

本稿では，テキストデータの活用を想定して，ターゲット事象に影響を与えるトピックをテキストデータから抽出する手法を提案し，その適用事例を紹介する．

連絡先：野守耕爾，株式会社アナリティクスデザインラボ，
koji.nomori@analyticsdlab.co.jp

2. 確率的因果意味解析（PCSA）

本研究では，PLSAを応用し，テキストデータからあるターゲット事象に影響を与えるトピックに限定して抽出する手法を PCSA として提案する．（特許出願中，商標出願中）

2.1 確率的潜在意味解析（PLSA）

PLSA(Probabilistic Latent Semantic Analysis)は，文書分類のために開発された次元圧縮手法であり[Hofmann 1999]，トピックモデルと呼ばれる手法の一つである．文書 D とそこに出現する単語 W の間には潜在的な意味クラス C があることを想定し，各文書における単語の出現頻度が記録された「文書」×「単語」の共起行列データを学習し，文書と単語の共通トピックとなるような特徴を見つける手法である．PLSA の実行により 3 種類の確率変数 P(D|C), P(W|C), P(C)が計算され，これにより「文書」×「潜在クラス（トピック）」という低次元データに変換でき，クラスタリングの手法としても用いられる．

PLSA が他のクラスタリング手法と異なる特徴の一つは，行と列を同時にクラスタリングできることである．一般的なクラスタリング手法は，列をベースに行をクラスタリングする，あるいは行をベースに列をクラスタリングするため，どちらか一方しかクラスタリングできない．一方 PLSA で抽出される潜在クラスには，行の要素と列の要素が同時に所属することができる．

2.2 PLSA の共起行列構成の工夫

行と列を同時にクラスタリングできる PLSA では，行と列は双方が十分意味を持つ情報で構成すれば，抽出された潜在クラスの意味を行と列の 2 つの情報軸から解釈することができる．本来の PLSA の適用では，「文書」×「単語」という構成の共起行列をインプットとするが，この構成を工夫することで解釈のしやすい潜在クラス（トピック）を抽出する試みがある．

例えば，「品詞」×「品詞」の共起行列を用いる方法が提案されており，有用な知識が抽出されたことが報告されている[Kameya & Sato 2005][野守 2014]．また，全国の観光地の口コミから得られた「観光地」×「係り受け表現」の共起行列に PLSA を適用することで観光地のテーマを抽出している例もある[野守 2015]．共起行列の軸の一方を「係り受け表現」とすることで，文脈をイメージしやすくトピックの解釈がより容易になったとされており，「単語」×「係り受け表現」の共起行列に PLSA を適用した事例も報告されている[野守 2016] [野守 2018]．これにより単語と係り受けを同時にクラスタリングすることになるが，単語という話題の観点となる軸に基づいて，その観点の具体的な内容となる係り受け表現をグルーピングでき，より文脈上近しい言葉・表現でまとめられた解釈のしやすいトピックを潜在クラスとして抽出できるとされている．

2.3 PLSA の結果を用いた教師あり学習

筆者は，上記のようにテキストデータから PLSA の教師なし学習によって抽出されたトピックに対して，各データの該当有無を計算し，そのトピックを確率変数としてベイジアンネットワークを適用し，教師あり学習によってターゲット事象との関係をモデル化している．例えば温泉旅行の口コミデータから，口コミの満足度（評点）と関係のあるトピックを分析し，観光マーケティングへの応用を検討している[野守 2016]．この適用事例では，まず温泉旅行の口コミ全体で話題にされていることをトピックに集約し，その中から満足度と関係のあるトピックを探索している．しかしトピックは満足度と関係があることを前提に抽出されたものではなく，モデル構築の結果，満足度と関係のないトピックも多く抽出されている．マーケティングなどビジネス業務への応用を想定する場合，特に満足度に影響を与えるトピックに集中して抽出することが望ましいとされるケースが考えられる．

2.4 確率的因果意味解析（PCSA）の提案

本研究では，テキストデータからあるターゲット事象に影響を与えるトピックに限定して PLSA で抽出する手法を，確率的因果意味解析（PCSA: Probabilistic Causal Semantic Analysis）として提案する．

PCSA では，全データから構築した共起行列に対して，あるターゲット事象が起こるデータから構築した共起行列と，それが起こらないデータから構築した共起行列に分割し，その 2 つの共起行列の差分を計算した共起行列に対して PLSA を適用する．PCSA で適用する共起行列のイメージを図 1 に示す．

なお，ターゲット事象が起こるグループと起こらないグループではデータ件数の規模に差が出てしまうため，単純な差分ではなく，件数の少ないグループのデータ件数に合わせて，件数の多いグループの共起行列の各頻度をデータ件数の比率で重み調整する．データ件数の少ないグループに頻度を合わせる理由は，件数の多いグループに頻度を合わせてしまうと，件数の少ないグループの頻度が大きくなるわけだが，特に 1 件などの頻度の少ない共起ペアはたまたま 1 件出現したというケースが大いに考えられ，全体のデータ件数が多くなればその割合に応じて増加すると仮定することは現実と大きく乖離する懸念がある．共起行列では頻度 1 件の共起ペアは最も多く，これがデータ規模に応じて全て同じ割合で増加することの影響は大きいと考えられる．一方，データ件数の多いグループはそのデータ規模でその頻度の共起ペアが存在したことは事実であり，データ件数の少ないグループに合わせて重み調整することでその頻度は小さくなるが，0 件（存在しない）になることはなく，件数の少ないグループの頻度を大きくすることよりも現実的と考えられる．また，2 つの共起行列の差分については，負数とならないようにここでは差の絶対値を取ることにする．

このように設定された共起行列では，ターゲット事象の発生有無に関係する共起ペアは頻度が大きくなり，そうでない共起ペアでは頻度が小さくなるため，この共起行列に PLSA を適用することでターゲット事象の発生有無に影響を与える潜在トピックが優先的に抽出されることが期待される．

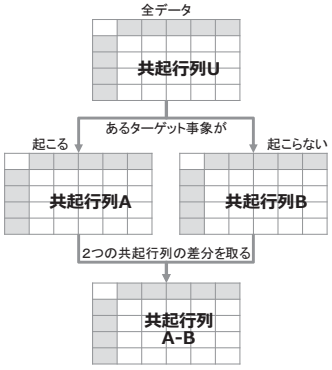


図 1 PCSA で適用する共起行列のイメージ

3. PCSA の適用事例

本稿では PCSA の適用事例として，特許の要約文のテキストデータに適用し，出願が近年上昇傾向，あるいは下降傾向にある技術トピックを抽出した分析結果を紹介する．

3.1 分析データ

特許の要約文と請求項に「風」「空気」を含む 10 年分（出願日が 2006 年 1 月 1 日～2015 年 12 月 31 日）の特許公報 30,039 件を用意し，特にその要約文で「解決手段」に関する項目で記述された文章のデータを分析対象とした．

3.2 PLSA を適用した結果

筆者は本データに対し，「単語」×「係り受け表現」という構成の共起行列を構築し，それに PLSA を適用することで潜在的な技術トピックを抽出し，出願年を軸としたそのトピックのトレンドを分析している[野守 2018]．本節ではその結果の概要を紹介し，次節で PCSA を適用した結果を紹介し，それらを比較する．

3.2.1 抽出されたトピック

まず分析データにテキストマイニングを適用し，単語とその文法的なペアとなる係り受けを抽出した．抽出結果のうち頻度 10 件以上を対象とし，単語（5,187 語）×係り受け（7,174 表現）の共起行列を作成した．各共起ペアの出現を集計する単位は特許単位ではなく文章単位（句点で区切られた文章単位）とした．

この共起行列に PLSA を適用して技術に関するトピックを抽出した．なお PLSA は予めトピック数を設定する必要があり，また初期値により解が異なる特性がある．そこでトピック数を 1 刻みで変化させ，それぞれのトピック数に対して PLSA を初期値を変えて 5 回ずつ実行し，それぞれの解を情報量基準 AIC で評価して最も評価の良い解を採用した．その結果，最も評価の良い解として 47 個のトピックが得られた．

PLSA のアウトプットは，①トピック T における行要素（単語 W）の所属確率 P(W|T)，②トピック T における列要素（係り受け E）の所属確率 P(E|T)，③トピック T の存在確率 P(T)，という 3 つの確率が計算される．特に各トピックにおいて①②の確率の高い単語，係り受けを確認し，そのトピックの意味を解釈していく．抽出されたトピックの内容例を表 1 に示す．トピック t25（表 1 左）では，単語は，水，供給，加湿装置，加湿などが，係り受けは，水の供給，供給される水，空気の加湿などが関係しているので，この結果は加湿に関するトピックであると解釈できる．トピック t32（表 1 右）では，単語は，送風機，塵埃，掃除機，分離，吸い込む，集塵部などが，係り受けは，塵埃の分離，分離する塵埃，塵埃を含む，吸い込む塵埃などが関係しているので，この結果は塵埃の分離に関するトピックであると解釈できる．このように解釈をつけた 47 個のトピックの一覧を表 2 に示す．

表 1　PLSA で抽出されたトピックの内容例

トピックt25			
確率	単語	確率	係り受け
8.5%	水	2.4%	水-供給
2.6%	供給	1.3%	供給-水
2.6%	加湿装置	1.3%	空気-加湿
2.3%	加湿	0.9%	吹出口-連通
1.8%	加湿フィルタ	0.9%	空気-通過
1.7%	水槽	0.9%	連通-空気風路
…	…	…	…

トピックt32			
確率	単語	確率	係り受け
5.5%	送風機	2.1%	塵埃-分離
5.2%	塵埃	1.7%	分離-塵埃
4.1%	掃除機	1.7%	塵埃-含む
3.6%	分離	1.5%	吸い込む-塵埃
3.5%	吸い込む	1.3%	含む-空気
2.3%	集塵部	1.0%	空気-分離
…	…	…	…

表 2　PLSA で抽出された 47 個のトピック一覧

No.	トピック名	No.	トピック名
t01	冷凍サイクル	t25	加湿
t02	冷却	t26	放電式ミスト生成
t03	車室内空調	t27	微細粒子の飛散（マイナスイオン等）
t04	空気路	t28	イオン発生・空気除菌・脱臭
t05	換気	t29	電解水生成と除菌
t06	排気	t30	空気浄化＆効率性
t07	空気の吸込と吹出	t31	塵埃除去
t08	流体の流入と吐出	t32	塵埃分離
t09	空気流の利用と制御	t33	回転駆動
t10	送風	t34	電源と駆動制御
t11	空気の噴出	t35	運転と停止の制御
t12	送風搬送（紙葉類等）	t36	センサと制御（温度や風量等）
t13	印刷	t37	人検出
t14	光の利用（照射、発光等）	t38	風向制御
t15	ファンと機器冷却	t39	抑制・防止（騒音やコスト等）
t16	空気導入と車両エンジンの冷却	t40	構成・取り付け
t17	放熱	t41	接続
t18	除湿	t42	機器（熱交換器等）の配置
t19	乾燥機能	t43	配置と形成
t20	洗濯乾燥	t44	位置・形状・大きさ
t21	洗浄（衣類や食器等）	t45	位置の方向
t22	燃焼	t46	方法・装置
t23	加熱	t47	その他（発明目的、ケース構成等）
t24	温湿度制御と空気循環		

3.2.2 トピックのスコア計算

全特許データに対して各トピックのスコア（該当度）を計算した．1 件の特許は複数の文章で構成されているため，まず文章単位に各トピックのスコアを計算し，それを特許単位に集約した．文章 S_h におけるトピック T_k のスコアは $P(S_h|T_k)/P(S_h)$ で定義した．これはトピックを条件とすることで文章の発生確率が何倍になるのかを示し，そのトピックをよく話題にしている文章ほど高くなる．以下，$P(S_h|T_k)$ と $P(S_h)$ の計算について説明する．

$P(S_h|T_k)$については，文章 S_h を単語で定義される文章 Sw_h と係り受けで定義される文章 Se_h に分解し，それぞれについて $P(Sw_h|T_k)$と $P(Se_h|T_k)$を計算し，それらを一つに統合して $P(S_h|T_k)$を計算する．$P(Sw_h|T_k)$と $P(Se_h|T_k)$は式(1)(2)で計算される．単語 W_i と係り受け E_j が含まれる文章の数をそれぞれ $n(W_i)$ と $n(E_j)$とすると，$P(Sw_h|W_i)$は $n(W_i)$の逆数，$P(Se_h|E_j)$は $n(E_j)$の逆数として計算される．$P(W_i|T_k)$と $P(E_j|T_k)$はそれぞれ PLSA の実行結果によって得られている．$P(S_h|T_k)$は式(3)で計算され，$P(S_h|Sw_h)$と $P(S_h|Se_h)$は文章 S_h において重みは同じであるためそれぞれ 0.5 とする．$P(S_h)$は式(4)で計算され，$P(T_k)$は PLSA の実行によって得られている．

$$P(Sw_h|T_k) = \sum_i P(Sw_h|W_i)P(W_i|T_k) \quad (1)$$

$$P(Se_h|T_k) = \sum_j P(Se_h|E_j)P(E_j|T_k) \quad (2)$$

$$P(S_h|T_k) = P(S_h|Sw_h)P(Sw_h|T_k) + P(S_h|Se_h)P(Se_h|T_k) \quad (3)$$

$$P(S_h) = \sum_k P(S_h|T_k)P(T_k) \quad (4)$$

以上から$P(S_h|T_k)/P(S_h)$で定義されるスコアを文章単位に計算し，それを特許単位に見たとき，各トピックのスコアの最大値をその特許のトピックスコアとして採用した．さらにこのスコアの閾値として 3 を設定し，各特許データに対してそのトピックの該当有無を示す 0,1 のフラグ情報を付与した．$P(S_h|T_k)/P(S_h)$で定義したスコアは 1 を基準と考えることができるが，各トピックの特徴をより濃く抽出するため，このスコアの分布や実際の文章内容も確認しながら妥当性を検討し，基準の 3 倍と厳しく設定した．

3.2.3 トピックのトレンド分析

特許データの出願年の情報と，各トピックのフラグ情報から，トピックのトレンドを分析した．具体的には出願年 Y とトピック T の関連度を示す指標値として P(Y|T=1)/P(Y)を計算し，この値の出願年変化を集計した．本節では 2013 年を境に，2012 年までのデータ（22,387 件）で計算される指標値と 2013 年からのデータ（7,652 件）で計算される指標値の増減率を計算した結果を紹介する．全 47 個のトピックの増減率の一覧について，増加率の高いものから順に表 3 に示す．表 3 より抽出されたトピックは増減率の高いものから低いものまでばらついていることがわかる．

表 3　47 個のトピックの 2013 年前後における指標値の増減率

増減率	トピック名	増減率	トピック名
19.3%	t44.位置・形状・大きさ	0.0%	t06.排気
17.3%	t09.空気流の利用と制御	−1.1%	t46.方法・装置
16.1%	t43.配置と形成	−1.3%	t22.燃焼
15.0%	t36.センサと制御（温度や風量等）	−1.6%	t23.加熱
14.0%	t38.風向制御	−2.2%	t02.冷却
13.5%	t16.空気導入と車両エンジンの冷却	−2.3%	t47.その他（発明目的、ケース構成等）
12.9%	t14.光の利用（照射、発光等）	−3.8%	t21.洗浄（衣類や食器等）
12.2%	t45.位置の方向	−4.4%	t13.印刷
11.3%	t10.送風	−4.8%	t05.換気
10.6%	t03.車室内空調	−5.0%	t15.ファンと機器冷却
9.6%	t37.人検出	−6.4%	t12.送風搬送（紙葉類等）
8.9%	t41.接続	−7.3%	t29.電解水生成と除菌
7.9%	t40.構成・取り付け	−9.8%	t32.塵埃分離
7.4%	t07.空気の吸込と吹出	−9.9%	t27.微細粒子の飛散（マイナスイオン等）
6.5%	t33.回転駆動	−15.5%	t24.温湿度制御と空気循環
6.3%	t34.電源と駆動制御	−15.7%	t30.空気浄化＆効率性
3.9%	t04.空気路	−17.9%	t20.洗濯乾燥
3.7%	t17.放熱	−19.5%	t31.塵埃除去
3.3%	t01.冷凍サイクル	−20.7%	t28.イオン発生・空気除菌・脱臭
3.1%	t08.流体の流入と吐出	−21.3%	t39.抑制・防止（騒音やコスト等）
2.5%	t25.加湿	−22.0%	t19.乾燥機能
1.9%	t11.空気の噴出	−24.0%	t18.除湿
0.8%	t35.運転と停止の制御	−27.4%	t26.放電式ミスト生成
0.4%	t42.機器（熱交換器等）の配置		

3.3 PCSA を適用した結果

本節では，3.2 で紹介した PLSA の適用事例と同一のデータで PCSA を適用した分析結果を示す．ここでの PCSA におけるターゲット事象とは，2013 年以降の特許であるかどうかとし，2013 年前後で上昇傾向にある技術，あるいは下降傾向にある技術に集中してトピックを抽出する．

3.3.1 抽出されたトピック

3.2 の分析事例と同様に，共起行列の構成は単語（5,187 語）×係り受け（7,174 表現）とし，2012 年までのデータ（22,387 件）と2013 年からのデータ（7,652 件）でそれぞれ共起行列を作成した．共起行列の各頻度は文章単位で集計しているが，その文章数は 2012 年までのデータで 33,283 件，2013 年からのデータで 11,831 件あり，2012 年までのデータの共起行列の各頻度を文章数の比率で重み調整した（全ての頻度に 11,831/33,283 を乗した）．この 2 つの共起行列の差の絶対値を計算した共起行列を作成し，これに PLSA を適用した．

3.2 の分析事例と同様に，トピック数を 1 刻みで変化させ，それぞれのトピック数に対して PLSA を初期値を変えて 5 回ずつ実行し，それぞれの解を情報量基準 AIC で評価して最も評価の良い解を採用した結果，14 個のトピックが得られた．抽出されたトピックの内容例を表 4 に示す．所属確率の高い単語と係り受けから，トピック T10（表 4 左）は塵埃の分離に関するトピック，トピック T13（表 4 右）は車両用空調の配置に関するトピックであると解釈できる．トピック T10 は 3.2 の分析事例で抽出されたトピック t32 におおよそ対応するものと思われる．このように解釈をつけた 14 個のトピックの一覧を表 5 に示す．

表 4　PCSA で抽出されたトピックの内容の例

トピックT10			
確率	単語	確率	係り受け
3.4%	塵埃	0.9%	付着-塵埃
1.8%	送風機	0.8%	塵埃-除去
1.7%	掃除機	0.8%	吸い込む-塵埃
1.6%	吸い込む	0.7%	塵埃-含む
1.3%	分離	0.7%	塵埃-吸い込む
1.3%	フィルタ	0.7%	塵埃-分離
1.3%	捕集	0.6%	発生-送風機
1.0%	集塵部	0.6%	含む-空気
…	…	…	…

トピックT13			
確率	単語	確率	係り受け
1.5%	配置	0.5%	流れる-空気
1.1%	流れる	0.4%	空気-流す
1.0%	向ける	0.4%	備える-車両用空調装置
1.0%	下流	0.3%	空気-送風
1.0%	車両用空調装置	0.3%	下流-配置
0.9%	方向	0.3%	通過-空気
0.9%	車室内	0.3%	前方-配置
0.9%	車両	0.3%	方向-沿う
…	…	…	…

表 5　PCSA で抽出された 14 個のトピック一覧

No.	トピック名	No.	トピック名
T01	冷凍サイクル	T08	イオン発生
T02	空気の冷却	T09	電解水の生成
T03	冷却ファン	T10	塵埃の分離
T04	空気流（吸込と吹出）	T11	羽の回転
T05	紙葉類の搬送	T12	検出と制御
T06	衣類乾燥	T13	車両用空調の配置
T07	空気の燃焼	T14	配置と形成

3.3.2 トピックのトレンド分析

3.2 の分析事例と同様に，全特許データに対して，抽出された各トピックのスコア（該当度）を計算し，スコアの閾値を 3 に設定して，トピックの該当有無を示す 0,1 のフラグ情報を付与した．そして出願年 Y とトピック T の関連度を示す指標値として P(Y|T=1)/P(Y)を採用し，出願年を 2012 年までとした指標値と，2013 年以降とした指標値を計算し，2013 年前後におけるこの値の増減率を集計した．全 14 個のトピックの増減率の一覧について，増加率の高いものから順に表 6 に示す．表 6 を表 3 と比較すると，抽出されたトピックはその多くが増減率の高いものと低いものに集中していることが分かる．また，上記指標値を各出願年において計算し，表 6 で増減率が上位 5 位のトピックと下位 5 位のトピックについて，その経年変化を可視化したものをそれぞれ図 2,3 に示す．今回は 2013 年前後の出願件数に影響を与えるトピックを抽出したが，図 2,3 より全体的に上昇トレンド，下降トレンドにあるトピックが抽出されていることが分かる．

表 6　14 個のトピックの 2013 年前後における指標値の増減率

増減率	トピック名	増減率	トピック名
48.5%	T13.車両用空調の配置	7.0%	T01.冷凍サイクル
30.3%	T14.配置と形成	−0.3%	T05.紙葉類の搬送
23.9%	T04.空気流（吸込と吹出）	−5.9%	T07.空気の燃焼
17.7%	T12.検出と制御	−8.8%	T09.電解水の生成
14.9%	T11.羽の回転	−17.0%	T10.塵埃の分離
13.1%	T03.冷却ファン	−24.2%	T06.衣類乾燥
11.6%	T02.空気の冷却	−28.7%	T08.イオン発生

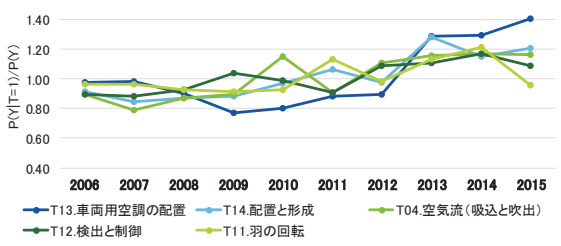


図 2　2013 年前後で増減率上位 5 位のトピックのトレンド

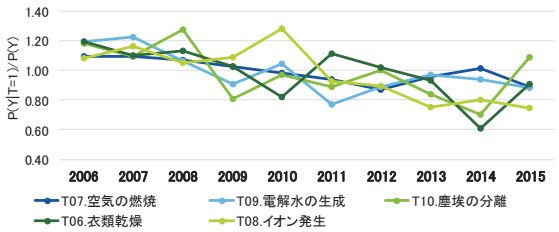


図 3　2013 年前後で増減率下位 5 位のトピックのトレンド

4.　まとめ

本研究では，テキストデータからあるターゲット事象に影響を与えるトピックに限定して PLSA で抽出する手法を，確率的因果意味解析（PCSA）として提案し，同じデータで同じ共起行列の条件のもと，これまでの PLSA を適用した結果と PCSA を適用した結果を示し比較した．その結果，PCSA を適用すると，特にターゲット事象（2013 年前後における特許の出願傾向）に影響を与えるトピックが集中的に抽出されていた．

本手法は様々なテキストデータに適用可能であり，例えば，口コミデータに適用して口コミ評点に影響するトピックを抽出することで満足度を高める商品・サービスを検討たり，コールセンターの問い合わせ履歴に適用し，そのデータに苦情の程度や解約有無などの情報があれば，その要因となる問い合わせトピックを抽出することで，サービスの改善を検討したり，営業マンの日報データに適用して成約に影響する活動のトピックを抽出することで，営業マンの教育に活用することもできる．また，今回の特許データにおいても，例えば調査会社が提供している特許の注目度を示す指標に影響する出願内容のトピックを抽出し，良い特許の要因を探ることも適用アイデアとして考えられる．

このように PCSA はテキストデータに潜む要因関係を顕在化することができる．特にターゲット事象に影響を与える要因を集中的に抽出することができ，効果的なビジネスアクションの検討に有用な知識を提供することが期待できる．

参考文献

[野守　2014] 野守耕爾，神津友武: 三位一体アプローチによるテキストデータモデリング法の開発―宿泊施設の口コミデータを用いた評価推論モデルの構築―，2014 年度人工知能学会全国大会論文集，2014.

[野守　2015] 野守耕爾，神津友武: 口コミデータに PLSA を適用した観光客目線による観光地分析，2015 年度人工知能学会全国大会論文集，2015.

[野守　2016] 野守耕爾，神津友武:口コミビッグデータに人工知能を応用した地域観光の次世代マーケティング―観光客の声に基づいた温泉地の特徴と観光客の価値観の確率モデリング―，2016 年度人工知能学会全国大会論文集，2016.

[野守　2018] 野守耕爾: 人工知能技術を応用した特許文書分析が生み出す新たな技術戦略の検討，経営情報学会 2018 年春季全国研究発表大会要旨集，2018.

[Hofman　1999] Hofmann, T.: Probabilistic latent semantic analysis, Proc. of Uncertainty in Artificial Intelligence, pp. 289-296, 1999.

[Kameya & Sato　2005] Kameya, Y., & Sato, T.: Computation of probabilistic relationship between concepts and their attributes using a statistical analysis of Japanese corpora, Proceedings of Symposium on Large-scale Knowledge Resources, 65-68, 2005.

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

Word2Vec で表現された単語の意味の可視化に関する検討

Consideration of Visualizing Word Meanings in Word2Vec Space

森 祥恭 Yoshiyuki Mori　　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

This paper investigates the meaning of words acquired by Word2Vec using visualization. Word embedding such as Word2Vec has been popular in different kinds of applications using text data. Word embedding represents words in a corpus as vectors, based on which calculation in terms of those meanings is possible. However, it is difficult to interpret dimensions of a vector space. In order to investigate word categories of which meaning is obtained by Word2Vec, and dimensions corresponding to the meaning, this paper examines the variance of word vectors belonging to a word category, and visualizes word vectors using PCA-based scatter plot and radar chart.

1. はじめに

近年，自然言語処理の分野で単語の分散表現を学習する手法が注目を集めている．単語の分散表現は，大規模なテキストコーパスを利用して学習することにより獲得され，コーパスに出現する単語をベクトルで表現することができる．これを利用した研究や様々な応用が試みられている．

分散表現の特徴の一つとして，単語間のベクトル演算を行うことで国と首都や男性と女性といった，単語間の意味的な関係を求めることができる．また，学習した単語ベクトルにコサイン類似度を利用することで，単語同士の類似度を求めることもできる．しかし，単語の分散表現で生成された空間が高次元であること，および各次元の意味が自明でないため解釈が困難といった問題がある．どの様な意味が獲得されているか，ベクトル空間のどの次元が意味の表現に関係しているかなどが確認可能となれば，分散表現を利用した学習結果や分析結果の理解に貢献すると考える．

本稿では，Word2Vec により得られた単語の分散表現が持つ，単語の意味や単語間の関係を情報可視化手法を用いて分析することを目的とする．WordNet の単語カテゴリを利用した分析結果により，所属する単語に対応したベクトルの分散が小さいカテゴリが存在することや，特定のカテゴリと関係の強い次元が存在することを示す．

2. 関連研究

2.1 単語の分散表現

単語の分散表現とは，各単語を高次元の実数ベクトルで表現したものであり，大規模テキストコーパスを利用して求められる．

Word2Vec は 2 層からなるニューラルネットワークを用いて単語の分散表現を学習する手法である．学習する方法として CBoW(Countinues Bag-of-Words)モデル[2][3]と Skip-gram モデル[1][2]の二つのモデルが提案されている．CBoW モデルはテキスト内の周辺にある単語を利用して対象となる単語を予測し，単語の分散表現を学習する．Skip-gram モデルは CBoW モデルとは逆に，ある単語が与えられた時に，その周辺の単語を予測し，単語の分散表現を学習する．Word2Vec ではベクトルの演算を行うことで，単語間の意味的な関係を求めることが可能である．例えば，フランスのベクトルからパリのベクトルを引いた結果に東京のベクトルを加えると，日本のベクトルに近くなることなどが知られている．

2.2 高次元データの可視化手法

高次元を対象とした可視化手法の代表的なものに，PCA（主成分分析）などの次元圧縮による可視化手法や，平行座標などのように次元圧縮を行わない可視化手法が存在する．次元圧縮による可視化手法は 2 次元空間などの低次元空間に高次元空間を写像する．平行座標による可視化では，各次元をそれぞれ直交する軸として平行に並べ，各データを一つの線グラフとして描画する．これにより，高次元データの情報を損なわずに，次元間の関係の解釈が可能になる．

3. 提案手法

3.1 学習データ

本稿では，Word2Vec で求めた分散表現において，ある単語カテゴリの意味やカテゴリ間の関係が獲得されているか分析する．Word2vec の学習には，英語版 Wikipedia のオリジナルのテキストデータに前処理を施した text8[1]を利用する．このデータセットの単語総数は 253,854 単語である．

英語の概念辞書である WordNet[2]を利用する．WordNet では単語が同義語のグループごとに分けられ，定義や他の同義語のグループとの関係が記述されている．本稿では WordNet における反意語と同義語を利用して単語のカテゴリ分けを行う．

3.2 単語ベクトルの分散による分析

WordNet を利用して学習データに存在する単語をカテゴリに分類し，カテゴリごとに所属する単語の重心ベクトルを求める．重心ベクトルと各単語との距離から分散を求めることにより，カテゴリに属している単語が高次元空間において互いに近い位置に存在しているのか，遠い位置に存在しているのかを判断する．

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

[1] http://mattmahoney.net/dc/text8.zip -O text8.gz

[2] https://wordnet.princeton.edu/

分散が小さい場合，当該カテゴリの意味が分散表現により獲得されていると仮定する．

3.3 次元圧縮による単語ベクトルの可視化

Word2Vec で得られたベクトル空間に PCA を適用し，2 次元空間に可視化する．3.2 節で求めた分散が小さいカテゴリに属する単語や，関係のある 2 カテゴリにそれぞれ属する単語間の関係を 2 次元空間で可視化することで，カテゴリの意味やカテゴリ間の関係を視覚的に確認する．

3.4 単語カテゴリ特有の次元の分析

分散表現によりその意味が獲得されたと判断した単語カテゴリやカテゴリ間の関係について，その意味と関連する単語ベクトルの次元について考察する．同じカテゴリに属する単語ベクトル，あるいは単語間の演算により得られたベクトルの要素が特定の次元に集中しているかを確認するために，要素値の平均値，分散に基づき分析を行うほか，平行座標やレーダーチャートなどにより視覚的に確認する．

4. 分析結果

単語の分散表現として，Word2Vec を以下の条件で学習したものを使用した．

- 単語ベクトルの次元数：200
- テキストコーパス内での出現回数が 5 回未満の単語を無視
- 予測する単語の前後 5 単語を学習に使用
- 学習モデル：CBoW

WordNet で分類した各カテゴリ内に存在する単語ベクトルの分散を表 1 に示す．各行に，意味的な関係を持つカテゴリの分散，両カテゴリでの対応関係にある単語ベクトルの差について求めた分散を示す．全単語から求めた分散は 9.713 であり，国，首都，原作者，文章，善はこれよりも分散が小さいことがわかる．分散が小さいカテゴリは，単語間の意味的なまとまりが強いと考えられる． また，差についてはどの対も分散が小さくなっていることがわかる．

表 1:分類したカテゴリとカテゴリ内の分散

カテゴリ名	分散	カテゴリ名	分散	差の分散
国	7.829	首都	6.458	6.782
男性	17.83	女性	14.58	3.297
始まり	14.46	終わり	11.36	4.385
原作者	9.157	文章	5.546	6.303
善	8.658	悪	13.15	3.093



図 1:「女性-男性」ベクトルの PCA による可視化

男性及び女性カテゴリに属する単語について，それぞれ対応関係にある単語の差を PCA により可視化した結果を図 1 に示す．図において，すべての単語のペアについて男性の単語が同じ位置に来るように平行移動している．単語間の対応関係は， WordNet の反意語に基づき判断している．“Female”と“Girl”を除いて男性と女性の位置関係が似た傾きで存在していることがわかる．

男性と女性カテゴリの単語集合の重心ベクトルそれぞれについて，その絶対値が大きい 10 次元を求めた結果を表 2 に示す．表に示す数値は次元の ID であり，同じ値は同じ次元に対応する．男性-女性は，関係のある単語同士で求めた差ベクトルの重心から求めたものである．男性，女性カテゴリにおいて，8 次元が一致しており，性別に関係すると考察できる．また，女性の重心ベクトルのみに存在している 2 次元（ID:189, ID:23）が男性-女性の上位 10 次元内に存在しており，女性としての意味が強い次元と考察できる．男性と女性に共通して存在する次元のうち，ID:94 が男性-女性の次元にも存在しており，男性と女性の違いを反映していると考察できる．

表 2:重心ベクトルの絶対値が大きい 10 次元

順位	1	2	3	4	5
男性	**62**	**97**	**83**	81	**44**
女性	**94**	**62**	**44**	**83**	**97**
男性-女性	**189**	86	197	**94**	123

順位	6	7	8	9	10
男性	110	**94**	**147**	**33**	**98**
女性	**189**	**147**	**98**	**33**	**23**
男性-女性	**23**	152	173	165	120

5. おわりに

本稿では，単語の分散表現を学習する手法である Word2Vec により得られた，単語の意味や単語間の関係について分析を行った．同一カテゴリに属する単語ベクトルの分散を求めることで，カテゴリに属する単語の意味的なまとまりを分析した．また，各カテゴリの意味を表現する特有の次元が存在することも示した．

今後は，より多くのカテゴリに関して同様に分析し，分散表現で獲得された意味や関係の理解を深めていくことで，単語の意味を利用する各種応用に貢献すると考える．また，学習に用いるデータや学習モデルの違いが，獲得される意味などに与える影響を分析することも有用と考える．

参考文献

[Mikolov 2013] T. Mikolov, I. Sutskever, K. Chen, G. Corrado, J. Dean: Distributed Representations of Words and Phrases and their Compositionality, NIPS2013, pp.3111-3119, 2013.

[Mikolov 2013] T. Mikolov, K. Chen, G. Corrado, J. Dean: Efficient Estimation of Word Representations in Vector Space, ICLR2013, 2013.

[Le 2014] Q. Le, T. Mikolov: Distributed Representations of Sentences and Documents, ICML2014, pp.1188-1196, 2014.

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

深層学習を用いたTwitterユーザの性格推定

Personality Estimation of Twitter Users by Using Deep Learning

若宮 悠希 *1 Yuki Wakamiya　砂山 渡 *2 Wataru Sunayama　畑中 裕司 *2 Yuji Hatanaka　小郷原 一智 *2 Kazunori Ogohara

*1滋賀県立大学大学院工学研究科 Graduate School of Engineering, The University of Shiga Prefecture

*2滋賀県立大学工学部 School of Engineering, The University of Shiga Prefecture

In recent years, SNS has become widespread and it has become possible to exchange easily with various people through a network.In order to carry out smooth exchange it is necessary to understand the person ' s character, but only the sentence on SNS Since it is difficult to understand sufficiently, it is easier to understand the exchange partner by estimating the character of the author from the characteristics of the sentence.In this research, for a Twitter user, a set of sentences posted on Twitter to estimate personality by deep learning and to present the estimation results to users.

We constructed a classification network by deep learning for each of a plurality of elements of human character and developed an estimation system.As a result of evaluating based on correct answer data created by cooperation of plural people, High conformity rate, recall rate, and sufficient validity could be confirmed.

1. はじめに

近年，Twitter や facebook といったソーシャル・ネットワーキング・サービス (SNS) が広く普及している．これによって近しい周囲の人間にとどまらず，距離に縛られない広い範囲の人間と交流を気軽に行うことができるようになった．

しかし，SNS を利用するユーザはそれぞれが違う性格や考え方を持つため，交流を行うとき，相手の持つ性格や考え方を受け入れられるかどうかが重要となる．そのため，相手の性格を十分に理解することが求められるが，交流を初めてもった人物の性格をすぐに理解することは難しい．また，SNS 上で交流を行う際には，画像や音声などの手段を除けば，文章でのやり取りで行われる．

よって，交流相手の性格を知るためには，表情や仕種といった情報に頼らず，相手が書いた文章のみから理解しなければならない．そのため，文章の特徴を分析し，自動的に著者の性格を推定し，提示することができれば，推定結果を足がかりにして，より簡単に交流相手を理解することができると考えられる．

容易に性格を推定できるようになることで，SNS 上でこれまで交流を持ったことのない人物からのアプローチを受けた場合に，相手の性格は自分と相性が良いか，衝突をする危険がないかを事前に察知することができる．また，自分の文章を対象とすることで容易に自分の性格を振り返ることができ，交流を行う上で自分に何が足りないかを客観的に分析することができるなど，数多くの利点がある．

そこで本研究では，ユーザ間交流が盛んに行われている SNS の一つである Twitter を対象に，ユーザの投稿した文章である Tweet 集合の特徴から，交流の際にユーザがどのような性格を持っており，交流相手にどのような印象で受け取られるのかを深層学習を用いて推定する．性格推定の結果を可視化し，利用者に提示するシステムを構築することを目的とする．

連絡先: 若宮悠希，滋賀県立大学大学院工学研究科電子システム工学専攻，〒 522-8533 滋賀県彦根市八坂町 2500, of23ywakamiya@ec．usp．ac．jp

2. 関連研究

2.1 性格の自動推定に関する研究

個人の日記や交流の記録から，その個人の経験や感情の記録を振り返り性格を明らかにする研究は，既に盛んに行われている．これまでに Blog 記事からの推定を試みた研究 [南川 10] と，Twitter に投稿された各ユーザのコメントである Tweet からの推定を試みた研究 [岡本 14][那須川 16] が行われている．これらの研究は，より多様な性格に対して多くの正解を自動的に集めて深層学習に適用できる形式ではない．

そこで本研究では, 自動的に有効な正解を集めて性格を推定するシステムを構築することで，複数の視点からの性格推定を容易にすることを目指す．

2.2 SNS を利用した個人情報の抽出に関する研究

SNS を利用するユーザの, 性別や年代, 出身地などの個人情報を抽出し, 活用する研究が行われている．これまでに，Twitter ユーザを対象として, 各ユーザの家族構成や所有物, 趣味嗜好などを抽出することでプロフィールを推定する研究 [馬縲 14][那須川 13] が行われている．これらの研究では一人称所有格の後に現れる名詞が, その個人の所有物と仮定したり，「ギター」を所有する人物は「音楽」に興味があるといった，文章中に含まれる単語により個人の情報を抽出していた．

そこで本研究では，文章から受ける性格の印象に対応して，文章中に現れやすい単語が変化すると仮定し，対象の単語が含まれる文章の人間では気づきにくい他の特徴を深層学習によって導き出すことで性格を推定する．

2.3 性格と言葉の関連を調査した研究

性格と言葉などの言語的特徴に関連があることを調査した研究が行われている．これまでにも, 家電機器に搭載された音声インタフェースによるアドバイスを, システム利用者の性格に対応して適した文章を選択する研究 [長光 07] が行われている．この研究では性格ごとに対応を変えることによってシステムへの好感度向上が実現できることを示している．

そこで本研究では, 推定対象の交流相手がどのような性格を持っているのかを，推定結果を可視化して提示することで交流の支援を行う．

表 1: エゴグラムの 5 つの自我状態とその特徴

自我状態	特徴
CP(批判的な親)	規則を守り，間違いなどを批判する
NP(養育的な親)	他人に対して寛容で，人と関わりを持とうとする
A(大人)	理性的で計画を立てて行動する
FC(自由な子供)	喜怒哀楽の感情を素直に表す，好奇心が強い
AC(順応的子供)	協調性が高く，行儀良く振舞う

表 2: 推定対象の性格要素

性格要素	定義
几帳面さ	きちんとした書き方をするか
外交性	他者と積極的に関わりを持とうとするか
論理性	論理的に話そうとするか
感情表現	感情を表に出すか
礼儀正しさ	丁寧な言葉を使うか

3. 深層学習による性格推定システム

3.1 性格の分類と推定する性格の選定

人間がそれぞれ有する性格は,「怖いけど面倒見がいい人」,「やさしいけど内気な人」などのように，複数の要素が複雑に重なり合うことで構成されている．

よって本研究では性格推定を,「怖い」や「やさしい」などの性格を構成する複数の要素ごとに分けて行うことで，それぞれのバランスにより個人の性格をより多角的な視点で推定する．これら性格の構成要素を本稿では「性格要素」と定義する．性格推定を行うにあたり可能な限り多くの性格要素を推定することが求められるが，性格の側面として定義されたものは無数に存在する．そのため性格要素の中からより性格推定に適したものを選択するための指標を用意することで，推定する性格要素を選択する．

性格推定の対象とする性格要素を選択する際に用いた指標として，エゴグラム [新里 86] を利用する．エゴグラムとは，心理療法に用いられる理論である交流分析から発展した考え方であり，人間の行動を 5 つの自我の状態に分類することで，個人の人格を表現するモデルである．エゴグラムでは，人間の自我は 5 つの自我状態により構成される．ここでエゴグラムの 5 つの自我状態とその特徴を表 1 に示す．

本研究では，エゴグラムの 5 つの自我状態の特徴から，それぞれの自我状態に当てはめられると考えられる性格要素を選択し，推定対象の性格要素を表 2 に定義した．これら 5 つの性格要素について，文章の読み手からどういった印象をもたれるのかを，対象の個人に対し推定を行う．

3.2 システムの構成

本研究で提案する深層学習を用いた性格推定システムの構成を図 1 に示す．

まず，あらかじめ深層学習を用いて構築した，それぞれの性格要素の性格推定ネットワークを元に推定対象の Twitter ユーザの Tweet 集合を分類，各性格要素が強く含まれているかどうかを推定する．この推定結果を可視化インタフェースを利用してグラフ化し，提示することで，システム利用者が結果を解釈する支援とする．

3.3 深層学習による性格推定ネットワークの学習

本研究では，各性格要素の強さを推定するために，深層学習による性格推定ネットワークを構築，これを元に対象の文章を分類していく．

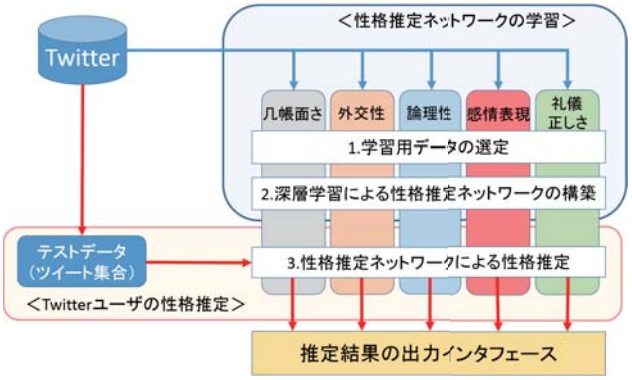


図 1: 深層学習を用いた性格推定システムの構成

表 3: 性格要素が強く現れる文章の特徴

性格要素	特徴
几帳面さ	句読点「、」「。」
外交性	他者へのメッセージ「リプライ」
論理性	接続詞
感情表現	感情を表す言葉 (「嬉しい」「悲しい」等 20 単語)
礼儀正しさ	丁寧語の語尾「です」「ます」の活用形

深層学習とは，機械学習の一種で入力と出力の関係をパターンとして学習したネットワークを構築する手法である．構築されたネットワークにより，人間に与えられない細かな分類規則によって新たなデータを分類することができる．

3.3.1 深層学習に利用するデータ集合

本研究では，性格推定の対象を Twitter のユーザに限定しており，各ユーザが投稿してきた文章，Tweet を深層学習によって分析し，各性格要素がどれだけの強さを持っているかを推定する．Twitter ユーザの性格推定を行う際，対象ユーザの投稿した複数の Tweet を 1 件ずつ推定していくことで，ユーザごとにどの性格要素を強くもっているかの傾向を示す．

3.3.2 深層学習における正例データと負例データの選定

深層学習に用いる入力データは，推定対象と同じく Tweet を利用する．対象とする性格要素が Twitter 全体で特に強く現れているとみなしたユーザの Tweet 集合に正例，対象とする性格要素が全く現れていないとみなしたユーザの Tweet 集合に負例としてラベルをつける．これらの Tweet 集合を入力データとして，深層学習により性格推定ネットワークを構築する．今回は正例，負例ともにユーザ 500 人それぞれ 10 件ずつの Tweet 集合，すなわち 5000 件ずつの Tweet を選択する．

深層学習の入力データや推定対象の文章は，それぞれ文章から BoW(Bag of Words) に変換して利用する．BoW とは，全文章中に出現する単語を並べ，各文章での単語の出現頻度をベクトルで表現したものである．

ここで，それぞれの性格要素が強いユーザかどうかを推定する基準として，性格要素が強く現れる文章の特徴を表 3 に示す．対象の性格要素が強く表れているユーザは，仮定した特徴が多く現れる Tweet を投稿する傾向にあると仮定した．

各性格要素について，仮定した特徴が文章中に多く表れているユーザは強く性格要素を持っているとみなす．日本語によって記述された Tweet を無作為に 20 万件取得し，その中から仮定した特徴の出現回数が 20 万件中上位 20 %以内にある Tweet を投稿したユーザを正例の候補とし，対象のユーザが投稿した 10 件の Tweet を新たに取得する．

次に，10 件の Tweet を検査し，候補ユーザを更に絞り込

表 4: 各性格要素の性格推定ネットワークの詳細

性格要素	入力層ノード数	中間ノード数
几帳面さ	4195	20
外交性	4584	50
論理性	4457	20
感情表現	4835	50
礼儀正しさ	4635	20

んでいく．20 万件の Tweet に対し，仮定した特徴が最低でも 1 回以上出現している Tweet の件数の割合を，「特徴の出現確率」として，性格要素ごとに，「10 件の Tweet 中に特徴が出現した．Tweet が最低でも設定した件数以上に含まれる確率 C」が 0.1 を下回るように設定し，この条件に合うユーザを絞り込む．各性格要素の確率 C は式 (1) によって算出した． ここで，P は特徴の出現確率，X は各性格要素ごとに設定する Tweet 件数であり，10 件中 X 件以上に特徴を含む Tweet が発生する確率を算出する． 各性格要素で，算出された確率が 0.1 を下回るように X を設定する．

$$C = \sum_{i=X}^{10} {}_{10}C_i P^i (1-P)^{10-i} \quad (1)$$

以上の方法で絞り込んだ正例の候補からランダムに 500 人を選択し，これらのユーザが投稿した Tweet 各 10 件を収集，5000 件の Tweet を正例として決定した．また負例として，投稿した 10 件の Tweet 中に一切特徴が表れていないユーザを選択し，正例と同様にして 5000 件の Tweet を決定した．正例，負例それぞれ 5000 件の Tweet を BoW に変換し，深層学習に用いる入力データとした．

3.3.3 性格推定ネットワークの構築

各性格要素について，正例，負例の入力データを元に深層学習を行い，性格推定ネットワークを構築する．各性格要素の性格推定ネットワークの詳細を表 4 に示す．ここで，全ての性格要素で中間層数は 3，出力ノード数は 2，中間層の活性化関数は Relu，出力層の活性化関数はソフトマックス関数，学習回数は 1000 回，シード値は 30，使用した単語の品詞は「名詞」「形容詞」「形容動詞」「副詞」に統一している．

今回，性格推定ネットワークの構築を行う上で，性格推定の結果が後述の評価実験により作成した正解データに対し最も精度が高くなるように条件を設定した．

3.4 性格推定ネットワークを用いた Twitter ユーザの性格推定

深層学習によって構築した性格推定ネットワークを利用して，推定対象のユーザの Tweet から性格推定を行う．

性格推定を行う際には，推定対象の Twitter ユーザが投稿した複数の Tweet の集合を対象とし，Tweet1 件を 1 データとして性格要素が強く現れているかどうかを 2 値で推定する．次に性格要素が強く現れていると正推定された Tweet が，全体の Tweet 集合に対しどの割合で現れたかを算出してグラフ出力する．推定結果を提示するための可視化インタフェースとして，統合開発環境である TETDM[砂山 17] を利用する．

3.5 性格推定システムの使用例

性格推定システムの使用例として，Twitter 上でそれまで交流の無かった他のユーザから交流を持ちかけられたが，感情的なユーザとは交流をしたくないと考えているユーザが，相手の性格をシステムを利用して推定することで相手と付き合うかを決める例を挙げる．

TETDM を利用した性格推定結果の提示例を図 2 に示す．相手ユーザが直近に投稿した Tweet100 件を TETDM に入力



図 2: TETDM を利用した性格推定結果の提示例

し，性格推定システムを起動する．図 2 に示すように TETDM 上に，性格推定結果のグラフが Tweet 集合とともに表示される．強さの目安として，後述の評価実験を元に決定した閾値を超えた性格要素は強く現れていると判断する．図 2 の例では，相手ユーザは感情表現を積極的に行うことが推定されるため，交流を事前に断ることができる．

4. 性格推定システムの妥当性評価実験

4.1 実験目的

本研究では性格推定システムを，深層学習による文章分類を行うことで著者の性格を推定し，システム利用者に提示することを目的に開発したため，推定結果はシステムの利用者が納得できるものである必要がある．そこで複数人により人手で正解ラベルをつけられたユーザに対してシステムによる性格推定を行い，その結果からシステムによる推定に妥当性があるかを評価した．

また比較手法として，各性格要素について仮定した特徴が Tweet に含まれていた場合，その性格要素が強く現れていると判断し，性格推定を行った場合についても同様に評価した．両者を比較して，提案システムが仮定した特徴以外の分類規則を適切に学習し，より有用な判定を行えているかを評価した．

4.2 実験方法

提案システムを評価するための正解データとして，Twitter ユーザ 30 人を用意し，これらのユーザが各性格要素を強く持つか，全く持たないかを人手で判断した．性格要素の強さを判定するため，被験者 12 人に対象のユーザ 30 人が投稿した Tweet 各 100 件を読んでもらい，各ユーザに対して，それぞれの性格要素に対応する 5 項目を「1」「2」「3」「4」「5」の 5 段階により評価してもらった．ここで被験者に与えた評価基準を表 5 に示す．なお 5 段階評価では「5」に近づくにつれて高い評価となる．被験者には評価項目についてのみ伝え，性格要素については伝えず，対象の Tweet がリプライかどうかは分からなくした．

被験者による各ユーザの 5 段階評価を集計して正解データを決めた．各性格要素において「5」「4」以上の評価を行った被験者が 8 人を超えたユーザを，十分に性格要素を強く持っているとみなし，正解データとした．

各ユーザそれぞれ 100 件の Tweet を提案システムにより各性格要素について判定を行い，全 Tweet 中で正判定された Tweet の割合をそれぞれ算出した．この割合が閾値を上回るものを提案システムが正判定したデータとした．閾値は被験者の評価による正解データ数と提案システムの正判定データ

表 5: 被験者に与えた評価基準

性格要素	評価項目
几帳面さ	文章の体裁を整えよう とする考えを持っているか
外交性	他のユーザと積極的に交流を図ろう とする考えを持っているか
論理性	言いたいことを理由とともに言おう とする考えを持っているか
感情表現	自分の感情を前面に出そう とする考えを持っているか
礼儀正しさ	しっかり敬語を使っていこう という考えを持っているか

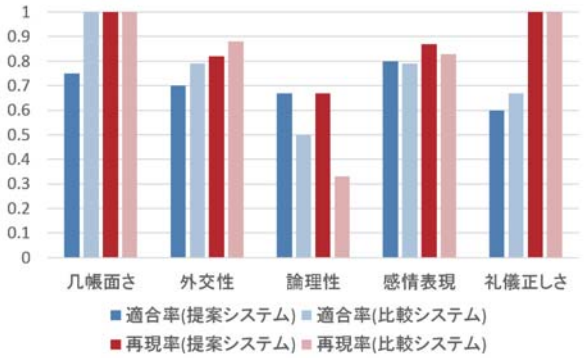


図 3: 被験者による正解に対するシステムの推定結果の適合率と再現率の結果

数が同程度になるように設定した．また，全 Tweet 中で性格要素ごとに仮定した特徴を含む Tweet の割合をそれぞれ算出し，提案システムと同様に設けた閾値を上回るものを比較手法が正判定したデータとした．

各性格要素について，被験者の評価による正解データと両システムによる正解データを比較し，提案システムの適合率，再現率を出すことでシステムの妥当性を評価した．

4.3 実験結果と考察

実験の結果として，被験者による正解に対するシステムの推定結果の適合率を再現率の結果を図 3 に示す．

対象の全ての性格要素について，6 割以上の適合率と再現率を示すことができたため，一定の妥当性があると言える．また，提案システムと比較手法について比較すると，「論理性」，「感情表現」についての性格推定では，提案システムの方がより適切な判定結果を見せた．

「論理性」，「感情表現」について，提案システムによって強いと判断されたユーザと，強くないと判断されたユーザの Tweet を比較すると，「論理性」が強いと判断されたユーザの Tweet 中には接続詞も多く含まれていたが，その他に「思う」「実際」「特に」といった共通の単語が多く見られた．「感情表現」についても，強いと判断されたユーザの Tweet 中には設定した単語の他に，「素晴らしい」「元気」「助かる」といった共通の単語が多く見られ，これらの単語が性格推定に大きく寄与しているのではないかと考えられた．そのため「論理性」，「感情表現」では，最初に仮定した特徴にのみによる分類では不十分であり，他の分類規則を学習して複数の基準で分類することで，より適した性格推定を行えると考えられた．

一方，「几帳面さ」，「外交性」，「礼儀正しさ」についての性格推定では，比較手法の方がより適切な判定結果を見せた．これらの性格要素では，最初に仮定した特徴が分類を行う上で大きな影響を持っており，他の分類規則を深層学習によって利用する意味が薄く，特徴のみの分類で十分であると考えられた．そのため，これらの性格要素については比較手法を用いて性格推定を行うことも検討する．

これらの結果より，起点となる特徴として対象の性格要素を表す表現の一部分のみを与え，性格推定に必要なその他の表現を深層学習により補完する必要があると考えられる性格要素に対して提案システムは有効であると考えられる．今回推定対象とした性格要素以外に，ひとつの単語のみで分類することができない「前向きさ」や「やさしさ」など様々な性格要素に対応できると考えられる．

5. 結論

Twitter ユーザを対象として性格推定を行い，推定結果をシステム利用者に提示することを目的として行った．人間の性格を複数の構成要素からなるものとし，それぞれの要素が対象のユーザが投稿した Tweet 集合に強く現れているかを深層学習を用いて判定し，提示するシステムを開発した．

システムの推定結果の妥当性を評価する実験として，各性格要素について，実験対象ユーザの投稿した Tweet を読んだ被験者の評価を元にして作成した正解データに対する適合率，再現率を求めた．その結果，推定結果が高い適合率，再現率を示したことから，十分な妥当性があることを確認できた．

今後の課題として，推定対象の要素を追加していき，より多用な解釈を可能にすることを目標としていきたい．

参考文献

[南川 10] 南川淳宣, 横山浩之: テキストマイニングによる個人 Blog データからの性格推定手法, 人工知能学会データマイニングと統計数理研究会 (第 12 回), pp.96-100 (2010)

[岡本 14] 岡本拓馬, 松本和幸, 吉田稔: ナイーブベイズ法を用いた Twitter による性格推定, 言語処理学会第 20 回年次大会発表論文集, pp.1123-1125 (2014)

[那須川 16] 那須川哲也, 上條浩一, 山本眞大, 北村英哉: 日本語における筆者の性格推定の取り組み, 言語処理学会第 22 回年次大会発表論文集, pp.1181-1184 (2016)

[馬緤 14] 馬緤美穂, 徳久良子, 寺嶌立太: ユーザの嗜好と所有物の関係性を用いた属性分析, 情報処理学会研究報告情報基礎とアクセス技術 2014-IFAT-114, pp.1-6 (2014)

[那須川 13] 那須川哲也, 西山莉紗, 金山博, 吉田一星, 大野正樹: 一人称所有格を用いたプロフィール推定, 言語処理学会第 19 回年次大会発表論文集, pp.952-955 (2013)

[長光 07] 長光左千男, 野田真樹子, 山形洋子, 中村裕一, 美濃導彦: ユーザの性格に応じた調理アドバイス文章の選択, 情報処理学会論文誌 48 巻 2 号, pp.701-710 (2007)

[新里 86] 新里里春, 水野正憲, 桂戴作, 杉田峰康: 交流分析とエゴグラム, チーム医療 (1986)

[砂山 17] 砂山渡, 高間康史, 徳永秀和, 串間宗夫, 西村和則, 松下光範, 北村侑也: 統合環境 TETDM を用いた社会実践, 人工知能学会論文誌 32 巻 1 号, pp.NFC-A __ 1-12 (2017)

[3F2-OS-12b] [Organized Session] OS-12

Thu. Jun 7, 2018 3:50 PM - 4:50 PM Room F (4F Garreria)

[3F2-OS-12b-01] A Study on Creation of Supplementary Learning Materials for Foreign Language by Using Comics

○Kohei Matsuoka[1], Yoko Nishihara[1], Ryosuke Yamanishi[1] （1. Ritsumeikan University）

3:50 PM - 4:10 PM

[3F2-OS-12b-02] Consideration of Quantitative Evaluation Method of Scientific Papers based on Text Analysis

○Shota Shimizu[1], Yasufumi Takama[1] （1. Tokyo Metropolitan University）

4:10 PM - 4:30 PM

[3F2-OS-12b-03] Document Writing Support by Visualizing Favorable Words and Malicious Words for Building Good Relationships

○Shota Ihori[1], Wataru Sunayama[1], Yuji Hatanaka[1], Kazunori Ogohara[1] （1. The University of Shiga Prefecture）

4:30 PM - 4:50 PM

©The Japanese Society for Artificial Intelligence

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

コミックを用いた外国語学習のための補助教材作成に関する検討

A Study on Creation of Supplementary Learning Materials for Foreign Language by Using Comics

松岡航平 *1　西原陽子 *2　山西良典 *2
Kohei Matsuoka　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 creation of supplementary learning materials for foreign language by using comics. We propose a method to make a learning material for role words of Japanese and make an interface for learning the role words. We experimented with the interface for verifying the efficiency of the method. Participants of the experiment learned 30 role words for three days and took a test to answer appropriate role words. The participants with the interface marked higher scores than scores by participants who learned role words by using textbooks.

1. はじめに

多くの人が母語以外の外国語を学ぶようになった．例えば外国語としての日本語を例にあげると，2015 年の時点で約 370 万人の学習者が存在する．中国語や英語など他の外国語でも同様であり，母語以外の外国語を学ぶニーズが増えている．

外国語を学ぶ上で難しいことの一つに，話し手が使うべき表現と使うべきでない表現の習得があげられる．男性が使うべき表現を女性が使うと聞き手に違和感を与えることや，子供が使うべき表現を大人が使うと違和感を与えることなどである．このような表現の一つに，日本語における役割語がある．

役割語とは話者の特定の人物像（年齢，性別，職業，階層，時代，容姿･風貌，性格等）を想起させる言葉遣いである [金水 11]．例えば,「わし」という文字列を見たり，音声を聞くと，この話者は男性の老人であると想起されることが多い.「わし」は役割語の一つである．日本語を母語とする人たちは，様々な人物と役割語のペアの実際の例を日常生活を通じて得ているため，役割語の学習が容易くできている．一方で，日本語を母語としない人たちは，実際の例を見聞きすることは少なく，役割語の学習が困難な状況にあると考えられる．我々は、実際の例がふんだんにあるメディアとしてコミックやアニメに着目し，その活用を検討してきた [Shan 17]．

本論文では，日本語の役割語を学習するためにコミックを用いた補助教材の作成方法を提案し，その実験結果を報告する．欧米では日本語学習においてコミックを用いた教材の例が報告されている [Lammers 04]．教材の多くは人手で作成されているが，本研究では人手を借りず自動的に教材を作成する．

2. 役割語学習のための コミックを用いた補助教材の作成方法

作成手順の概要を説明する．

1. コミックのあるページを i とする
2. ページ i のセリフをテキスト化する
3. ページ i のテキストを形態素解析し，形態素と品詞情報を得る
4. ページ i の形態素 j が役割語であれば，ページ i に役割語 j のラベルを付与する
5. 3. の処理をページ i 内の形態素分だけ行う．
6. 2. から 5. の処理をコミックのページ数分だけ行う．

表 1: 役割語のラベルの一部

田舎ことば，江戸ことば，王様・貴族ことば，大阪弁・関西弁，沖縄ことば，奥様ことば，おじさん語，お嬢様ことば，男ことば，おばあさん語，お姫様ことば

それぞれの手順について，本論文での詳細を説明する．1. のコミックは，研究用データセットである Manga109[Fujimoto 16] を用いた．2. のテキスト化は，OCR ソフトウェアである Google Cloud Vision API[Google] を用いた．3. の形態素解析は，MeCab を用い，辞書は NEologd を用いた．4. の役割語は「＜役割語＞小辞典」[金水 14] に掲載されたものを用いた．表 1 に役割語のラベルの一部を示す．役割語は与える印象によりラベルがあり,「田舎ことば」「お嬢様ことば」などがある．ラベルは 53 種類ある．ラベルごとに役割語が分類されており,「田舎ことば」であれば「おら」「ばってん」などがあり,「お嬢様ことば」であれば「あら」「かしら」などがある．

1. から 6. までの手順を行うと，役割語ごとに分類されたコミックのページの集合が得られる．これを役割語をキーとしてアクセスできるようにインタフェースを用意した．図 1 にインタフェース画面の一例を示す．画面の左側に役割語が並び，役割語がコミックのページ集合へのリンクとなっている．リンクをクリックすると，画面の右側に役割語を含むコミックのページが表示される．コミックのページをクリックすると，そのページが拡大して表示される．コミックに描かれた人物と役割語が含まれるセリフを見て，役割語の学習が行える．

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



図 1: 役割語学習のためのインタフェース画面の一例

表 2: 実験で学習してもらった役割語

上位 10 件	ね，わ，ん，じゃ，こと，の，ある，ぞ，さ，ぜ
中位 10 件	あたし，ませ，お前，あんた，ねん，あら，わし，ぼく，ちゃう，かしら
下位 10 件	貴様，っす，わたくし，まじ，おいら，たまえ，えらい，諸君，申す，拙者

3. 評価実験と結果

図 1 に示したインタフェースを用いて，役割語を学習する効果を評価する実験を行なった．実験者は被験者を集め，実験群と統制群に分け，実験群はインタフェースを用いて役割語を学習する群，統制群は「＜役割語＞小辞典」[金水 14] を用いて学習する群とした．被験者は日本語を母語としないが，日本語の学習を行っている中国人の留学生 16 名であった．実験群が 8 名，統制群が 8 名であった．

実験者は 30 個の役割語を選定し，1 日あたり 10 個の役割語を学習するよう被験者に指示した．選定された役割語を表 2 に示す．これらの役割語は Manga109 で出現した頻度の順に，上位 10 個，中位 10 個，下位 10 個であった．

被験者は 3 日間にわたり役割語の学習を行った．最終日に役割語の学習度合いを評価するテストを行なった．テストは 2 種類用意した．テスト 1 はコミックのコマを示し，吹き出しの中に書かれている役割語が適切なものかどうかを YES/NO で回答させるものであった．テスト 2 はコミックのコマを示し，吹き出しの中に書かれている役割語を空白とし，もっとも適切な役割語を 3 つの選択肢の中から回答させるものであった．テストで用いた役割語は学習した 30 個の中からランダムに選択された 17 個であった．

3.1 結果：テストの点数比較

表 3 に評価テストの平均点を示す．満点は 17 点であった．全体の点数は実験群は 14.5 点，統制群は 11 点で実験群の方が点数が高かった ($t=2.56$, $p=0.02 < 0.05$)．選択肢を回答するテスト 2 の点数は実験群は 8.5 点，統制群は 5.2 点で実験群の方が点数が高かった ($t=3.52$, $p=0.007 < 0.05$)．中位の点数は，実験群は 5.2 点，統制群は 3.8 点で実験群の方が点数が高かった ($t=2.54$, $p=0.02 < 0.05$)．

以上の結果から提案インタフェースを用いて役割語を学習すると，全体的な点数が高くなることがわかった．特に選択肢を回答させるテストで差がつくことがわかった．また，中程度の頻度の役割語の学習で効果が高くなることがわかった．

表 3: 評価テストの結果

	全体	テスト 1	テスト 2	上位	中位	下位
実験群	14.5	6.0	8.5	4.0	5.2	5.2
統制群	11	5.7	5.2	3.0	3.8	4.1

4. おわりに

本論文では日本語の役割語を学習するために，コミックを用いた補助教材の作成方法を提案し，実験結果を報告した．実験では被験者に提案インタフェースを使って役割語を学習してもらった後，学習の度合いを評価するテストを課した．提案インタフェースを使わずに学習した被験者とテストの点数を比較すると，提案インタフェースを使った被験者の方がテストの点数が高くなった．テストの形式については，適切な役割語を選択肢から回答させる形式において，提案インタフェースを使う群の点数の方が高くなった．役割語の種類については，中程度の頻度の役割語について問うた問題において，提案インタフェースを使う群の点数の方が高くなった．

今回の被験者は中国人の留学生であり，ともに漢字を使う文化であるため，役割語の学習において影響があった可能性がある．今後は漢字を使わない文化圏からの留学生に対して実験を行い，その違いを検証する．現状のインタフェースはコミックのコマを示すだけで，コミックのストーリーを楽しめるようにはなっていないため，この点も改善していく．

謝辞

本研究の遂行にあたり，Manga109 を使用した．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

[Fujimoto 16] Azuma Fujimoto, Toru Ogawa, Kazuyoshi Yamamoto, Yusuke Matsui, Toshihiko Yamasaki, Kiyoharu Aizawa: Manga109 Dataset and Creation of Metadata, International Workshop on Comics Analysis, Processing and Understanding (2016).

[Google] https://cloud.google.com/vision/?hl=ja

[金水 11] 金水敏: 役割語と日本語教育, 日本語教育, Vol.150, pp.34–41 (2011).

[金水 14] 金水敏: ＜役割語＞小辞典, 研究社 (2014).

[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).

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

テキスト解析に基づく学術論文の定量的評価方法の検討

Consideration of Quantitative Evaluation Method of Scientific Papers based on Text Analysis

清水 勝太[*1]
Shota Shimizu

高間 康史[*1]
Yasufumi Takama

[*1] 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 proposes a method to evaluate scientific papers based on text analysis. Recently, there are many scientific papers on the Web along with the trend of digitization of academic information. Such a situation creates a need for evaluation method of scientific papers as selection criteria. This paper defines Journal similarity and analyzes relationship between Journal similarity and Scimago Journal Rank (SJR). The Journal similarity of a target journal to an authoritative journal is calculated based on distributed representations of texts of papers. When the similarity of a target journal is high, its quality in terms of writing and organization is expected to be high. This paper also proposes to evaluate the consistency of writing of a paper using ROUGE. The experimental results show that journals with high SJR tends to have high Journal similarity with authoritative journals and that Cell Reports is more consistent than Cell in evaluation using ROUGE.

1. はじめに

学術論文は，知識創発にとって重要な情報源の 1 つである．近年，インターネットの普及に伴い，Web での学術論文の出版，古い論文の電子化，学会発表資料の公開などが行われている．電子媒体を通して論文を利用する研究者も増加している．学術図書館研究委員会の調査[SCREAL 2014]において，月に一回以上電子ジャーナルを利用していると答えた研究者は 85%程度に上る．もっとも電子ジャーナルの利用が顕著な薬学分野では 97.2%の研究者が月に一回以上電子ジャーナルを利用している．2007 年時の調査と 2011 年時の調査を比較すると，論文を印刷して読む研究者の割合は減少し，ディスプレイを通して論文を読む研究者の割合が増加している．同様に，American Journal Experts 社の調査[AJE 2016]によれば，2006 年から 2016 年までに学術論文の出版数は倍程度になっている．流通する研究情報が増大することで，人間の処理能力とのギャップが増大し，読むべき論文の選択が研究者にとって以前よりも負荷の大きい作業になっている．その結果，選択基準の 1 つとして論文や学術雑誌の評価指標が利用されている．

学術雑誌の評価指標として，Impact Factor (IF) や Scimago Journal Rank (SJR) [Bote 2012] などが存在する．これらは学術雑誌を掲載論文の被引用数，引用元の論文が掲載されている雑誌などから評価する指標であり，学術雑誌に対して定量的な評価を与える．しかし，被引用数をもとに算出されることから，出版直後の学術雑誌を評価できないこと，論文単体ではなく，学術雑誌に適用されること，被引用数の多い少数の論文によって学術雑誌の評価が高まり，被引用数の少ない論文も高い評価を得てしまうことなどから，研究の内容評価に用いられることは疑問視されている[Callaway 2016]．また，これらの指標は定期的に刊行される学術雑誌を想定したものであり，学会の予稿には適用されていないものが多い．情報科学の分野では研究サイクルの早さの観点から，学会発表を重視する傾向があるため，これら指標を適用しづらい問題が存在する．

連絡先：首都大学東京大学院
システムデザイン研究科情報科学域
〒191-0065 東京都日野市旭が丘 6-6
E-mail: shimizu-shota@ed.tmu.ac.jp

以上のことから，多量の論文から読むべき論文を選ぶ際，研究内容を考慮した定量的な評価方法が必要と考える．本稿では，学術雑誌間類似度を定義し，既存の評価が高い権威的な論文集合を基準として，類似度による論文の評価を提案する．本稿における類似度とは論文が扱うトピックの類似度ではなく，論文の構成や体裁，言い回し等に関するものを指す．高い評価を得ている論文集合は著者の論文執筆スキルや経験が高いことが想定されるため，この様な類似度が高くなると考える．また，要約評価指標 ROUGE (Recall-Oriented Understudy for Gisting Evaluation) [Lin 2003,2004] を用いた論文の一貫性に関する評価方法も提案する．

2. 関連研究

2.1 研究評価

本稿では既存の評価指標として，データ利用の観点から SJR を用いる．SJR は，学術雑誌に掲載された論文の被引用数に重み付けをした評価指標を採用している．この重みの基準は権威のある学術雑誌，学術会議に対し，PageRank に類似するアルゴリズムを適用して求めている．また，SJR は分野の異なる雑誌間の評価に対して補正をかけ，算出された数値によってすべての雑誌を一様に評価する．SJR は，ある雑誌に掲載された論文が，権威のある雑誌に掲載された論文からどの程度の引用を行っているかを考慮している点で IF と異なる．

この他にも論文あるいは研究を対象とした評価指標が多数提案されている[Moed 2010][West 2010]．しかし，それらのほとんどが論文の内容的な評価を行っておらず，引用関係に基づいて評価を定めている．また，これらは論文単体に対して評価が与えられず，対象の論文がどのような学術雑誌に掲載されているか，という点からしか論文の評価を考えることができないデメリットが存在する．

2.2 分散表現

自然言語として表現される単語や文といった処理単位を，有限次元の実数値ベクトルとして表現することを分散表現という．通常，分散表現された処理単位は，コーパス中の語彙数より少ない次元数を持ち，同一の単語や文でも，学習コーパスによっ

て異なるベクトルとして表現されることがある. また, 分散表現は, 分布仮説[Harris 1954]に基づいた「共起している語が似ていれば単語の意味は類似している」という分布類似度の考えに基づいている.

自然言語をベクトル空間上に表現することにより, 様々な距離尺度を類似度や重要度のスコアとして利用できる. また, 分布類似度の考えから単語や文の意味関係を扱うことができる利点も存在する. さらに, 自然言語をベクトルとして扱うことは, 単語によって明示的にあらわされるトピックよりも, 体裁や言い回しなどの類似度を扱うことに適していると考える.

本稿では, 論文をベクトルとして扱うために, 分散表現を得るツールとして, 学習が高速かつ, 可変長の入力を受け付ける fastText [Bojanowski 2016]を用いる.

2.3 要約評価指標

文書間の類似度を測ることで, 異なる文書間の差異を計量することができる. 自動要約や機械翻訳の分野では, システム出力の評価ために要約結果や翻訳結果と原文の差異を評価する際に文書間類似度を用いる. 自動要約システムを評価する指標として ROUGE[Lin 2003,2004]が提案されている. 要約の評価は通常, 人手で用意された参照要約と要約システムによる要約が一致する度合いで定められる. ROUGE による評価方法を以下の式に示す.

$$R_{ouge}(S,R)=\frac{\sum_{e\in n(S)}C_{match}(e)}{\sum_{e\in n(R)}C(e)} \qquad (1)$$

ここで, Sはシステム出力, Rは参照要約(正解データ), $n(\cdot)$はテキストに含まれる n-gram を示す. $C(e)$は文書中における e の出現頻度, $C_{match}(e)$はシステム要約と参照要約における eの出現頻度の内, 小さいものである.

3. 提案手法

論文中の文をベクトルとして扱うことにより, 論文間類似度を定義する. さらに論文間類似度を用いて, 学術雑誌間類似度を定義する. 2 種類の論文集合を用意し, 片方を評価基準として用いることにより, 論文集合に対する評価方法を提案する. 評価基準として, 既に高い評価を得ている権威的な論文集合を用いることにより, それらと類似している論文は同様に高い評価を得ると考える.

また, 論文において明示的に得られる段落構成に対して要約評価を行うことで論文の一貫性を評価する方法も提案する.

3.1 学術雑誌間類似度

論文中の文に基づく学術雑誌間類似度について述べる. 学術雑誌XとYの学術雑誌間類似度$sim_j(X,Y)$を以下に定義する.

$$sim_j(X,Y)=\frac{1}{|X_N||Y_N|}\sum_{p_i\in X_N}\sum_{p_k\in Y_N}sim_p(p_i,p_k) \qquad (2)$$

$$sim_p(p_i,p_k)=\frac{1}{|p_i||p_k|}\sum_{s_m\in p_i}\sum_{s_n\in p_k}sim_s(\boldsymbol{s}_m,\boldsymbol{s}_n) \qquad (3)$$

$$sim_s(\boldsymbol{s}_m,\boldsymbol{s}_n)=\frac{\langle \boldsymbol{s}_m,\boldsymbol{s}_n\rangle}{|\boldsymbol{s}_m||\boldsymbol{s}_n|} \qquad (4)$$

式(2)-(4)において, sim_pは論文間類似度, sim_sは文間類似度を示し, $\boldsymbol{s}_m$, $\boldsymbol{s}_n$はそれぞれ論文p_i, p_kに含まれる文のベクトルとする. p_i, p_kは雑誌X, Yに含まれる論文であり, それぞれの雑誌からランダムにN本選択した論文の集合をX_N, Y_Nとする.

また, 論文 1 つのテキスト全てを 1 つのベクトルとして扱う場合, 雑誌X', Y'の学術雑誌間類似度$sim_j(X',Y')$を以下の式により定義する.

$$sim_j(X',Y')=\frac{1}{|X'_N||Y'_N|}\sum_{\boldsymbol{p}_i\in X'_N}\sum_{\boldsymbol{p}_k\in Y'_N}sim_s(\boldsymbol{p}_i,\boldsymbol{p}_k) \qquad (5)$$

$$sim_s(\boldsymbol{p}_i,\boldsymbol{p}_k)=\frac{\langle \boldsymbol{p}_i,\boldsymbol{p}_k\rangle}{|\boldsymbol{p}_i||\boldsymbol{p}_k|} \qquad (6)$$

ここで, $\boldsymbol{p}_i$, $\boldsymbol{p}_k$は各論文の全テキストによるベクトルとする.

本稿では, 評価基準となる論文集合として, 権威的な学術雑誌または, 高 h-index の著者による論文集合を用いる. 2 種類の論文集合から選択する論文数Nは 4 節に後述するように実験ごとに変更した.

3.2 要約評価指標による論文評価

学術論文には abstract, あるいは summary として全体の要約を示す部分が存在する. 本文とみなせるパラグラフを参照要約, 全体の要約を示す部分をシステム要約とみなし, 要約評価指標を学術論文に適用することで, 本文と要約部分の一貫性を評価する. 学術論文における一貫性は読み手の理解を助長するため, 評価指標として有効であると考える.

本稿では, 要約評価指標として ROUGE を用いて論文の一貫性評価を行う. 論文Pの本文をR_P, 要約部分をS_PとしてPの要約評価スコア$S_S(P)$を以下の式で定義する.

$$S_S(P)=R_{ouge}(S_P,R_P) \qquad (7)$$

本稿では, ROUGE を適用する際, 単語 n-gram をユニグラムとして評価を行う.

表1. 使用した学術雑誌

学術雑誌	分野	SJR 値
Cell	分子生物学	27.696
Journal of Finance	経済学	20.973
Nature	学際的分野	18.134
Cell Reports	分子生物学	8.507
Journal of Machine Learning Research	計算機科学	1.627
Cell and Bioscience	分子生物学	1.621
Journal of Artificial Intelligence Research	計算機科学	1.016
Cells	分子生物学	0.889
i-Perception	計算機科学	0.725
Computational Linguistics	計算機科学	0.546
Open Biochemistry Journal	分子生物学	0.394
Journal of Computer Science	計算機科学	0.255
Journal of Applied Research of Children	心理学	0.173
BUSSINESS THEORY and PRACTICE	経済学	0.165
Journal of Chemical and Pharmaceutical Sciences	分子生物学	0.124
pythagoras	数学	0.101

表2. 使用した高 h-index の著者

著者	分野	h-index
A	計算機科学	145
B	計算機科学	137
C	計算機科学	106
D	計算機科学	99
E	計算機科学	77

4. 評価実験

4.1 使用データ

Web 上から収集した PDF 形式の論文ファイルからテキストを抽出し，不要部分の削除など，前処理を行った論文のテキストデータをベクトル化する．本稿では権威的な学術雑誌として，SJR 値の高い，Cell，Nature，Journal of Finance を用いた．同様に権威的な論文集合として，h-index の高い著者による論文を使用した．表 1 に使用した学術雑誌を，表 2 に使用した高 h-index の著者を示す．

また，各雑誌の SJR の値は 2015 年の値を使用した．2015 年の SJR 値の算出に用いられるのは直近 3 年間に掲載された論文であるので，その期間に掲載された取得可能な論文を分析対象とした．

4.2 前処理

PDF 形式の論文ファイルから抽出したテキストデータに対して，可能な限り，雑誌名や発行年月日などの不要な情報を排除した．同様に論文中に現れるストップワードと制御文字を削除し，ピリオドで終わる文字列を一文とみなしてベクトル化する際の単位として用いた．論文間類似度を計算するための，fastText の学習パラメータについては，学習モデルを skip-gram，文字 n-gram は 3-6 のデフォルト値を用いた．ベクトルの次元数，学習コーパスについては実験ごとに変更して評価を行った．

4.3 論文間類似度と SJR に基づく評価

4.3.1 異分野間雑誌の評価

Cell と異なる分野の学術雑誌 4 誌との学術雑誌間類似度と SJR の関係を分析する．fastText の学習パラメータとして次元数 300，テキストコーパスを Wikipedia，論文 1 つの全テキストを 1 つのベクトルとした．雑誌からのサンプル数Nは 16 とした．結果を図 1 に示す．

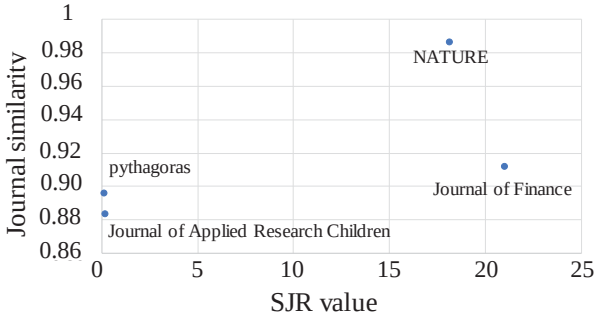


図1.異分野雑誌の学術雑誌間類似度

図 1 から SJR 値が高い雑誌ほど Cell との類似度が高い傾向にあることがわかる．しかし，Nature と Journal of Finance に関して傾向が逆であることがわかる．これは，Cell と Nature の分野が部分的に重なるため，Cell と Nature に共起する単語が Cell と Journal of Finance に共起する単語より多く，Cell と Nature の学術雑誌間類似度が高くなったと考えられる．このことから，異分野の学術雑誌に対して学術雑誌間類似度から評価を行う場合は分野を考慮した補正が必要であることが示唆される．さらに，論文の全テキストを単一のベクトルとして扱うため，多数の単語情報が圧縮され，共通の単語によるトピックの影響を排除しきれなかったと考える．

4.3.2 同分野間雑誌の評価

Cell と同分野の学術雑誌との学術雑誌間類似度と SJR の関係を分析する．fastText の学習パラメータとして次元数 100，テキストコーパスを Cell，論文中の一文を 1 つのベクトルとした．雑誌からのサンプル数Nは 16 とした．結果を図 2 に示す．

図 2 において SJR 値が高い雑誌ほど，Cell との学術雑誌間類似度が高い傾向にあることがわかる．SJR によって高い評価を得ている学術雑誌を基準に考えると，同分野の学術雑誌の評価は内容的な類似度とも対応があるといえる．ここから評価の与えられていない学術雑誌の論文に対して，同分野の権威的な学術雑誌を基準とした評価を行えると考える．

4.4 論文間類似度と h-index に基づく評価

権威的な論文集合として，表 2 に示した h-index の高い著者による論文を使用し，SJR との関係に関する分析を行った．fastText の学習パラメータは次元数 300，テキストコーパスを Wikipedia，論文中の一文を 1 つのベクトルとした．論文集合からのサンプル数Nは 5 とした．図 3 に著者別の学術雑誌間類似度，図 4 に雑誌別の学術雑誌間類似度を示す．

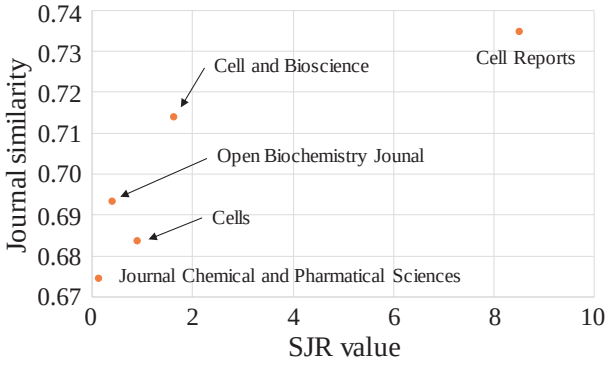


図2.同分野雑誌の学術雑誌間類似度

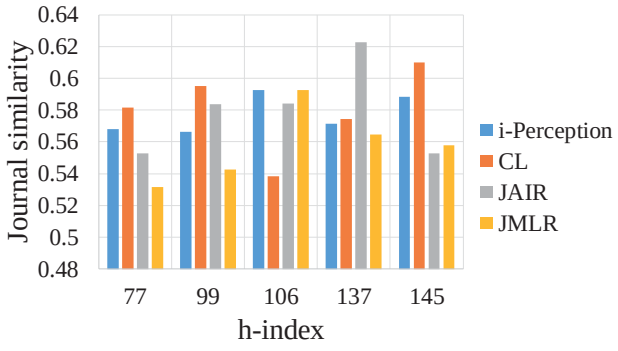


図3.著者別の学術雑誌間類似度

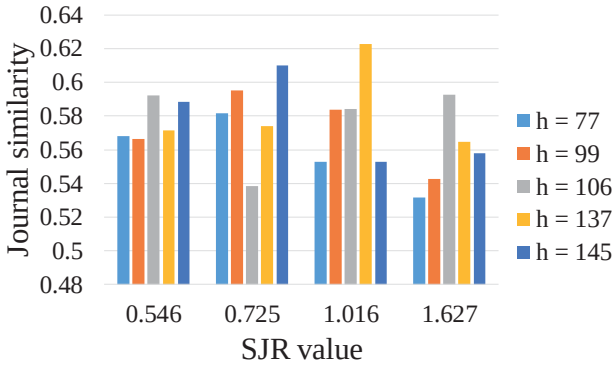


図4.雑誌別の学術雑誌間類似度

表3. ROUGE による Cell の要約評価値

	Precision	Recall	F-value
Introduction	0.106	0.506	0.175
Results	0.016	0.710	0.031

表4. ROUGE による Cell Reports の要約評価値

	Precision	Recall	F-value
Introduction	0.113	0.515	0.185
Results	0.018	0.713	0.035

図 3 から h-index と学術雑誌間類似度の間に一貫した傾向は確認できない. 同様に図 4 から SJR 値と学術雑誌間類似度についても一貫した傾向を確認できない. つまり SJR 値や h-index の大小は, 直接的に学術雑誌間類似度の値に影響しない. h-index は論文をもとに定まるが, 論文は単一の著者によって書かれるわけではなく, 同一著者による論文集合は学術雑誌のように扱えないと考える. よって高 h-index の著者による論文集合は評価基準として適していないと考える.

4.5 要約指標による評価

Cell と Cell Reports を用いて, 要約指標による論文の評価について検討する. Cell, Cell Reports の論文における Introduction, Results の記載内容を要約評価におけるシステムの出力, Summary を参照要約(正解データ)とみなして, 各論文に対して ROUGE を用いて要約評価を行った. 表 3 に Cell, 表 4 に Cell Reports の要約評価を示す.

表 3, 4 からどの比較においても適合率より再現率の方が高い. これは Summary と Introduction, Results で同じ単語が多く使われている. また, Introduction よりも Results の方が, 再現率が高く, Results と Summary で同じ単語がより多く使われていると考えられる. さらに, それぞれの評価値に着目すると, Cell よりも Cell Reports の方が, 全ての評価値が高く, 要約評価の面からみて, 一貫性のある学術雑誌だといえる.

5. おわりに

本稿では, 分散表現を用いたテキスト解析による定量的な学術論文の評価方法を提案した. また, 既存の評価指標 SJR と提案手法の関係を分析することで, その使用可能性を検証した.

評価実験から, Cell を基準として同分野の学術雑誌に対して提案手法を適用することで, SJR が高ければ, 学術雑誌間類似度も高い傾向を示す結果が得られた. 異分野の学術雑誌に対する実験では, 分野の違いによるトピックの影響を考慮しなければならないことがわかった.

高 h-index の著者による論文を基準とした実験では, SJR に対しても h-index に対しても一貫した傾向が確認できず, 論文の評基準として適していないことがわかった. これは論文が複数の著者によって執筆されることなどが原因であると考えられる.

要約指標による一貫性の評価では, ROUGE を適用することで, 論文の一貫性を評価できることを示した. 論文の相対的な比較において要約指標による評価を利用できる可能性があると考える.

本稿で検討した評価手法は, 他の尺度による評価を得ている論文を基準として相対的に評価するアプローチであり, 近年普及しつつある多数のオープンアクセスジャーナルの評価方法として, 使用可能性があると考える.

今後の課題として, 他の指標や評価方法と比較して評価の妥当性の検討, 引用関係を考慮した評価方法の検証などが挙げられる.

参考文献

[SCREAL 2014] 学術図書館研究委員会(SCREAL), 学術情報の取得動向と電子ジャーナルの利用度に関する調査 2011, SCREAL 調査報告書, 2014.

[AJE 2016] American Journal Experts, "AJE Scholarly Publishing Reports:2016," American Journal Experts, 2016.

[Bote 2012] V. P. Guerrero-Bote and F. Moya-Anegón, "A further step forward in measuring journals' scientific prestige: The SJR2 indicator," Journal of Informetrics, vol. 6, no. 4, pp. 674–688, 2012.

[Callaway 2016] E. Callaway, "Publishing elite turns against impact factor," Nature, vol. 535, no. 14, pp. 210–211, 2016.

[Moed 2010] H. F. Moed, "Measuring contextual citation impact of scientific journals," Journal of Informetrics, vol. 4, no. 3, pp. 265–277, 2010.

[West 2010] J. D. West, T. C. Bergstrom, and C. T. Bergstrom, "The eigenfactor metrics™: A network approach to assessing scholarly journals," College and Research Libraries, vol. 71, no. 3, pp. 236–244, 2010.

[Harris 1954] Z. S. Harris, "Distributional Structure," WORD, no. 2-3, pp. 146–162, 1954.

[Bojanowski 2016] P. Bojanowski, E. Grave, A. Joulin, and T. Mikolov, "Enriching Word Vectors with Subword Information," Transactions of the Association for Computational Linguistics, vol. 5, pp. 135-146, 2017.

[Lin 2003] C. Y. Lin and E. Hovy, "Automatic evaluation of summaries using N-gram co-occurrence statistics," NAACL '03, pp. 71–78. 2003.

[Lin 2004] C. Y. Lin, "Rouge: A package for automatic evaluation of summaries," WAS 2004, pp. 25–26, 2004.

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

良好な人間関係構築のための好意と悪意を表す単語の可視化による文章作成支援

Document Writing Support by Visualizing Favorable Words and Malicious Words for Building Good Relationships

庵 翔太 *1 Shota Ihori　砂山 渡 *2 Wataru Sunayama　畑中 裕司 *2 Yuji Hatanaka　小郷原 一智 *2 Kazunori Ogohara

*1滋賀県立大学大学院工学研究科 Graduate School of Engineering, The University of Shiga Prefecture

*2滋賀県立大学工学部 School of Engineering, The University of Shiga Prefecture

In recent years, with the increase of users of social media, many people are conducting online communication. However, recently troubles caused by inappropriate posting in social media are a problem. Considering these current situations, it is important to write sentences considering the emotions of the readers when conducting online communications in order to build good relationships. Therefore, in this research, using sentences as input, we implemented a function to visualize words expressing favor or malice of a writer and a function to urge text modification, with the purpose of supporting writing sentences that the writer receives a good impression from the reader . As a result of the experiment, it was found that the writing sentences support function of this system can support writing sentences receiving good impression from the reader.

1. はじめに

近年，SNS の利用者の増加によって，年齢を問わず増々多くの人々が，オンラインでの対話を行うようになっている．しかしながら，昨今 SNS における不適切投稿によって生じるトラブル，いわゆる「炎上」が問題となっている

こういった現状を考えると，オンラインでの対話を行う際に，読み手の感情を考慮した文章作成を行うことは，良好な人間関係を構築する上で重要であると言える．例えば，メールを作成する時に，読む人の気分を害する表現を避けることは我々が日常的に行っていることである．そこで，読み手が良い印象を抱く文章の作成を支援する事が出来れば，コミュニケーション支援として有用である．例えば，SNS 上で読み手が気分を害する投稿をしようとする書き手のユーザに注意喚起するサービスや，メールの自動添削システムが考えられる．

そこで本研究では，メールなどのオンラインでの対話における文章を入力とし、書き手が読み手から良い印象を受ける文章の作成を支援することを目的とする．このために、文章中で用いられる書き手の好意や悪意を表す単語を可視化する機能，文章修正を促すメッセージを表示する機能，文章をスコア付けして表示する機能を実装した．

2. 関連研究

2.1 読み手の感情を予測する研究

システムがユーザの感情を推測し，それに応じて自身の持つ感情状態を遷移させ，その時々の感情状態に応じて感情表現を用いながら，ユーザの説得を行う対話システムを提案した研究がある [石川 18]．この研究では，人を説得するための効率的な方法として感情表現を用いているが，本研究では，読み手から良い印象を受ける文章の作成を支援することを目的としている．

オンライン上の対話において聞き手の感情を予測し喚起させる研究がある [長谷川 14]．この研究では，マイクロブログから大規模な感情タグ付き対話コーパスを構築し，感情喚起モデルを学習することで読み手に感情を喚起させる応答を生成するが，本研究では書き手の文章作成の支援に着目している．

2.2 文章の作成を支援する研究

段落の一貫性を数値的に評価する研究がある [板倉 09]．この研究では，段落一貫度を定義し，論文執筆などの際の文章校正支援を期待している．本研究では，文法や文章構成のルールではなく，読み手の感情に基づいた文章作成支援を行う．

2.3 良好な人間関係の構築を支援する研究

多様な人間関係をシステム上で表現することにより，ユーザ間のコミュニケーションを支援するコミュニティシステムを提案する研究がある [高井 07]．この研究では，SNS などにおいて情報発信者が自分の友人を自由にグループ化し，コンテンツ毎に友人のグループを利用してアクセスコントロールを行う．この研究では情報の発信を促す事によるコミュニケーションの支援を行うが本研究では文章の作成を促す事によるコミュニケーション支援を行う．

3. 好意と悪意を表す単語の可視化による文章作成支援システム

本システムは人に送るメッセージを入力として，人に好かれるための文章作成を支援するインタフェースを提案する．本システムの構成図を図 1 に示す．

3.1 良好な人間関係の構築に向けた文章

本節では良好な人間関係を構築するために必要な文章の要素について述べる．まず「良好な人間関係」について定義する．「良好な人間関係」とは，コミュニケーションを図る者同士が互いに相手に好意を抱いている状態とする．コミュニケーションを図る相手に好意を抱いてもらうためには，こちらから好意を伝える必要がある．逆に，相手に対する悪意が伝わると相手も自分に対して悪意を抱くようになるだろう．つまり，良好な人間関係を構築するために必要な文章の条件とは，書き手から読み手に対する好意を表す表現が含まれてることだと考えた．

また一般的に文章において，最初と最後の数文が読み手の記憶に残りやすいと言われている．これを系列位置効果という

連絡先: 庵翔太，滋賀県立大学大学院工学研究科電子システム工学専攻，〒 522-8533 滋賀県彦根市八坂町 2500，of23sihori@ec.usp.ac.jp

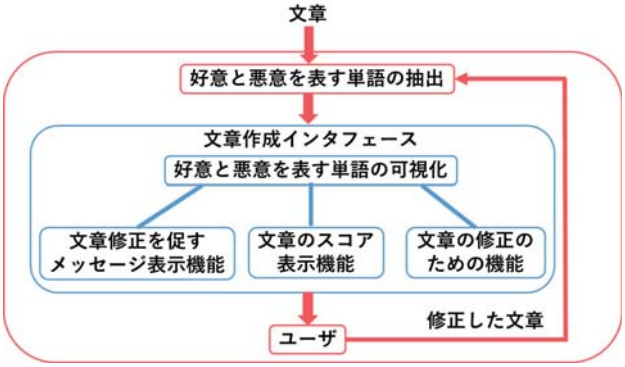


図 1: 文章作成支援システムの構成図

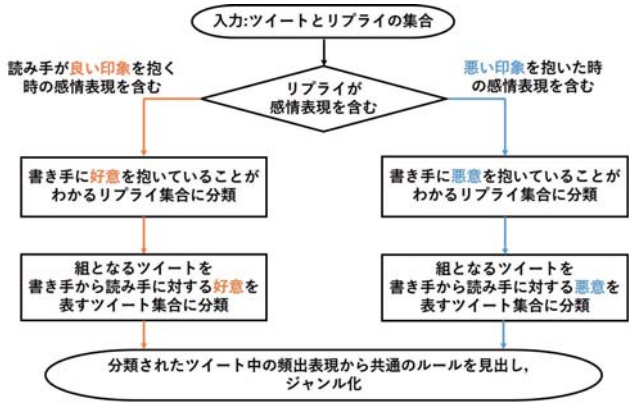


図 2: 辞書構成の流れ

[Murdock Jr. BB 62]．さらに，文章の要点となる文は読み手に強い印象を残すと言われている [Daniel 99]．よって文章の最初と最後と要点となる文に好意を表す表現があることが望ましいと言える．今回は書き手の好意を表す表現が多く，悪意を表す単語が少ない程読み手の印象が良くなるとした．

3.2 好意と悪意を表す単語の抽出

本研究では，文章中の好意と悪意を表す単語を抽出するために，好意と悪意を表す単語辞書を構築した．この単語辞書を構築するために，書き手のどのような発言に読み手は良いまたは悪い印象を受けるのかを調査した．このために，Twitter におけるユーザ間の対話情報を収集した．これを読み手への好意と悪意を表す文章に分類することで，書き手の好意と悪意を表す単語の大まかなジャンルを収集した．図 2 に辞書作成までの流れを示す．

3.2.1 Twitter の対話の取得

まず，TwitterAPI[Twitter] を利用することにより，Twitter 上でのある発話 (これを「ツイート」という) について，その発話に返答 (これを「リプライ」という) が行われているツイートを収集した．具体的には，Twitter Streaming API を用いて無作為にツイートを収集する．さらに Twitter REST API によって提供される'in_reply_to_status_id' のフィールドを利用することにより，先程のツイートのうち，別のツイートへのリプライを収集した．収集したデータはツイートとリプライで 1 つの組として 69458 組の対話で構成されている．収集の際には，Twitter 特有の「【】」を含むツイートや，URL を含むツイート，ならびにツイートのユーザ名に「bot」が含まれるツイートは削除した．

表 1: 読み手が書き手に対して抱く印象と感情表現

印象	感情表現
好印象	嬉しい，楽しみ，好き，幸せ
悪印象	悲しい，嫌，残念，迷惑

表 2: 好意と悪意を表す単語のジャンル

書き手の好意を表す単語	書き手の悪意を表す単語
褒め言葉	相手をけなす言葉
励ます言葉	相手をくじく言葉
好意を表す言葉	悪意を表す言葉
思いやりを表す言葉	薄情さを表す言葉
感謝の言葉	相手を恨む言葉
許可を表す言葉	禁止を表す言葉
挨拶	無視

3.2.2 好意と悪意を表す単語のジャンルの収集

こうして得られた対話データに対して，人手で用意した感情表現によってリプライを「読み手が書き手に対して好意や悪意を抱いていることがわかるリプライ」に分類した．ここでの書き手とは，ツイートの発信者のことを指し，読み手とは，リプライの発信者のことを指す．読み手が好意や悪意を抱いた時のリプライそれぞれにおいて人手で 4 個ずつの感情表現を用意し，それらの含まれるリプライを読み手が好意や悪意を抱いた時のリプライとした．以下の表 1 に用意した感情表現を示す．

さらに，分類された「読み手が書き手に対して好意や悪意を抱いた時のリプライ」の返答先のツイートを「書き手から読み手に対する好意や悪意を表す単語が含まれるツイート」とした．

そして，分類された「書き手から読み手に対する好意や悪意を表す単語が含まれるツイート」中の頻出表現から，書き手の好意や悪意を表す単語の大まかなルールを見出し，書き手の好意や悪意を表す単語のジャンルとして分類した．例えば，書き手の好意を表すジャンルとして,「カッコイイ」などの褒め言葉や,「頑張れ」などの人を励ます言葉が挙げられる．分類したジャンルを表 2 に示す．

こうして得られた表 2 のジャンルの特徴に当てはまる単語や単語の組合せによる表現を挙げることで単語辞書を構築した．実際に登録した単語の例を表 3 に示す．

3.3 文章作成インタフェース

本節では，ユーザが文章を作成するためのインタフェースについて述べる．本システムはテキストデータのための総合環境 TETDM(Total Environment for Text Data Mining)[砂山 13] 上で構築した．システムの表示例を図 3 に示す．

3.3.1 好意と悪意を表す単語の可視化

3.2 節で抽出した単語を，書き手の好意を表す単語をオレンジ色，悪意を表す単語を水色でハイライトして表示する．文章の 1 行目から 1 文毎に単語辞書を参照して，文章中に単語辞書内の単語と入力文章の表現が一致した場合，一致した部分をハイライトして表示する．これによって文章修正を促す．

3.3.2 文章修正を促すメッセージ表示機能

文章の内容に応じてユーザに文章修正の指針をメッセージとして表示する．表 4 に，メッセージの表示条件と表示内容を示す．これらのメッセージによって，文章修正を促す．メッセージの表示条件に「好意を表す単語を含む文が 3 文以上にある」という条件があるが，これは 3.1 節で述べたように，最初と最後また文章の要点となる文に好意を表す単語を含む文があると読み手に良い印象を与えることができるという考えに基づいて

表 3: 辞書単語とジャンルの例

ジャンル	単語例
誉め言葉	すごい，素晴らしい，立派，かっこいい
励ましの言葉	頑張って，ファイト，ドンマイ，気にするな
けなす言葉	意地悪，自己中心，不細工，情けない
くじく言葉	無理だ，駄目だ，無駄だ，無茶だ

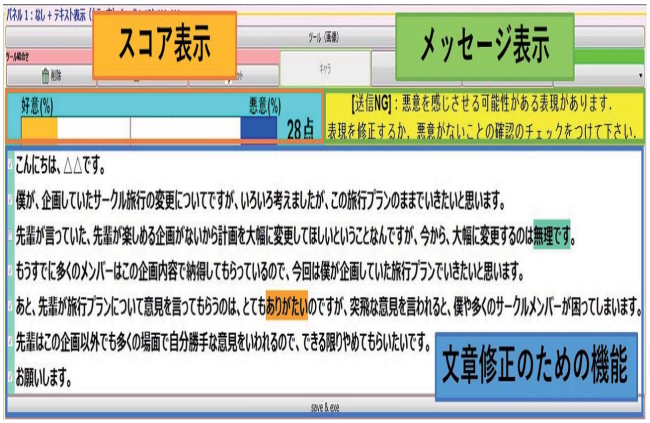


図 3: システムの表示例

いる．

3.3.3 文章のスコア表示機能

文章の内容を点数化，また可視化表示することで，現在の文章を定量的に評価する．3 節でハイライトした好意と悪意を表す単語の含まれる文の数を受けて，全文中における割合を算出し，それぞれオレンジ色と青色の棒グラフで可視化する．好意と悪意を表す棒グラフの原点はそれぞれ左右の端であり，100 %の点は棒グラフの中央である．また，好意を表す単語が含まれる文章の割合 1 %毎に 2 点としてスコアを算出し表示している．文章中のハイライトされている文の割合を視覚的に表現して，ユーザの文章修正の目安として活用してもらう．

3.3.4 文章修正のための機能

文章を編集する機能，システムの再描写機能，チェックボックス機能で構成されている．文章を編集する機能では文章を 1 文ずつ編集することが出来る．文末に全角の「.」または「。」を追加することで文の数を増やすことが出来る．システムの再描写機能では，編集した文章をシステムに再入力するボタンを表示する．チェックボックス機能では，悪意を表す単語が含まれる文の先頭にのみチェックボックスを表示し，これにチェックをすることで，チェックされた文において単語を悪意を表す単語として表示しないようにし，スコア表示とメッセージ機能を再描写する．悪意を表す単語について，修正しなくてもそのままの表現で問題ない場合にチェックボックスにチェックをすることで，問題ないことを確認することが出来る．

4. 良好な人間関係の構築に向けた文章作成支援機能の効果の検証

4.1 実験目的

本実験では，好意と悪意を表す単語の可視化機能，また文章作成インタフェースを利用することによって，読み手が良い印象を抱く文章の作成を支援出来るかを評価する．

4.2 実験方法

表 5 に示す 4 つの状況設定において，指定の目的を達成するメールを，10 分程度でシステムを用いずに作成してもらった．そして作成したメールをシステムに入力してシステムを用いてメールの修正を 10 分程度で行ってもらった．ここで，システムを用いずに作成したメールを「修正前のメール」とし，システムを用いて修正したメールを「修正後のメール」とする．これを 9 人の理系学生を被験者として行った．

表 4: メッセージの表示条件と表示内容

表示条件	メッセージ (上のメッセージを優先)
悪意を表す単語を含む	[送信 NG]：悪意を感じさせる可能性があります. 悪意がないことの確認のチェックをつけて下さい.
好意を表す単語を含む文が 3 文未満	[送信微妙]：好意を感じさせる表現が少ないです. 出来るだけ多く，好意的な表現を追加して下さい.
好意を表す単語を含む文が 3 文以上	[送信 OK]：送信しても問題ありません. より多くの好意的な表現を追加して， 高得点の状態で送信しましょう.

表 5: メールの作成課題の状況設定

	送信相手	送信相手について	送信したいメール
1	同じサークルの異性の先輩	自己中心的な性格で，普段からあなたを含め周りの人のことを全く考えない発言や行動をする先輩.	あなたが企画したサークル旅行について先輩が楽しめる企画が少ないから計画を大幅に変更するようにと自分勝手な事を言われた．あなたの周りのメンバーは，計画に概ね同意している．そこで，先輩に自分勝手な主張はやめてもらい普段からみんな困っていると文句を言いたい
2	同じ学科の同性の先輩	成績優秀でいつもやさしく，先生や周りの人からの評価も高くあなた自身も憧れている先輩.	期末試験に向けて，勉強でわからないところを質問したら個人的に時間を取ってくれて，丁寧にわかりやすく教えてもらったので感謝のお礼を伝えたい. また先輩ともっと仲良くなりたい.
3	同じ研究室の同性の後輩	自分を含め，後輩から見て先輩にあたる人達に，普段からタメ口で文句を言うなど，その態度や言葉遣いが問題視されている.	研究室の研究報告会で，自分がしたコメントに対して，不満そうな顔をした上で，ぶっきらぼうに「それはない」と言った．先生からはその指摘は正しいという言葉も貰っている．報告会での態度を謝るようにまた普段からも最低限の礼儀をわきまえるように指導したい.
4	同じサークルの気になる異性	普段から仲良く話をする相手．とても気が合って数人で一緒に遊びに行く事もある．服装にこだわるおしゃれさん.	次の土曜日に，普段のおしゃれさから自分の服装にもアドバイスをもらいたいという話から入り自分と二人で遊びに行く誘いのメールをしたい.

さらに、先程の手順で作成されたメールが，自分宛てに送られてきたという仮定で，メールの送り主にどの程度好感を持ったか，別の 10 人の理系大学学部生を評価者として評価してもらった．評価方法は 1 点から 7 点の 7 段階評価 (7 点が最高点) で，この評価を 9 人 (被験者数) × 2 種類 (修正前と修正後) × 4 種類 (状況設定) = 72 種類 のメールに対して行った．また，評価を選んだ理由を回答してもらった．

4.3 結果と考察

4.3.1 システムの有無による文章好感度の比較

システムを用いることで，修正前後で好感度が高くなるか検証する為に，4 つの状況設定における被験者の修正前後のメールの好感度の合計を図 4 に示す．ここでの差は修正後から修正前の好感度を引いたものである．図 4 より，殆どのユーザにおいて修正前後で好感度が高くなる事がわかる．

また，システムによって悪意を表す単語を削除することで，読み手の印象が良くなるか検証するために，悪意を表す単語が含まれていた修正前のメールのうち，その単語を修正したメールとしなかったメールとで好感度の変化を検証した．その結果を表 6 に示す．状況設定 2 と 4 には悪意を表す単語は用いなかったため，表から除外した．表 6 より，状況設定 1,3 において悪意を表す単語を修正したメールの方が好感度が上がっていることが分かる．また，実際の修正例を表 8 に示す．これは状

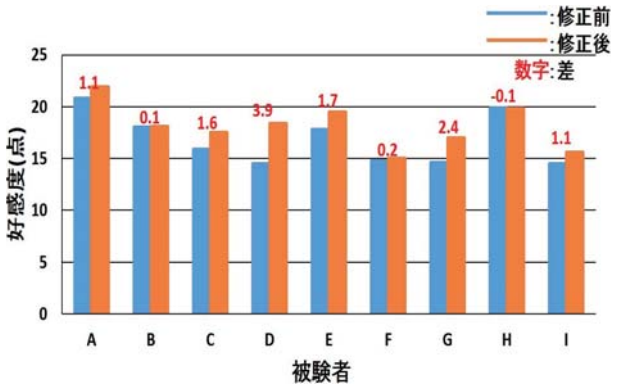


図 4: 4 つの状況設定の平均値

表 6: 悪意を表す単語の修正の有無による修正前後の好感度の差

	状況設定 1	状況設定 3
修正有り	1.70	0.55
修正無し	0.15	0.10

況設定 3 について作成されたメールであり，悪意を表す単語を修正して柔らかい表現にしている．さらに，好感度が上昇していることが分かる．これより，システムによって悪意を表す単語を修正することで読み手の印象が良くなることが分かる．

さらに，システムによって好意を表す単語を追加することで，読み手の印象が良くなるか検証した．その結果，好意を表す単語を追加しているメールの全てにおいて好感度が大きく上がるわけではなかった．どのように好意を表す単語を追加すればよいか以下で考察する．

4.3.2 文章修正量と好感度の関係

好意を表す単語が追加されているメールのうち，好感度の上がっているメールでは，単語単位での修正ではなく，新しい文の追加や，文章の大幅な修正を行っているメールが多く見受けられた．これより，好意を表す単語を文に追加するだけで好感度を上げることは出来ず，文章の大幅な修正が必要であると考えられる．

これを検証するために，被験者が各状況設定において修正した文の数と修正前後での好感度の差の相関を調査したところ，状況設定 1，2，3，4 でそれぞれ 0.52，0.29，0.44，0.51 となった．これより，状況設定 1，3，4 についてある程度相関があることがわかった．よって文章の修正量が多い程，好感度は上がりやすいということが推測できる．また，実際の修正例を 7 に示す．これは状況設定 2 について作成されたメールであり，修正によって最後に感謝を伝える文を追加しており，好感度は上昇している．一般的に考えても修正後の方が読み手の印象がより良いだろう．これより，システムによって好意を表す単語を単語単位で追加するのではなく，文単位での大幅な修正を行うことで好感度を上げることが出来ると考えられる．

5. 結論

良好な人間関係の構築のための文章構成支援を行うために，文章の書き手の読み手に対する好意，悪意を表す単語を可視化し，書き手に文章修正を促すシステムを実装した．

また，実験より，システムによって悪意を表す単語を修正し，好意を表す単語を含む文を追加することで読み手に良い印象を与える文章の作成を支援する事が出来るとわかった．今後の課題として，修正案の提示や文脈をもとに好感度を判定することが挙げられる．

表 7: 状況設定 2 における被験者 G の作成したメール

好感度	本文
修正前 (4.6 点)	こんにちは、△△です。 期末試験前の忙しいときに、テスト勉強に 付き合ってもらいありがとうございます。(中略) あと、今後も課題やテストで何か聞くと思いますので そのときはまたお世話になります。
修正後 (5.4 点)	こんにちは、△△です。 期末試験前の忙しいときに、テスト勉強に 付き合ってもらいありがとうございます。(中略) あと、今後も課題やテストで何か聞くと思いますので そのときはまたお世話になります。 本当にありがとうございました。

表 8: 状況設定 3 において被験者 C の作成したメール

好感度	本文
修正前 (2.2 点)	○○君、△△です。 先日の研究室の研究報告会にて私の指摘に対して (中略) また、あなたは普段から私を含む先輩に対して 態度や言葉遣いが悪いですよね。敬語を使えなどとは 言いませんが、最低限の礼儀はわきまえるべきだと 思います。以後気を付けるようにしてください
修正後 (3.0 点)	○○君、△△です。 先日の研究室の研究報告会にて私の指摘に対して (中略) また、あなたは普段から私を含む先輩に対して 態度や言葉遣いが適切ではないですよね。敬語を使えなどとは 言いませんが、最低限の礼儀はわきまえるべきだと 思います。私たちが卒業するまでの短い間では ありますが、こちらとしてはあなたを含む後輩と 良い関係を構築したいと思っています。 以後気を付けるようにしてください。

参考文献

[石川 18] 石川葉子, 水上雅博, 吉野幸一郎,Sakti Sakriani, 鈴木優, 中村哲：感情表現を用いた説得対話システム, 人工知能学会論文誌,Vol.33,No.1 ,pp.1–9 (2018)

[長谷川 14] 長谷川貴之, 鍜治伸裕, 吉永直樹, 豊田正史：オンライン上の対話における聞き手の感情予測と喚起, 人工知能学会論文誌,Vol.29 ,No.1 ,pp.90–99 (2014)

[板倉 09] 板倉由知, 白井治彦, 黒岩丈介, 小高知宏, 小倉久和：様々な文書を対象とした段落一貫性の解析, 研究報告自然言語処理（NL）,Vol.192 ,No,9 ,pp.1–6 (2009)

[高井 07] 高井一輝, 河口信夫：ACS:多様な人間関係を表現可能なソーシャルネットワーキングシステム, 情報処理学会論文誌,Vol.48 ,No.7 ,pp.2328–2339 (2007)

[Murdock Jr. BB 62] Murdock Jr. BB : The serial effect of free recall. ,J ExpPsychol. ,Vol.64 ,No.5 ,pp.482–488 (1962)

[Daniel 99] Kahneman Daniel,Diener Ed.,Schwarz Norbert:Objective Happiness. ,The Foudations of Hedonic Psychology ,pp.3–25 (1999)

[砂山 13] 砂山渡, 高間康史, 西原陽子, 徳永秀和, 串間宗夫, 阿部秀尚, 梶並知記:テキストデータマイニングのための統合環境 TETDM の開発, 人工知能学会論文誌,Vol.28 ,No.1 ,pp.1–12 (2013)

[Twitter] Twitter.com,
(URL)https://dev.twitter.com/docs/api/

[3G1] [General Session] 9. NLP / IR

座長:星野 綾子（日本電気株式会社）

Thu. Jun 7, 2018 1:50 PM - 3:30 PM Room G (5F Ruby Hall Hiten)

[3G1-01] A Method for Detecting Overgeneralized Be-Verb based on Subject-compliment Identification

○Ryo Nagata[1,2], Shoya Nishite[1], Hokuto Ototake[3] （1. Konan University, 2. JST,PRESTO, 3. Fukuoka University）

1:50 PM - 2:10 PM

[3G1-02] Semantic Graph-based Simple Semantic Textual Similarity Metrics

○Takaaki Tanaka[1], Masaaki Nagata[1], Yuki Arase[2], Makoto Onizuka[2] （1. NTT Communication Science Laboratories, 2. Osaka University Graduate School of Information Science and Technology）

2:10 PM - 2:30 PM

[3G1-03] Extraction of rare cause-result expressions from summary of financial statements

○Hiroyuki Sakai[1], Hiroki Sakaji[2], Risa Murono[1], Ryozo Kitajima[1], Jason Bennett[3] （1. Seikei University, 2. The University of Tokyo, 3. Sumitomo Mitsui Asset Management Company, Limited）

2:30 PM - 2:50 PM

[3G1-04] Automatic alignment of figures and tables with texts in scientific literatures

○Hiroto Shinoda[1], Ichiro Nakaema[1], Hidetsugu Nanba[1], Toshiyuki Takezawa[1] （1. Hiroshima City University）

2:50 PM - 3:10 PM

[3G1-05] Semantic Parsing in ccg2lambda and its Application to Financial Document Processing

Yasunori Hokazono[4], Takahiro Hasegawa[5], Kazuki Watanabe[2], ○Kana Manome[1], Yukiko Yana[1], Hitomi Yanaka[2], Ribeka Tanaka[1], Pascual Mart'inez-G'omez[3], Koji Mineshima[1], Daisuke Bekki[1] （1. Ochanomizu University, 2. University of Tokyo, 3. National Institute of Advanced Industrial Science and Technology, 4. Nomura Research Institute, 5. Omega Partners）

3:10 PM - 3:30 PM

©The Japanese Society for Artificial Intelligence

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

主語と補語の意味的関係を考慮したbe動詞の過剰一般化誤り検出

A Method for Detecting Overgeneralized *Be*-Verb based on Subject-compliment Identification

永田 亮[*1][*2] 西手 翔矢[*1] 乙武 北斗[*3]
Ryo Nagata Shoya Nishite Hokuto Ototake

[*1]甲南大学 Konan University
[*2]国立研究開発法人科学技術振興機構，さきがけ JST, PRESTO
[*3]福岡大学 Fukuoka University

This paper addresses the detection of overgeneralization of *be*-verb found in learner English. It is an error where the subject and complement are not semantically equivalent in a *be*-verb sentence as in **Paris is rain.* This paper presents a method for detecting it by predicting through word embeddings whether a given subject and complement pair is semantically equivalent or not. This paper also presents a method for determining the hyperparameters in the method efficiently and effectively. Experiments show that the present method outperforms two baseline methods based on corpus statistics and WordNet ontology. Looking into the detection results brings out a way of generating feedback messages for learners that explain why the detected error is not a valid English expression.

1. はじめに

英語を対象にした文法誤り検出の性能は著しく向上しているが, 依然として研究例の少ない誤りも存在する. その代表例に，be 動詞の過剰一般化誤りがある．be 動詞の過剰一般化誤りとは, 例えば，“*Paris is rain.（パリは雨だ。）” のように，意味的な関係が同一でない主語と補語を be 動詞でつなげる誤りを指す[*1].

be 動詞の過剰一般化誤りは日本人英語学習者によくみられる誤り [小島 88] であり，検出対象として重要である．この種の誤りが頻出する主な要因に母語からの影響がある [小島 88]. したがって，語学学習支援という観点からは，母語における be 動詞相当表現と英語の be 動詞の用法の違いを学習者に説明できることが望ましい．そのためには，まずは，be 動詞の過剰一般化誤りを他の誤りと区別して検出できる必要がある．

従来の文法誤り検出／訂正手法では，be 動詞の過剰一般化誤りを検出することは難しい．冠詞や前置詞など代表的な文法誤りの検出では，対象語（冠詞や前置詞）の周辺情報に基づいて正しい語を選択するという分類問題を解くことが多い．しかしながら，この方法は be 動詞の過剰一般化誤りに適用することは困難である．そもそも be 動詞の過剰一般化誤りの場合，周辺情報から正しい be 動詞を選択するという問題ではない. 上の例でみたように，be 動詞の過剰一般化誤りの検出では，主語と補語の組み合わせが意味的に同一かどうかを判別しなければならない．be 動詞の過剰一般化誤りの情報が付与された学習者コーパスは皆無であるため，正誤を判定するという分類問題 [Izumi 03] としても解くことも困難である．翻訳問題として文法誤り訂正を解く手法（例えば文献 [Chollampatt 16]）であれば，一部の誤りについては訂正できる可能性はある．しかしながら，誤りの種類を区別せず全ての誤りを同時に訂正するため，誤りの理由は説明できない．また，be 動詞の過剰一般化誤りには，翻訳問題として解くことが難しい，文全体を書き換える必要のある誤りが少なくない（例：“*Paris is rain.” → “It is raining in Paris.”）.

そこで，本稿では be 動詞の過剰一般化誤りを検出する手法を提案する. 上で述べた通り be 動詞の過剰一般化誤りの検出には, 主語と補語の意味的な同一関係の判定が重要となる．提案手法では，単語の分散表現を利用して，この問題を解決する．単語の分散表現は，単語の通時的な意味変化を捉える研究 [Hamilton 16] や英語と日本語の意味のずれを検出する研究 [Takamura 17] などに応用されており，意味的な同一関係の判定にも適していると予想される．提案手法では，単語の分散表現を利用して意味的に同一でないと判定された主語と補語の組を be 動詞の過剰一般化誤りとして検出する.

本研究の貢献は次の通りである. 我々が知る限り，提案手法は，世界初の be 動詞の過剰一般化誤り検出手法である．その性能は，二種類のベースライン（主語と補語の共起に基づいた手法と WordNet [Miller 95] のオントロジーに基づいた手法）よりも有意に高い．また，検出結果を利用して，誤りの理由を自動的に説明する方法も示す.

2. be 動詞文と be 動詞の過剰一般化誤り

本稿では **be 動詞文**を次のように定義する：

be 動詞文：第 2 文型の文のうち， 動詞が be 動詞である，かつ主語，補語どちらとも名詞である文.

この定義の下の be 動詞文には，次の二つの用法がある [Quirk 85].

同一性の表示： 主語と補語が意味的に同一であることの表示.
例) Kevin is my brother.

特徴づけ： 主語の名詞を補語により特徴づける.
例) Dwight is an honest man.

以降, 本稿では，この二つの用法をまとめて同一関係と表記することにする.

上述の通り，be 動詞文中の主語と補語は同一関係になければならないが, 学習者の英文では，そうでない場合がある[*2]. 本稿では，これを be 動詞の過剰一般化誤りと呼ぶ. 以降では，特に断らない限り，be 動詞の過剰一般化誤りを，単に，過剰一般化誤りと表記する.

連絡先: 永田亮，甲南大学，nagata-ai @ hyogo-u.ac.jp.

*1 厳密な定義は 2. 節で述べる.

*2 実際には，英語でも “I’m coffee.” という表現が可能である．しかしながら，限られた場面でのみ用いられる特殊な用法である．学習者が取り組むライティングで用いられることは稀である.

過剰一般化誤りが起こる要因の一つに母語干渉がある．例えば，日本語には，be 動詞文に（見かけ上の）用法が類似する「〜は〜だ。」という表現がある．この表現では，主語と補語が意味的に同一関係にない場合でも使える. 例えば,「パリは雨だ。」,「今日は学校だ。」,「飛行機は危険だ。」のように表現できる．日本語のこの用法が英語に適用され過剰一般化誤りが起こると分析できる．このように，母語の be 動詞相当表現に，主語と補語が同一関係でないものを結びつける用法があると，過剰一般化誤りが起こりやすい.

3. 提案手法

3.1 検出手順

提案手法の誤り検出手順は次の通りである：(1) 検出対象文書の入力；(2) 主語と補語の抽出；(3) 主語と補語の同一関係の判定；(4) 誤り検出；(5) 後処理；(6) 検出結果の出力.

手順 (1) で，検出対象となる文書から各文を読み込む．手順 (2) で，入力文を依存構造解析し, 主語および補語となる主名詞を抽出する．抽出対象とするのは，be 動詞文のみである．手順 (3) では，主語と補語の同一関係の判定を行う．この処理の詳細については，3.2 項で述べる．手順 (4) で，判定結果に基づいて誤り検出を行う．同一関係にないと判定された主語と補語の組み合わせを誤りとする．手順 (5) で，後処理として，検出結果に対する例外処理を行う．具体的には，主語または補語が次の単語の場合は，手順 (4) の結果にかかわらず常に正しいと判定する：it，they，this，these，that，those，thing，things．これらの語は，指し示す意味範囲が非常に広いため誤り検出対象外とする．最後に，手順 (6) で，検出結果を出力する.

3.2 主語と補語の意味的同一関係の判定

主語と補語の意味的な同一関係の判定は単語の分散表現を利用して行う．そのため，単語の分散表現を大規模な母語話者コーパスから，あらかじめ学習しておく.

主語と補語の意味的な同一関係の判定を定式化するため，次の記号を導入する．いま，主語と補語を，それぞれ s と c で表す．また，それぞれに対する分散表現（ベクトル）を $\boldsymbol{v}_s$ と $\boldsymbol{v}_c$ で表す.

このとき，主語 s と補語 c の同一関係の判定を $\boldsymbol{v}_s$ と $\boldsymbol{v}_c$ の余弦類似度に基づいて行う．具体的には，θ を閾値として，

$$\cos(\boldsymbol{v}_s, \boldsymbol{v}_c) > \theta \tag{1}$$

を満たす主語 s と補語 c との組み合わせを同一関係にあると判定する（閾値 θ の決定方法は，3.3 項で説明する）．すなわち，主語と補語が同一関係にあるかどうかを，余弦類似度で測定された主語と補語の類似度に基づいて近似的に判定していることになる．これは，一見荒い近似にみえるが，5. 節で示すように，その判定精度は高い．なお，低頻度な単語に対しては，分散表現がうまく学習できない可能性が高いため，訓練データ中での頻度が一定以上の主語と補語に対してのみ，式 (1) を用いて同一関係の判定を行う．それ以外の場合は，常に正しいと判定する.

3.3 ハイパパラメータの推定方法

提案手法で，高い検出性能を達成するためには，ハイパパラメータを適切に設定することが重要となる．具体的には，式 (1) の閾値 θ，分散表現の次元数や文脈窓幅などのハイパパラメータである．通常は，開発データを用いて決定することが多い．しかしながら，過剰一般化誤りの情報が付与された学習者コーパスが乏しい現状では，この方法の利用は現実的でない.

解決策として，母語話者コーパスから，ハイパパラメータ決定用の疑似的な開発データを生成する．その手順の概要を図 1 に示す．まず，母語話者コーパスから，3.1 項の手順 (1) と (2) を用いて，主語と補語の組を抽出する（図 1（1））．次に，得られたペアのうち，主語または補語が学習者コーパスに一度も出現しないものを除外する（図 1（2））[*3]．これは，学習者の英文に極力近い単語からなる開発データを生成する目的で行う．この結果を，同一関係にある正しい組み合わせとみなす（以降，この組を集めたものを正例データと呼ぶ）．次に，正例データから，主語と補語をそれぞれ独立にランダムに抽出して新たな組を作る（図 1（3））．ただし，新たに作られた組が正例データに存在する場合は除外する．得られた組を，同一関係にない主語と補語（すなわち，過剰一般化誤り）とみなす（以降，この組を集めたものを負例データと呼ぶ）．最後に，正例データと負例データを統合して疑似的な開発データとする（図 1（4））．この疑似的な開発データを対象にして，様々なハイパパラメータで誤り検出を行い，その検出性能（例えば，F 値）を見積もる．性能値が最大となる組み合わせを選択する.

以上の手順を実施するためには，正例データと負例データを混合する割合が問題となる．本稿では，事前分布に基づいて決定する．言い換えれば，be 動詞文のうち何割が過剰一般化誤りになるかの事前知識に基づいて，負例データを生成する割合を決定する．厳密には，事前分布の推定のためには訓練データが必要であるが，訓練データの希少性を考慮し，本稿では事前分布は与えられているとする.

更に，頑健なハイパパラメータ推定とするため，提案手法では，複数の分散表現を利用する．まず，ハイパパラメータ（例えば，文脈窓幅や次元）が異なる複数の分散表現を得る．次に，それぞれの分散表現について，上述の方法で，式 (1) の閾値 θ を決定する．最後に，各分散表現を用いて誤り検出を行い，その多数決を最終的な検出結果とする．多数決をとることにより，より頑健な誤り検出となることが期待される.

4. 評価実験

検出対象として，Konan-JIEM Learner Corpus 第 5 版 [Nagata 16]（KJ）を使用した．KJ には，過剰一般化誤りの情報は付与されていないため，人手により新たに誤りの情報を付与した．まず，Stanford Parser Ver.3.5.0[*4]の LexicalizedParser を用いて KJ を解析し，be 動詞文および主語と補語の組を抽出した．その結果，294 の主語と補語の組が得られた．この 294 組に対して，原文を見ながら，第一著者と第二著者が独立に正誤のタグを付与した．その後，不一致する箇所について両者で相談し，最終的な正誤を決定した．その結果，83 の過剰一般化誤りを同定した.

分散表現の訓練については，文分割とトークン同定済みの One Billion Word Model Benchmark[*5]中の news.en-00001-of-00100 から news.en-00099-of-00100 を用いた[*6]．次元数を

*3 学習コーパス中で出現するかどうかの判定は，主語，補語以外の使用も考慮して行う.

*4 https://nlp.stanford.edu/software/lex-parser.shtml

*5 http://www.statmt.org/lm-benchmark/

*6 訓練には，word2vec（https://github.com/tmikolov/word2vec）を用いた．使用したハイパパラメータの値は次のとおりである：-negative 25 -sample 1e-4 -iter 15 -cbow 1 -min-count 5．なお，全てのトークンを小文字に変換した.

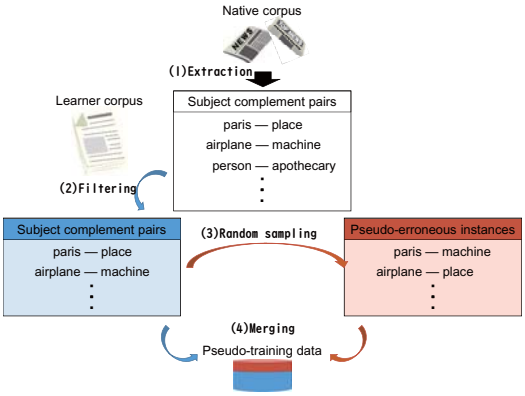


図 1: 擬似的な開発データの生成の流れ.

200，400，800，文脈窓幅を 5，10，15，20，25 とした計 15 種類の分散表現を用いた．ただし，訓練コーパス中での出現頻度が 5 回以上の単語のみを対象とした（それ以外のパラメータは脚注のように固定した）．

閾値の決定にも同じコーパスを用いた．負例データの割合は，KJ での過剰一般化誤りの割合に合わせて 28%とした．このデータを対象にして，閾値を 0〜1 の範囲で 0.01 刻みで変化させたときの F 値を算出し，F 値が最大となる閾値を選択した．なお，本評価は，過剰一般化誤りの割合に関する事前知識を用いているため，厳密にはブラインドテストではないことに注意が必要である．

比較のため，2 種類のベースライン手法を実装した．一つ目は，共起に基づいた手法である．すなわち，母語話者コーパス内で一度も出現しない主語と補語の組み合わせを誤りとする手法である．二つ目は，Lin の類似度 [Lin 98] に基づいた手法とした．Lin の類似度は，WordNet のオントロジーに基づいて計算される，二単語間の意味的な類似性を表する指標である．主語と補語の組に対する Lin の類似度を求め，閾値以下となる場合を誤りと判定した．閾値については，このベースラインの性能限界を明らかにするため，検出対象である KJ 上で F 値が最大になる値を設定した（したがって，このベースラインについても完全なブラインドテストではない）．両ベースラインとも，提案手法の場合と同一のコーパスと解析器を利用した．また，提案手法と条件を合わせるため，主語，補語共に母語話者コーパスでの頻度が 5 以上のみの場合を検出対象とした（これ以外の場合は，常に正しいと判定した）．

評価尺度は，判定精度（正誤の判定に成功した主語，補語の組の数を主語，補語の組の総数で除した値）を用いた．また，再現率，適合率，F 値も用いた．

表 1 に，結果を示す．表 1 には，参考として，KJ に対する F 値が最大となるハイパパラメータを用いた提案手法の性能「提案手法（最適ハイパパラメータ）」も記載している．なお，全て正しいと判定した場合の判定精度は 0.717（=211/294）である．表 1 から，提案手法の方が，ベースライン手法よりも判定精度，F 値共に高いことがわかる；提案手法（推定ハイパパラメータ，多数決あり）と最も性能がよいベースライン（「ベースライン（共起）」）における，判定精度の差は有意である（MacNemar 検定，$p = 0.015$）．コーパス内での単純な共起に基づくと，スパースネスの問題により誤判定が多くなることがわかる．一方，提案手法では，より高い精度で，意味的な同一関係の判定に成功している．提案手法は，高い適合率が求められる語学学習支援への応用に特に適しているといえる．

提案手法（推定ハイパパラメータ，多数決あり）と提案手法（推定ハイパパラメータ，多数決なし）を比較すると，多数決を取ることの効果がうかがえる．複数の分散表現に基づいた検出結果の多数決を取ることで，最適なハイパパラメータを設定したときに近い性能を達成している．

このことをより詳細にみるために，図 2 に，ハイパパラメータと判定精度の関係を示す．図の横軸は文脈窓幅に対応する．また，縦軸は，判定精度に対応する．各線は，分散表現の次元数に対応する．なお，比較のため，共起に基づいたベースライン手法の判定精度も示している．図 2 より，文脈窓幅を 10 単語以上にとると，大抵の場合，最適なハイパパラメータを設定したときの判定精度に近くなるが，中にはベースラインの性能を下回る場合もあることがわかる．このことは，ハイパパラメータを最適に設定することの重要性を示唆する．多数決を取ることで，ハイパパラメータを唯一の組み合わせに設定する必要がなくなり，よりロバストな検出手法となることもわかる．以上より，開発データが利用可能でない場合は，文脈窓幅も分散表現の次元数もある程度の大きさの範囲に設定し，複数の分散表現による検出結果の多数決をとればよいことがわかる．

5. 考察

提案手法の検出の傾向を明らかにするため，提案手法（最適ハイパパラメータ）による検出結果を分析した．同手法で，余弦類似度が負の値になった主語と補語の組は 20 件であった（全て誤りと判定した）．そのうち，実際に誤りであったのは 12 件（判定精度 60%）であった．この判定精度は一見低いようにみえる．しかしながら，誤検出 8 件中 6 件は，主語または補語が固有名詞であり，それ以外の 12 件の一般名詞における判定精度は 83%と非常に高いことが明らかとなった．また，余弦類似度が 0.3 より大きいの主語と補語の組は，48 件存在した（全て正しいと判定した）．そのうち，実際に正しい組み合わせは，41 件であり，こちらの方も高い判定精度であることが確認できた（判定精度 85%）．これらの結果は，少なくとも一般名詞については，余弦類似度の大小により，主語と補語の意味的な同一関係がある程度判定できることを示す．

全体的に，固有名詞に対して検出に失敗する傾向が見られた．日本人名や日本の地名などの固有名詞は，母語話者コーパスでは出現回数が少なく，信頼性の高い分散表現が得られなかった可能性がある．更に，一部の名詞については，偶然に英語の固有名詞と同一表記になることがあり，判定失敗の大きな要因となっていた．例えば，“Kobe”（神戸）や “Himeji Oden”（姫路おでん）は，今回用いた母語話者コーパスでは，“Kobe (Bryant)” と “(Greg) Oden”（両者ともバスケットボール選手）としての使用が散見された．そのため，“Kobe is a nice place.” などの表現での誤検出につながる（“Kobe”，“Oden” は全部で 7 回出現し，その内 4 回について検出に失敗していた）．このことから，固有名詞に対しては検出を行わない，別の方法で検出を行うなどの処置が必要なことがわかる．

検出結果をより深く理解するために，検出対象に含まれる 83 の誤りを訂正方法により細分類した．その結果 7 種類を同定した．表 2 に分類結果と対応する再現率を示す．

表 2 より，最も多いのは「文全体を書き換える必要がある誤り」であることがわかる（例：“*Japan was a winter.”）．以降,「主語または補語を別の名詞にすべき誤り（例： *My job is an acceptance.)」,「動詞を変更すべき誤り（例： *I can be fun.）」,「補語を現在／過去分詞にすべき誤り（例： *I was worry.）」,「補語を形容詞にすべき誤り（例： *Airplanes is danger.)」と続く．どの誤りについても，ある程度，検出に成

表 1: 評価結果.

手法	判定精度	再現率	適合率	F 値
提案手法（最適ハイパパラメータ）	**0.786**	0.614	**0.622**	**0.618**
提案手法（推定ハイパパラメータ，多数決あり）	0.762	0.578	0.578	0.578
提案手法（推定ハイパパラメータ，多数決なし）	0.643	0.639	0.414	0.502
ベースライン（共起）	0.673	0.530	0.436	0.478
ベースライン（Lin の類似度，最適ハイパパラメータ）	0.599	**0.735**	0.389	0.509

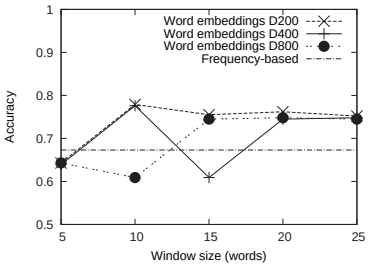


図 2: ハイパパラメータと判定精度の関係.

表 2: 誤りの細分類と再現率.

誤りの種類	再現率
文全体を書き換える必要がある誤り	0.47 (9/19)
主語または補語を別の名詞にすべき誤り	0.50 (9/18)
動詞を変更すべき誤り	0.50 (5/10)
補語を現在／過去分詞にすべき誤り	0.88 (7/8)
補語を形容詞にすべき誤り	1.0 (7/7)
補語の前に前置詞を挿入すべき誤り	0.50 (3/6)
主語と補語の帰属関係が逆である誤り	0.00 (0/1)
その他	0.57 (8/14)
計	0.58 (48/83)

功しており，分散表現に基づいた同一関係の判定が有効であることがわかる．例外としては，主語と補語の帰属関係が逆である誤りがある（例： *Fruits are bananas.）．ここまで，棚上げにしてきたが，提案手法では主語と補語の帰属関係の判定は行わない．したがって，この種の誤りは検出できない．しかしながら，表 2 からわかるように，この種の誤りの頻度は非常に低い．過剰一般化誤りが頻出するのは，学習者が，主語と補語の帰属関係を判断できないためではなく，母語の be 動詞相当表現に備わった他の用法を英語に適用するためであると考えると，この現象をうまく説明できる．これが正しいとすると，主語と補語の帰属関係を判定しなくても，実用上の問題は少ないと予想される．

主語と補語の帰属関係が逆である誤り以外については，母語話者コーパスから得られる統計量に基づいて誤りの種類を識別できる可能性がある．例えば,「補語を形容詞にすべき誤り」では，補語の名詞に対応する形容詞があるかを辞書で確認し，存在すれば，主語，be 動詞，形容詞の三つ組の頻度をコーパスから得る．そのほかの誤りでも同様に（例えば,「動詞を変更すべき誤り」であれば，主語，動詞，目的語（= 補語）の三つ組）の頻度を得る．それらの頻度を適切に正規化して比較することで誤りの種類を特定できる可能性がある．その結果，例えば,「be 動詞文では，主語と補語は，意味的に同一なものを用いなければなりません．補語 “danger” を形容詞に代えられませんか？」のような説明が可能となる．仮に，有効な統計量が得られなければ,「文全体を書き換える必要がある誤り」であるとし,「文全体を書き換えて別の表現にしてみましょう.」などの説明を与えることが考えられる．

6. まとめ

本稿では，主語と補語の意味的な同一関係の判定に基づいて，be 動詞の過剰一般化誤りを検出する手法を提案した．評価実験により，提案手法の性能は，共起に基づいた手法および WordNet のオントロジーに基づいた手法よりも有意に高いことを示した．また，検出結果を利用して，be 動詞の過剰一般化誤りに対する解説を自動生成する方法も示した．

謝辞

本研究は，JST，さきがけ，JPMJPR1758 の支援をうけたものである．

参考文献

[Chollampatt 16] Chollampatt, S., Taghipour, K., and Ng, H. T.: Neural Network Translation Models for Grammatical Error Correction, in *Proc. of 25th IJCAI* (2016)

[Hamilton 16] Hamilton, W. L., Leskovec, J., and Jurafsky, D.: Diachronic Word Embeddings Reveal Statistical Laws of Semantic Change, in *Proc. of 54th ACL* (2016)

[Izumi 03] Izumi, E., Uchimoto, K., Saiga, T., Supnithi, T., and Isahara, H.: Automatic error detection in the Japanese learners' English spoken data, in *Proc. of 41st ACL* (2003)

[Lin 98] Lin, D.: An Information-Theoretic Definition of Similarity, in *Proc. of 15th International Conference on Machine Learning* (1998)

[Miller 95] Miller, G. A.: WordNet: A Lexical Database for English, *Communications of the ACM*, Vol. 38, No. 11 (1995)

[Nagata 16] Nagata, R. and Sakaguchi, K.: Phrase Structure Annotation and Parsing for Learner English, in *Proc. of 54th ACL* (2016)

[Quirk 85] Quirk, R., Greenbaum, S., Leech, G., and Svartvik, J.: *A Comprehensive Grammar of the English Language*, Longman, New York (1985)

[Takamura 17] Takamura, H., Nagata, R., and Kawasaki, Y.: Analyzing Semantic Change in Japanese Loanwords, in *Proc. of 15th EACL* (2017)

[小島 88] 小島 義郎, 日本語の意味 英語の意味, 南雲堂 (1988)

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

意味グラフに基づくテキスト類似性尺度の提案

Semantic Graph-based Simple Semantic Textual Similarity Metrics

田中貴秋 *1 永田昌明 *1 荒瀬由紀 *2 鬼塚真 *2
Takaaki Tanaka Masaaki Nagata Yuki Arase Makoto Onizuka

*1NTT コミュニケーション科学基礎研究所
NTT Communication Science Laboratories

*2大阪大学 大学院情報科学研究科
Osaka University Graduate School of Information Science and Technology

We present a novel method of measuring semantic textual similarity (STS) based on semantic graph. We employed UDepLambda as semantic representation and incorporated the semantic graph-based scores with word based scores. The method improve the correlations between automatic correlation metrics and human judgements in comparison to the other semantic graph-based methods in the evaluations of an STS task and an MT evaluation task.

1. はじめに

機械翻訳，自動要約，剽窃検出など自然言語処理の各タスクにおいて，テキスト内容の意味的類似性 (Semantic Textual Similarity, STS) を測定する重要性が高まっている．頑健性を重視した評価方法として，表層，辞書知識，分散表現を含む語彙，および統語構造に基づく評価尺度が，評価型ワークショップ SemEval 2017 [Daniel 17] などで数多く提案されている．また，異なる言語間の類似性尺度については，SemEval でも実施されており，日本語を含んだ言語対についても研究が行われている [羅 16]．これらの方法では，類似性のあるテキストを比較したときに，類似性，および差異のある部分の根拠を示すことが困難であった．

本稿では，意味グラフをアライメントすることを中心として，テキスト間の意味的類似性を測定する手法について提案する．提案手法では，Universal Dependencies (UD) [Nivre 15] に基づく意味表現 UDepLambda [Reddy 17] を用いる．UDepLambda は論理式による意味表現であるが，各変数をノードとすることにより Abstract Meaning Representation (AMR) [Banarescu 13] と同様の有向グラフと見做すことができる．提案手法では，グラフ間のアライメントを行って類似性評価を行うため，類似している部分，および情報の過不足のある部分を明確にできる．

意味グラフの類似性比較手法の代表的なものとして，AMR を対象とした Smatch [Cai 13] が提案されている．Smatch は，純粋に「意味グラフの重複度合い」を計測するものであるが，提案手法は，典型的な比較評価値である，単語類似性，単語列類似性，アライメントの適合度合い等を組み合わせることで，より頑健で人間の感覚に近似する指標を目指している．

また，意味グラフに基づく STS の評価方法の 1 種として，画像からの captioning により生成されたキャプションと正解キャプション群との類似性を計測する SPICE と呼ばれる方法が提案されている [Anderson 16]．SPICE では，Scene Graph [Schuster 15] と呼ばれる主に画像上のオブジェクト，属性，オブジェクト間の関係を表現した意味グラフを tuple に変換し，その tuple の一致度合いを F-measure により計測する．提案手法でも，同様の tuple の 一致度合いを一要素として採用しているが，述語と項の関係など，人間が類似性を判断する上で重視する関係について，重みを加えることで，人間によるアノテーションのスコアと近いものになるようにしている．

連絡先: 田中貴秋，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, tanaka.takaaki@lab.ntt.co.jp

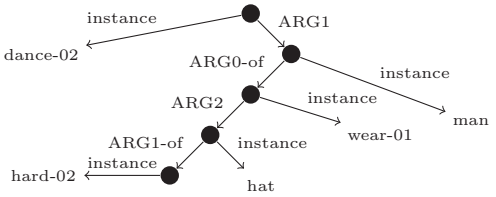


図 1: AMR の例.

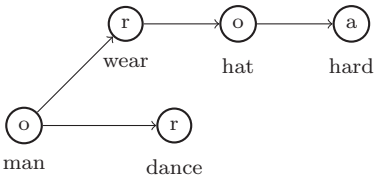


図 2: Scene Graph の例．◯ 内の文字はノードの種類を表している（“o”:object,“a”:attribute，“r”:relation）.

AMR も Scene Graph も基本的に英語を中心として活用されている意味グラフであるが，UDepLambda は ベースとなっている UD とともに多言語処理を念頭において設計されている．本稿では，多言語間の類似性測定への拡張を見据えて，意味表現に UDepLambda を用いた手法を提案し，その有効性を検証する．

STS の測定手法の評価として，2 種類のベンチマークによる実験結果を報告する．一つは，内容的に無関係な文対を含む評価セットに対して，0-5 の絶対評価を行うもので，SemEval の STS benchmark を用いた．もう一つは，翻訳評価手法の妥当性を測るもので，WMT 2015 の Translation Metrics shared task のベンチマークを用いた．提案手法は，STS においては上位システムには及ばないが，翻訳評価タスクでは参加システムと同等の結果を示し，どちらのタスクにおいても，意味グラフに基づく SPICE, Smatch に比較して良い結果が得られたこ

とを報告する．

2. 意味グラフと評価尺度

2.1 AMR

単一の root を持ち，有向グラフで構成される意味表現である (図 1)．AMR の持つ情報には，PropBank [Palmer 05] の意味役割，文内の照応関係，固有表現，モダリティ等がある．AMR の比較手法としては，Smatch[Cai 13] が提案されている．Smatch は，AMR から変換した triple を単位として，2 文間の重なりを調べる．ノードは，entity や event からなり，エッジが relation となる．

2.2 Scene Graph

画像の記述を目的とした有向グラフによる意味表現で Stanford coreNLP [*1] で解析可能な形式 [Schuster 15] である (図 2)．Scene Graph では，object(entity)，attribute, relation がノードになり，エッジには関係ラベルを持たない．Captioning の evaluation を目的とした，SPICE (Semantic Propositional Image Caption Evaluation) [Anderson 16] が提案されている．SPICE では，Graph のノードとエッジをばらして，それぞれの組み合わせを抽出して，2 文間の重なりを F-measure により調べる．各 relation (subject-object などの意味関係) や，color, size などの属性ごとに関係を抽出することも述べられているが，具体的な評価尺度には反映されていない．

2.3 UDepLambda

UDepLambda [Reddy 17] は，多言語共通のアノテーションスキームである UD [Nivre 15] に基づいて提案された論理式タイプの意味表現である．図 3 は，類似した 2 文に関する UD および UDepLambda を示している．ラムダ式による意味表現は，UD による構文解析結果を項の間の照応解析を行って変換している．多言語への適用例として，英語，ドイツ語，スペイン語等のクエリをそれぞれ UDepLambda に変換することにより，同一の枠組みでそれぞれの言語における質問応答システムを実現した結果について報告されているが，意味グラフ間の比較方法については言及されていない．本稿では，UDepLambda の論理式を，AMR タイプの意味グラフと見做して，アライメントを行うことにより類似度を測定する．

3. 提案手法

UDepLamba の 意味グラフに基づくスコアと，単語 (列) に基づくスコアを組み合わせてモデルを構築する．以下，それぞれについて詳細を説明する．

3.1 意味グラフに基づくスコア

SPICE や Smatch で行っているように意味グラフを tuple の形に分解し，対象とする文間の tuple の比較を行う．tuple 間の比較は，Smatch 方式のアライメントスコアに基づくものと，SPICE 方式の F-measure に基づくものを組み合わせる．語彙の比較は，WordNet による類似度スコアあるいは単語分散表現による類似度スコアを用いた．

UDepLambda を用いることで，文法構造の違いを吸収して意味的関係をある程度抽象化できる．その結果，例えば，述語と主格の関係が *nsubj* という関係になっている場合と関係節で *acl* になっている場合を，同一の関係 arg_1 として扱うことができる．これは意味的関係を比較する上で，大きな利点である．また，項の binding を行うことにより，コントロールされている項が解消されている点も意味表現を利用する大きな効用である．例えば，*the children want to swin* から，$(relation, val_1, val_2)$ の tuple を抽出することを考えると，$(arg_1, want, children)$, $(arg_1, swin, children)$ の二つの関係が得られる [*2]．

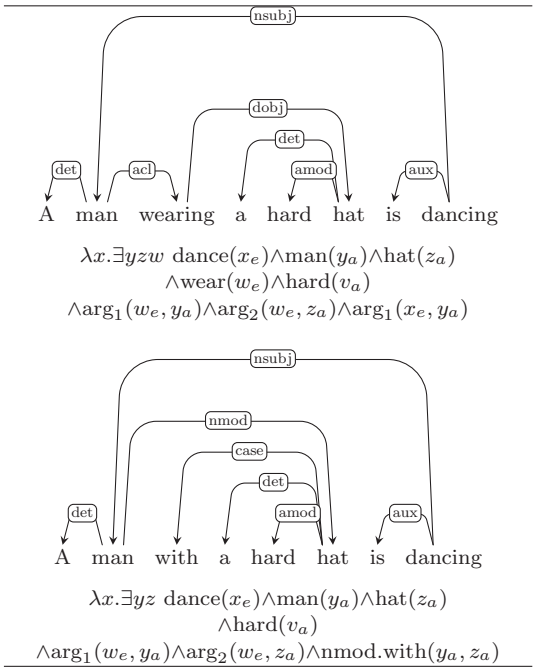


図 3: Universal Dependencies と UDepLambda の例.

ただし，UD, UDepLambda ともに内容語と内容語の間の関係をベースにしているため，述語項構造のように内容語を中心とした関係になっている場合と，前置詞を介した関係になっている場合では，tuple の単位やそれに基づく構造が異なってしまう場合がある．例えば，*a man wearing a hat* と *a man with a hat* における，*man* と *hat* の関係はほぼ同様のものと考えられるが，前者の tuple は，$(arg_1, wear, man)$, $(arg_2, wear, hat)$，後者の tuple は，$(nmod.with, man, hat)$ となりそのまま比較すると類似性を捉えづらい．そこで，同一の内容語を介した複数の tuple に関しては，2 語間の関係を含む tuple に縮約した tuple を新たに追加する．前者の例の場合は，共通の内容語 wear を縮約した tuple $(rel*, man, hat)$ を追加する．$rel*$ は縮約した tuple に付与する関係である．

意味グラフのアライメント Smatch で用いられているように tuple に変換した上でアライメントを行う．ただし，アライメントスコアの算出時に，前述のように内容語ベースの tuple を縮約した tuple を考慮する．

UDepLambda から tuple への変換および，tuple のアライメントは以下のように行う．アライメントは，[Cai 13] で行われているように，初期値から，山登り法によって，アライメントスコアが変化しなくなるまで，探索を行う．局所解に陥る危険性があるが，ここでは計算の簡便性に重きを置いた．

1. 意味グラフのノードから各変数 v を抽出する．比較する 2 文から抽出した変数群をそれぞれ $V_A = \{v_{A1}, ..., v_{Am}\}$, $V_B = \{v_{B1}, ..., v_{Bn}\}$ $(m \leq n)$ とする．
2. 変数 v とインスタンス（entity または event e） を組にした tuple $(inst, v, e)$ を追加する，

*1 https://stanfordnlp.github.io/CoreNLP/

*2 実際の UDepLambda では，変数を介して論理式で得られる．

Genre	Train	Dev	Test	Total	≥ 4	≥ 2	≥ 0
news	3299	500	500	4299	1079	2141	1079
caption	2000	625	525	3250	721	1235	1294
forum	450	375	254	1079	208	432	439
Total	5749	1500	1379	8628	2008	3808	2812

表 1: STS benchmark の統計量 [Daniel 17].

3. 変数 v_i, v_j とその間の関係 r の組を抽出し，tuple $t = (r, v_i, v_j)$ として追加する．比較する 2 文から抽出した tuple 群をそれぞれ T_A, T_B とする
4. head (最初の変数 v_i) が同一の変数を含む複数の tuple $(r_k, v_i, v_j), (r_p, v_i, v_r)$ について，2 変数間の関係を含み縮約した tuple $(rel*, v_j, v_r)$ を新たに追加する．
5. 変数 のアライメントの初期値 $A_0 = (a_1, ..., a_m)$ を定める．ただし，$a_i = j$ は，変数 v_{Ai} と v_{Bj} がアライメントされていることを表している．$a_i = 0$ の場合は，v_{Ai} に対するアライメント先がないことを示す [*3]．
6. アライメントの 1 点を隣接点に変更するか，2 点を入れ替えて作成した A_k を探索候補リストに加える．探索候補リスト中の要素それぞれにアライメントスコア $\sigma_{align}(A_k)$ を求め，最高のスコアを出すもの次の探索候補とする．
7. 前項を，アライメントスコアが向上する候補がなくなるまで繰り返し，探索範囲内でスコアが最高になったアライメントを，アライメント結果とする．

なお，アライメントスコア σ_{align} は，以下のように tuple 間のスコア σ_T の総和で定める．

$$\sigma_{align}(A_k; V_A, V_B, T_A, T_B) = \sum_{\{k,l|a_k=l\}} \sigma_T(t_{Ak}, t_{Bl}) \quad (1)$$

ただし，$t_{Ak} = (r_{Ak}, v_{Ap}, v_{Aq}) \in T_A$，$t_{Bl} = (r_{Bl}, v_{Br}, v_{Bs}) \in T_B$ である．

$$\sigma_T(t_{Ak}, t_{Bl}) = \begin{cases} sim(I(v_{Aq}), I(v_{Bs})) & \text{if } (r_{Ak} = r_{Bl} \text{ or } r_{Ak} = rel* \text{ or } r_{Bl} = rel*) \text{ and } I(v_{Ap}) = I(v_{Br}) \\ 0 & \text{otherwise} \end{cases} \quad (2)$$

ここで，$I(\cdot)$ は，変数からインスタンスへの写像を表しており，$I(v_{Ai}) = e$ のとき，$(inst, v_{Ai}, e) \in T_A$ である．なお，インスタンス e_1,e_2 間のマッチングについては，各インスタンスの属する synset c_1,c_2 の WordNet 上のパスと共通の親 synset の深さによるスコア $sim_{wn}(c_1, c_2)$ [Wu 94]，または GloVe による単語ベクトル $\boldsymbol{v_{e1}}$,$\boldsymbol{v_{e2}}$ の cosine 類似度 $sim_{glove}(\boldsymbol{v_{e1}}, \boldsymbol{v_{e2}})$ を用いて行った．

$$sim_{wn}(c_1, c_2) = \frac{2 \cdot \text{depth}(\text{lso}(c_1, c_2))}{\text{len}(c_1, c_2) + 2 \cdot \text{depth}(\text{lso}(c_1, c_2))} \quad (3)$$

ここで，lso(c_1, c_2) は，synset c_1,c_2 の共通の親のうち最も深い synset, len(c_1, c_2) は，c_1 から c_2 へ辿るパスの長さ，depth$(\cdot)$ は，synset の WordNet 上での深さを表す．

意味グラフの重なり SPICE で行うように意味グラフから変換された tuple 集合の重なりのスコア σ_{ov} を F-measure として算出する．以下で，$T_A \oplus T_B$ は，各 tuple の変数をインスタンスに変換した際に一致する tuple の集合を表している．

$$\sigma_{ov} = \frac{2PR}{P+R} \quad \left(P = \frac{|T_A \oplus T_B|}{|T_B|}, R = \frac{|T_A \oplus T_B|}{|T_A|}\right) \quad (4)$$

*3 本稿では，1 対 1 または 1 対 0 のアライメントを仮定している．

System	Description	Test
ECNU⋆	hybrid	.810
BIT⋆	WordNet	.809
Proposed	UDepLambda	.690
SPICE	Scene Graph	.543
Smatch	AMR	.511

表 2: STS benchmark における人手評価値との相関 (Pearson の積率相関係数 r). ⋆ は，[Daniel 17] より抜粋した．

System	Description	de-en	fr-en
DPMFcomb	1st place in de-en	.482	.395
RATATOUILLE	1st place in fr-en	.441	.398
Proposed	UDepLambda	.398	.398
sentBLEU		.360	.358
SPICE	Scene Graph	.211	.211
Smatch	AMR	.303	.285

表 3: WMT2015 の segment-level 評価 (Kendall's τ).

3.2 単語・単語列に基づくスコア

意味グラフに基づくスコアを補完するため，従来手法で用いられている類似性スコア [Šarić 12, 羅 16] から以下のものを用いる．以下，2 文の単語集合をそれぞれ S_A, S_B と表す．

単語の重なり S_A, S_B で共通する単語の割合を算出する (ϕ_1).

$$\phi_1 = sim_{wo}(S_A, S_B) = \frac{2 \cdot |S_A \cap S_B|}{|S_A| + |S_B|} \quad (5)$$

S_A, S_B の包含関係を表すフラグである (ϕ_2).

$$\phi_2 = \begin{matrix} 1 & \text{iff } (S_A \subseteq S_B) \vee (S_A \supseteq S_B) \neq \emptyset \\ 0 & \text{otherwise} \end{matrix} \quad (6)$$

S_A, S_B を WordNet の synset に変換した場合の重なりを算出する [Šarić 12]. 以下の $P_{wn}(S_A, S_B)$, $P_{wn}(S_B, S_A)$ の調和平均の値を用いる (ϕ_3).

$$\phi_3 = P_{wn}(S_A, S_B) = \frac{1}{|S_B|} \sum_{w \in S_A} score(w, S_B) \quad (7)$$

$$score(w, S) = \begin{cases} 1 & \text{if } w \in S \\ \max_{w' \in S} sim_{wnp}(w, w') & \text{otherwise} \end{cases} \quad (8)$$

ただし，$sim_{wnp}(\cdot, \cdot)$ は，WordNet 上の path 類似度 である．

N-gram の重なり N-gram の重なりの度合いとして，unigram, bigram, trigram における共通する n-gram の割合を算出する (ϕ_4,ϕ_5,ϕ_6) [Šarić 12]. 以下において，M_A^N， M_B^N は文 S_A，S_B それぞれにおける N-gram の集合である．S_N，S_B で共通する n-gram に対するそれぞれの n-gram 全体数の割合の調和平均を用いている．

$$sim_{ng}(M_A^N, M_B^N) = 2 \cdot \left(\frac{|M_A^N|}{|M_A^N \cap M_B^N|} + \frac{|M_B^N|}{|M_1^N \cap M_B^N|} \right)^{-1} \quad (9)$$

単語アライメント 統語的な構造を考慮してアライメント可能な単語の割合を算出する (ϕ_7) [Sultan 13].

$$\phi_7 = sim_{align}(S_A, S_B) = \frac{n_c^a(S_A) + n_c^a(S_B)}{n_c(S_A) + n_c(S_B)} \quad (10)$$

3.3 回帰

対象とする 2 文間の類似度スコアが前述した意味グラフに基づくスコア (σ_{align}, σ_{ov}) と単語・単語列に基づくスコア ($\phi_1, ..., \phi_7$) により推定されると仮定する．回帰は，[Liu 17] で用いられているのと同様に SVR を使って行った．RBF カーネルを用い，SVR のパラメータは，開発セットの結果からペナルティ項 $C = 10$, $\gamma = 0.2$, $\epsilon = 0.5$ とした．

4. 実験

提案手法の評価は，意味的関係の極端に低いものを含む対の類似性評価を含む設定と，翻訳システムの翻訳結果のように，類似性が比較的高いものを分別する設定の 2 種類について行った．前者には，STS shared task の評価ベンチマーク，後者には，WMT2015 のデータセットを用いて，自動で算出した類似スコアと人のアノテーションとの相関で評価した．UDepLambda, AMR の解析, Smatch, SPICE の算出は，公開されているツールを使って行った [*4] [*5] [*6]．

4.1 STS benchmark による評価

STS benchmark は SemEval 2017[Daniel 17] で使われたベンチマークと歴代 SemEval の評価セットから作成されたベンチマークである (表 1)．対になった 2 文それぞれの内容の類似性について，0-5 のアノテーションがされている．5 は 2 文の意味内容が完全に一致する，0 は意味内容に関連性がないことを示す．複数のアノテータによる平均値をとっているため，値は整数とは限らない．評価値は，SemEval と同様に，各手法に基づき算出された類似度 ([0,5]) と，人手で付与された類似度の間の Pearson の積率相関係数 r の値を用いる．結果を表 2 に示す．

参加システムの 1,2 位には及ばないが，意味グラフベースの評価尺度の中では，かなり良い結果となっている．ただし，自動解析が難しい文では解析エラーにより情報がかなり欠落しており，簡易な単語に基づくスコアの補完のみでは，困難なものも目立った．

4.2 WMT 2015 評価データに基づく評価

機械翻訳の Evaluation Metrics shared task 用のデータを使用して，評価を行った．評価データは，英語を含む 5 か国語 10 方向のうち．本稿の実験では，独英対訳の 2169 文，仏英対訳の 1500 文を使用した．STS のように正解の評価値データが十分にないため，提案手法では，STS の訓練データで構築した回帰モデルを使って，STS の類似度スコアを使用した．各システムの翻訳結果について参照訳との類似性評価を行い，人手で行った翻訳品質評価との比較を行った．評価方法は，pairwise での優劣を人手評価と自動評価尺度での判定結果を比較し，これらの間の相関を Kendall's τ により算出した．比較する翻訳結果を同点と判断した場合の扱いについては，WMT15 Metrics Shared Task [Stanojevič 15] で用いられた算出方法に準じた．

表 3 に示すように，独英では参加システムのトップに及ばないものの，仏英では同等の結果を残している．これは，提案手法が本データで学習していないことを考えると良好な結果といえる．ベースライン手法である sentBLEU に優位な結果となっていることも本タスクへの適用可能性が高いことを示している．STS と同様，解析エラーによる影響が大きく，解析精度および補完方法の改善が課題である．

5. おわりに

本稿では，意味グラフ UDepLambda に基づいたテキストの意味的類似性尺度について提案した．提案手法は，従来の意味グラフに基づく手法に比較して，人のアノテーションとの相関が高いことが確かめられた．本手法を多言語間の類似性尺度に拡張し，翻訳評価等への適用を検討する予定である．

*4 https://github.com/sivareddyg/UDepLambda
*5 https://github.com/mdtux89/amr-eager,amr-evaluation
*6 https://github.com/peteanderson80/SPICE

参考文献

[Anderson 16] Anderson, P., Fernando, B., Johnson, M., and Gould, S.: SPICE: Semantic Propositional Image Caption Evaluation, in *Proceedings of the 14th European Conference on Computer Vision*, ECCV 2016 (2016)

[Banarescu 13] Banarescu, L., Bonial, C., Cai, S., Georgescu, M., Griffitt, K., Hermjakob, U., Knight, K., Koehn, P., Palmer, M., and Schneider, N.: Abstract Meaning Representation for Sembanking, in *Proceedings of the Linguistic Annotation Workshop* (2013)

[Cai 13] Cai, S. and Knight, K.: Smatch: an Evaluation Metric for Semantic Feature Structures, in *Proceedings of the 51st Annual Meeting of the Association for Computational Linguistics*, ACL 2013 (2013)

[Daniel 17] Daniel, C., Diab, M., Agirre, E., Lopez-Gazpio, nigo I., and Specia, L.: SemEval-2017 Task 1: Semantic Textual Similarity Multilingual and Crosslingual Focused Evaluation, in *Proceedings of the 11th International Workshop on Semantic Evaluations*, SemEval-2017 (2017)

[Liu 17] Liu, W., Sun, C., Lin, L., and Liu, B.: ITNLP-AiKF at SemEval-2017 Task 1: Rich Features Based SVR for Semantic Textual Similarity Computing, in *Proceedings of the 11th International Workshop on Semantic Evaluations*, SemEval-2017, pp. 159–163 (2017)

[Nivre 15] Nivre, J.: Towards a Universal Grammar for Natural Language Processing, in *Proceedings of CICLing 2015*, pp. 3–16 (2015)

[Palmer 05] Palmer, M., Gildea, D., and Kingsbury, P.: The Proposition Bank: An Annotated Corpus of Semantic Roles, *Comput. Linguist.*, Vol. 31, No. 1, pp. 71–106 (2005)

[Reddy 17] Reddy, S., Täckström, O., Petrov, S., and Lapata, M. S. M.: Universal Semantic Parsing, in *Proceedings of the Conference on Empirical Methods in Natural Language Processing*, EMNLP 2017, pp. 89–101 (2017)

[Schuster 15] Schuster, S., Krishna, R., Chang, A., Fei-Fei, L., and Manning, C. D.: Generating Semantically Precise Scene Graphs from Textual Descriptions for Improved Image Retrieval, in *Proceedings of the Workshop on Vision and Language (VL15)* (2015)

[Stanojevič 15] Stanojevič, M., Kamran, A., Koehn, P., and Bojar, O.: Results of the WMT15 Metrics Shared Task, in *Proceedings of the 10th on Statistical Machine Translation*, WMT 15 (2015)

[Sultan 13] Sultan, M. A., Bethard, S., and Symner, T.: Back to basics for monolingual aligner: Exploiting word similarity and contextual evidence, *TACL*, Vol. 2, pp. 219–230 (2013)

[Šarić 12] Šarić, F., Glavaš, G., Karan, M., Šnajder, J., and Bašić, B. D.: TakeLab: Systems for Measuring Semantic Text Similarity, in *Proceedings of the First Joint Conference on Lexical and Computational Semantics*, SemEval '12, pp. 441–448 (2012)

[Wu 94] Wu, Z. and Palmer, M. S.: Verb semantics and lexical selection, in *Proceedings of the 32nd Annual Meeting of the Association for Computational Linguistics*, ACL-1994, pp. 133–138 (1994)

[羅 16] 羅 文涛, 林 良彦 : 機械翻訳を利用した異言語文間の意味的類似度計算の評価, 言語処理学会第 22 回年次大会予稿集, pp. 883–886 (2016)

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

意外性のある原因・結果表現の決算短信からの抽出

Extraction of rare cause-result expressions from summary of financial statements

酒井 浩之 *1 Hiroyuki Sakai　坂地 泰紀 *2 Hiroki Sakaji　室野 莉沙 *1 Risa Murono　北島 良三 *1 Ryozo Kitajima　ベネット ジェイスン *3 Jason Bennett

*1成蹊大学 Seikei University　*2東京大学 The University of Tokyo　*3三井住友アセットマネジメント株式会社 Sumitomo Mitsui Asset Management Company, Limited

In this research, we propose a method to extract rare cause-result expressions from summary of financial statements. For example, our method extracts effect expression that "Sales of drinking paper containers has increased" with respect to cause expression that "due to hot summer", as a rare cause-result expression. It is difficult to imagine that the sales of "drinking paper containers" may increase in the case of "hot summer". Our method calculates the conditional probability with words contained in the result expression co-occurring with words contained in the cause expressions. Moreover, our method determines that cause information is contained in the result expression or not by using deep learning. Our method extracts rare cause-effect expressions by using the conditional probability and the cause information.

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 [和泉 11][藏本 13].

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原因とそれに対する結果が重要である．例えば，原因が「猛暑の影響により」において，結果が「冷房需要の盛り上がり」といった情報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，その原因に対する結果の情報から，猛暑の年には冷房機器に関する事業を行っている企業（空調機器メーカーや家電量販店など）の業績が好調に推移することが期待できる．

企業の業績に関する情報は，企業が決算ごとに発行する決算短信に記載されており，業績要因に含まれる原因と結果に関する情報も記述されている．しかしながら，証券市場の上場企業数は約 3,600 社と多いうえに，近年では年に 4 回，決算発表がある *1．そのため，人手によって多くの決算短信を読み，原因と結果の情報を取得するのには多大な労力を要する．そこで，坂地らは，決算短信から例えば「夏場の猛暑の影響により冷房需要が盛り上がりました。」のような原因・結果表現を自動的に抽出する手法を提案している [坂地 15]．しかし，坂地らの手法によって抽出された原因・結果表現のままでは投資に活用することは難しい．なぜなら，原因「猛暑の影響により」に対する結果「冷房需要の盛り上がり」の情報は誰にでも予想できることである．従って，猛暑のときに冷房のような空調機器を製造している企業の業績が良くなることは自明であり，投資に有用な情報とは言い難い．しかし，例えば原因「猛暑の影響により」に対して結果「除草関連商品の売り上げが好調になる」や「飲料用紙容器の販売が増加した」という情報は，個人投資家にとっては簡単には思いつきにくく意外性がある．すなわち，猛暑のときは雑草の成長が早く，結果として除草関連商品の売り上げが好調になることを示唆している．従って，猛暑のときに除草に関連する事業を行っている企業に対して投資をしておけばよいことがわかる．そのため，室野らは決算短信から抽出した原因・結果表現のなかから *2，意外性のある原因・結果表現を判定する手法を提案した [室野 17].

しかし，室野らの手法では，入力として「猛暑」「冷夏」のような「原因となる語」と定義された語を必要としている．すなわち，原因となる語として「猛暑」を入力し,「猛暑」を含む原因表現に対応する結果表現のなかから意外性のある結果表現を判定する．そのため,「猛暑」「冷夏」「暖冬」「厳冬」のような季節に関する語や天災に関する語であれば分かりやすいが，それ以外の意外性のある原因・結果表現を得るためには適切な「原因となる語」が必要となるため，投資に対する専門知識や企業の事業に関する専門知識がないと活用が難しいという問題があった．さらに，意外性のある原因・結果表現を多く獲得し投資のための知識ベースとして運用するためには，特定の「原因となる語」に限定することは望ましくない．そのため，本研究では,「猛暑」のような「原因となる語」を必要とせず，決算短信のみから意外性のある原因・結果表現を抽出することを目的とする．

関連研究として，酒井らは決算短信から業績要因を含む文（例えば「半導体製造装置の受注が好調でした。」）を抽出する手法を提案している [酒井 15][酒井 17]．北森らは決算短信から業績予測文 (今後の業績予測に関する情報が記述されている文) を抽出する手法を提案している [北森 17a][Kitamori 17b]．上記の研究では，業績に対しての要因，予測に関する情報を抽出しているため,「～が好調」のため業績が良くなるのような原因・結果情報ともいえる．しかし，好調であれば業績が良くなるのは自明なので，意外性のある情報は抽出できず，本研究とは目的が異なる．

連絡先: 酒井浩之，成蹊大学，東京都武蔵野市吉祥寺北町３－３－１，h-sakai@st.seikei.ac.jp

*1　1 年を 4 期に分け，3 か月ごとに企業が公表する．平成 15 年より全上場企業に義務づけられている

*2　原因・結果表現の抽出には坂地らの手法 [坂地 15] を使用した．

2. 原因・結果表現の意外性の判定

まずは，室野らの手法 [室野 17] について簡単に述べる．以下に手法の概要を示す．

Step 1: 決算短信から原因・結果表現を抽出する．

Step 2: 原因となる語（「猛暑」など）を指定し，原因となる語を含む原因表現に対する結果表現から名詞を抽出する．

Step 3: 原因表現に Step 2 で指定した原因となる語が出現するときに，対する結果表現に Step 2 で抽出された名詞が出現する条件付き確率を求める

Step 4: Step 3 で求めた条件付き確率と，企業キーワード（後述）を用いて，意外性のある原因・結果表現であるかを判定するための意外性スコアを求め，意外性スコアが高いものを意外性のある原因・結果表現と判定する．

2.1 条件付き確率の算出

Step 3 における条件付き確率を用いる理由として，例えば，原因表現に「猛暑」を含むときは，結果表現に「冷房」という名詞は多く出現し，逆に，原因表現が「猛暑」を含むときには，結果表現に「除草剤」は多く出現しないという仮定に基づく．したがって，原因に「猛暑」が出現するときに，結果に「冷房」が出現する条件付き確率は大きくなり,「除草剤」が出現する条件付き確率は小さくなることが予想できる．意外性があるのは「除草剤」であり，条件付確率が小さい名詞対を含む原因・結果表現は意外性があると判定できる．原因となる語 k が原因表現に出現したときに，結果表現に名詞 w が出現する条件付き確率 $P(w|kw)$ を以下の式 1 で算出する．

$$P(w|k) = \frac{f(w,k)}{f(k)} \tag{1}$$

ここで，$f(w,k)$ は，全ての原因・結果表現の集合において k が含まれている原因表現に対応する結果表現に名詞 w が出現する頻度を表し，$f(k)$ は，全ての原因・結果表現の集合において k が含まれている原因表現が出現する頻度を表す．

2.2 企業キーワードに基づくスコア

酒井らは決算短信からその企業にとって重要なキーワードを抽出する手法を提案しており [酒井 15]，そのようなキーワードを企業キーワードと定義する．決算短信からの企業キーワードの抽出は，企業 t の決算短信における名詞 n に対して以下の式 2 で重み $W(n,S(t))$ を計算することで行う．

$$\begin{aligned} W(n,S(t)) &= (0.5 + 0.5 \times \frac{tf(n,S(t)}{\max tf(n,S(t)}) \\ &\quad \times H(n,S(t)) \times \log_2 \frac{N}{df(n)} \end{aligned} \tag{2}$$

ここで，

$S(t)$**:** ある企業 t の決算短信の集合．

$tf(n,S(t))$**:** $S(t)$ において，名詞 n が出現する頻度．

$H(n,S(t))$**:** $S(t)$ の各決算短信である d に名詞 n が出現する確率に基づくエントロピー． begineqnarray

$df(n)$**:** 名詞 n を含む決算短信をもつ企業の数．

N**:** 決算短信を収集した企業の数．

$W(n,S(t))$ は，情報検索で一般的な $tf \cdot idf$ 値を 1 つの企業の決算短信 PDF の集合を 1 つの文書とみなして求め，さらに，その企業の決算短信集合においてまんべんなく出現している場合に高い値をとる尺度を組み合わせたものである．

ここで，企業 t における重要な原因・結果表現を判定するために，企業 t の決算短信において，原因となる語 k を含む原因・結果表現に対して以下の式で求めるスコア $KS(k,t)$ を求め，意外性の判定に使用する．

$$KS(k,t) = \frac{2S_1(k,t)S_2(k,t)}{S_1(k,t) + S_2(k,t)} \tag{3}$$

$$S_1(k,t) = c_1 \sum_{n \in T_1(k)} \frac{W(n,S(t))}{max_{n'} W(n',S(t))} \tag{4}$$

$$S_2(k,t) = c_2 \sum_{n \in T_2(k)} \frac{W(n,S(t))}{max_{n'} W(n',S(t))} \tag{5}$$

ここで，c_1，c_2 はそれぞれ原因表現，結果表現に含まれる企業キーワードの個数，$T_1(k)$ は k を含む原因表現に含まれている企業キーワードの集合，$T_2(k)$ は k を含む原因表現に対する結果表現の中に含まれている企業キーワードの集合である．

2.3 意外性スコア

企業 t の決算短信において，原因となる語 k を含む原因・結果表現の意外性を判定するための指標である意外性スコアを以下の式で求める．

$$SS(k,t) = \frac{KS(k,t)}{\sum_{w \in r(k)} P(w|k)} \tag{6}$$

ここで，$r(k)$ は，k を含んでいる原因表現に対する結果表現の中に含まれている名詞の集合である．意外性スコアが大きい原因・結果表現を意外性があると判定するため，条件付き確率に基づくスコアを分母に，企業キーワードに基づくスコアを分子とする式を意外性スコアとした．

3. 意外性のある原因・結果表現の抽出

前節の手法では「猛暑」のような原因となる語を入力として必要とするが，本節では，原因となる語を指定しなくても決算短信から意外性のある原因・結果表現を抽出する手法について述べる．具体的には,「原因となる語」として原因表現に含まれる全ての名詞 N-gram を採用し，意外性スコアの大きいものを出力する．しかし，上記の方法では原因・結果表現として不適切な表現が多く抽出されてしまう．多くの原因・結果表現を分析したところ，例えば以下に示すような，結果表現に業績要因に関する情報が含まれている原因・結果表現が適切であった [*3]．

> ・原因：多雨によるブラジル出し鉄鉱石の荷動き鈍化
> ・結果：ケープサイズ船市況は低迷しました

従って，意外性スコアが高い原因・結果表現の中から結果表現に業績要因に関する情報が含まれているかどうかを判定し，そのような原因・結果表現のみを抽出する．

3.1 結果表現における業績要因の判定

結果表現に業績要因に関する情報が含まれているかどうかの判定に深層学習を用いる．具体的には，決算短信から業績要

*3 ケープサイズ船とはパナマ運河が通航できない大型船を表す．

因を含む文を抽出する手法 [酒井 17] を，結果表現にのみ適用する．以下に深層学習を用いた業績要因の判定手法について述べる．

Step 1: 酒井らの手法 [酒井 15] を用いて決算短信から抽出した業績要因文から，手がかり表現の“拡張手がかり表現”を獲得する

Step 2: 業績要因文に対して前述の企業キーワードを用いてスコアを付与する．

Step 3: 拡張手がかり表現を含み，かつ，スコアが高い業績要因文を正例，手がかり表現，企業キーワードをともに含まない文を負例として学習データを自動生成する．

Step 4: 自動生成された学習データを使用し，深層学習にて結果表現の業績要因を判定する．

酒井らの手法 [酒井 15] では,「好調でした」「不振でした」といった業績要因文の抽出に有効な手がかり表現をブートストラップ的に獲得し，そのような手がかり表現と企業キーワードを使用して，業績要因文の抽出を行っている．本手法では，手がかり表現にいくつかの文節を追加することで,“拡張手がかり表現”と定義する文節列（例えば「受注が好調でした」）を獲得し，例えば拡張手がかり表現「極めて好調でした」を含む業績要因文のみを抽出する．さらに，業績要因文に含まれる企業キーワードを使用して業績要因文にスコアを付与し，スコアの高い業績要因文のみを抽出する．上記の処理を行うことで，精度 80% 程度である酒井らの手法による抽出精度を 100% 近くまで高め [*4]，抽出された業績要因文を学習データの正例とする．負例は，決算短信の企業キーワードと手がかり表現，どちらも含まない文とする．そして，997 企業の決算短信から 30,839 文の業績要因文を正例として生成した．また，負例は正例と同数とし，従って 61,678 文の学習データを生成した．

自動生成された学習データに基づき，深層学習により業績要因を判定する．まず，入力層の要素となる語（素性）を選択する．具体的には，自動生成された学習データにおいて正例の業績要因文に含まれる内容語（名詞，動詞，形容詞）に対して，以下の式 7 にて重みを計算する．

$$W_p(t, S_p) = TF(t, S_p) \times H(t, S_p) \tag{7}$$

ここで,

S_p**:** 学習データにおいて正例に属する業績要因文の集合

$TF(t, S_p)$**:** 文集合 S_p において，語 t が出現する頻度

$H(t, S_p)$**:** 文集合 S_p における各業績要因文に含まれる語 t の出現確率に基づくエントロピー

同様に，負例の文に含まれる内容語に対しても同様に重み $W_n(t, S_n)$ を計算する．ただし，S_n は学習データにおいて負例に属する文の集合となる．

ここで，ある語 t の正例における重み $W_p(t, S_p)$ が負例における重み $W_n(t, S_n)$ の 2 倍より大きければ，その語 t を素性として選択する．もしくは，語 t の負例における重み $W_n(t, S_n)$ が正例における重み $W_p(t, S_p)$ の 2 倍より大きければ，その語 t を素性として選択する．上記の条件を課すことで，正例，負例における特徴的な語のみを素性として選択し，正例，負例，ともによく出現するような一般的な語を素性から除去する．上記の手法により，61,678 文の学習データから 4,549 語が素性として選択された．

深層学習のモデルについて以下に述べる．入力は 61,678 文の学習データから抽出された 4,549 語を要素，語 t における $W_p(t, S_p)$，もしくは，$W_n(t, S_n)$ の大きいほうを要素値としたベクトルとする．モデルの入力層のノード数を入力ベクトルの次元数と同じ 4,549 とし，隠れ層は，ノード数 1,000 が 3 層，ノード数 500 が 3 層，ノード数 250 が 3 層，ノード数 125 が 3 層の計 12 層とする．出力層は 1 要素である．また，活性化関数として，ReLU を使用した．

学習されたモデルにより，結果表現の業績要因を判定する．

4. 評価

本手法の評価を行うため，本手法を実装した．実装にあたり，形態素解析器として MeCab[*5] を使用した．決算短信 [*6] から抽出した原因・結果表現，1,446,247 文において，原因表現に含まれる 662,372 個の名詞 N-gram を「原因となる語」として意外性スコアを求める．さらに，意外性スコアが高い原因・結果表現の結果表現に対して業績要因の判定を行い，結果表現に業績要因を含む原因・結果表現を抽出する．表**??**に，本手法にて抽出された意外性のある原因・結果表現をいくつか示す．

評価は本手法にて抽出された原因・結果表現を評価者が判定し，意外性の有無を評価した．意外性の有無を評価することは評価者の知識にも依存するため困難であるが，ここでは，個人投資家（すなわち，その分野の専門知識は持たない）を想定し，投資歴が１０年以上ある個人投資家に依頼して評価した．例えば，原因表現が「多雨によるブラジル出し鉄鉱石の荷動き鈍化」，結果表現が「ケープサイズ船市況は低迷しました」の場合，大型船による運搬や鉱物の採掘に携わっている人であれば意外性がないかもしれないが，その分野に対する専門知識を持たない個人投資家にとっては，鉄鉱石の荷動き鈍化→大量の鉄鉱石を運搬するには大型船が必要→ケープサイズ船の受注減という関係を思いつくのは困難である．従って，意外性が有ると判定できる．また，原因が結果に間接的に影響がある場合は意外性有りと判定した．例えば，原因が「猛暑の影響」，結果が「飲料用紙容器の販売が増加した」の場合，猛暑→飲料が売れる→飲料用紙容器の販売が増加のように，猛暑と飲料用紙容器の間にもう一つの原因がある．このような場合は機械的に意外性有りと判定した．逆に，原因が「猛暑の影響」，結果が「飲料が好調」であれば，原因が結果に直接的に影響があるため，意外性無しと判定される．なお，本手法でも原因・結果表現として不適切な表現が抽出されることがあるが，それは意外性無しと判定した．図 1 に意外性スコアの上位 N における精度の変化を示す．ここで，図中の Baseline は結果表現に業績要因の判定を行わない場合である．

5. 考察

本手法による意外性スコアの上位 70 における精度は 0.64 であり，ベースラインである結果表現に業績要因の判定を行わない場合と比べて，精度が大幅に向上した．室野らの手法では,「猛暑」のような原因となる語を指定し，適切な原因となる語を指定できれば 80% 程度の精度を達成できたが，原因表現に

∗4 再現率は大幅に低下する．

∗5 http://taku910.github.io/mecab/

∗6 3,821 社の企業 Web ページから取得した 106,885 個の決算短信 PDF ファイル

表 1: 抽出された原因・結果表現

原因表現	結果表現
患者さんや医療現場に対するドライアイの疾患啓発活動	角膜疾患治療剤の「ヒアレイン点眼液」は、順調な伸びを示しました。
オンライン請求義務化推進に伴うレセプトコンピュータ導入に対する補助金の影響	医療機関の電子カルテの導入が停滞した
計量法改正に伴う需要増	メディカル計量器が好調だった
原発事故に伴う放射能汚染問題、政治情勢の混乱に伴う公債発行特例法案の決議遅れによる予算の執行抑制などの影響	建設コンサルタント業界においても、引き続き厳しい状況で推移いたしました。

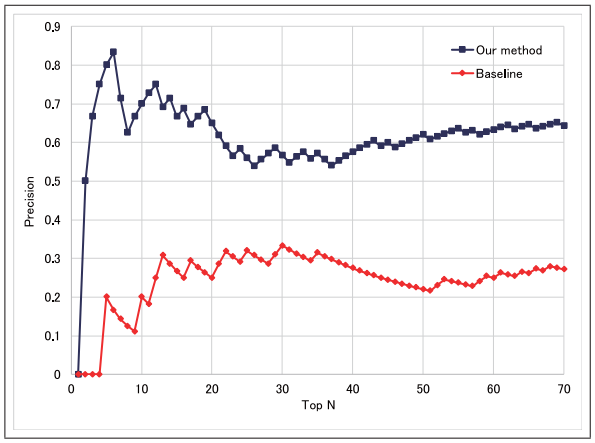


図 1: 意外性スコア上位 N における精度の推移

含まれる全ての名詞 N-gram を原因となる語として指定すると，不適切な表現が多く抽出されてしまうことが分かる．

しかし，例えば以下のように，ベースライン手法では抽出されたが，本手法では結果表現に業績要因が含まれていると判定されず，除去された原因・結果表現も存在した．

・原因：ＥＵの砂糖制度改革による輸出補助金削減
・結果：原糖市況は急伸し

本手法では，業績要因の判定に深層学習を用いており，その学習データを自動生成しているため，多くの語で構成される文が学習データの正例となる傾向にある．そのため，上記の例のような短い結果表現は，業績要因を含むと判定できないことが多い．

本手法による誤抽出では，例えば以下のような，原因と結果に意外性が乏しいものがあった．

・原因：新製品の手術画像用レコーダーの発売が第３四半期にずれこんだ
・結果：医用画像記録再生機器は減収となりました。

本手法では，結果に「医用画像記録再生機器」のような低頻度の語が出現すると条件付き確率が低くなり，原因と結果に意外性が乏しいにもかかわらず意外性スコアが大きくなる．

6. まとめ

本稿では，決算短信から意外性のある原因・結果表現を自動的に抽出する手法について述べた．本手法は，原因表現にある名詞が出現するときに結果表現に名詞が出現する条件付き確率と，決算短信から抽出された企業キーワードのスコアを用いて意外性スコアを算出することで意外性の判定を行った．さらに，原因・結果表現の結果表現に対して業績要因の判定を行うことで，不適切な表現を除去した．本手法を評価した結果，本手法の精度は 0.64 となり，ベースライン手法よりも高い精度を達成した．

参考文献

[和泉 11] 和泉 潔, 後藤 卓, 松井 藤五郎：経済テキスト情報を用いた長期的な市場動向推定, 情報処理学会論文誌, Vol. 52, No. 12, pp. 3309–3315 (2011)

[北森 17a] 北森 詩織, 酒井 浩之, 坂地 泰紀：決算短信 PDF からの業績予測文の抽出, 電子情報通信学会論文誌 D, Vol. J100-D, No. 2, pp. 150–161 (2017)

[Kitamori 17b] Kitamori, S., Sakai, H., and Sakaji, H.: Extraction of sentences concerning business performance forecast and economic forecast from summaries of financial statements by deep learning, in *IEEE Symposium on Computational Intelligence for Financial Engineering & Economics*, pp. 67–73 (2017)

[藏本 13] 藏本 貴久, 和泉 潔, 吉村 忍, 石田 智也, 中嶋 啓浩, 松井 藤五郎, 吉田 稔, 中川 裕志：新聞記事のテキストマイニングによる長期市場動向の分析, 人工知能学会論文誌, Vol. 28, No. 3, pp. 291–296 (2013)

[室野 17] 室野 莉沙, 酒井 浩之, 坂地 泰紀, ベネット ジェイスン：決算短信から抽出した原因・結果表現の意外性の判定, 第 11 回テキストアナリティクス・シンポジウム, pp. 93–98 (2017)

[酒井 15] 酒井 浩之, 西沢 裕子, 松並 祥吾, 坂地泰紀：企業の決算短信 PDF からの業績要因の抽出, 人工知能学会論文誌, Vol. J98-D, No. 5, pp. 172–182 (2015)

[酒井 17] 酒井 浩之, 松下 和暉：決算短信からの業績要因文の抽出, 第 11 回テキストアナリティクス・シンポジウム, pp. 87–91 (2017)

[坂地 15] 坂地 泰紀, 酒井 浩之, 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. J98-D, No. 5, pp. 811–822 (2015)

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

論文中の図表と本文の自動対応付け

Automatic alignment of figures and tables with texts in scientific literatures

篠田 広人 Hiroto SHINODA　仲榮眞 一朗 Ichiro NAKAEMA　難波 英嗣 Hidetsugu NANBA　竹澤 寿幸 Toshiyuki TAKEZAWA

広島市立大学 情報科学部
School of Information Sciences, Hiroshima City University

Recently, scientific information explosively increases, because of the increase of the number of researchers and the ramification of research domains, and it is difficult for researchers to read all the papers that they can get. Therefore, a support system, which enables researchers to grasp the outline of a research paper quickly, is required. In this paper, we constructed a support system focusing on figures and tables in a research paper. Figures and tables can be considered as the essential points of descriptive sentences in a paper. Therefore, it is useful for researchers to grasp the outline of the paper by showing figures and tables along with their descriptive sentences. We propose a method that automatically aligns figures and tables in a research paper with their corresponding sentences. We conducted some experiments to confirm the effectiveness of our method. From the experimental results, precision 0.65 and recall 0.13 were obtained, and the effectiveness of our method was confirmed.

1. はじめに

近年, 研究者数の増加および学問分野の専門分化と共に学術情報量が爆発的に増加している. 研究者が入手できる学術論文の量が増える一方で, そのすべてに目を通すことが困難になっており, 論文の内容を効率的に把握するための読解支援システムが求められている.

これまでに, 様々な観点から論文読解を支援するシステムが提案されてきたが, 本研究では, 論文内の図表に着目したシステムを構築する. 図表は, 論文中の説明文の要点を表したものと捉えることができ, 被験者に説明文だけを提示するよりも,図表とともに説明文を提示したほうが, 内容の理解に有用であるという調査報告もある[岩槻 98]. 本研究では, 論文中の図表と, 個々の図表に対応する文を自動的に対応付け, ユーザに表示することで論文読解の支援を行う. また, 図表と文の対応付けを「系列ラベリング問題」として, 機械学習を用いて解く. これにより, 研究者が論文を調査する際の労力・手間が改善し, 円滑な研究の支援ができるようになると考えられる.

論文の構成は以下のとおりである, 2 節では関連研究を紹介する. 3 節では図表に関連する文の自動対応付けについて述べる. 4 節では評価実験とその結果, 考察を述べる. 5 節で本論文をまとめる.

2. 関連研究

本節では, 論文読解支援, 技術文書マイニング, 文脈情報を考慮した情報抽出に関する関連研究について述べる.

2.1 論文読解支援

Abekawa らは, 論文のデジタル化の中で, PDF ファイル内に, 文書を理解する上で必要な論理構造を示す情報が含んでいないことに着目し, PDF から必要な情報を抽出するシステムである SideNoter について紹介している[Abekawa 16]. SideNoter は三つの機能を与えている. 一つ目は図表検索機能, 二つ目は, 関連部門検索機能, 三つ目は論文 1 ページごとの情報推薦機能である. 本研究でも, 論文をテーマとした研究で共通しているが, 論文内の図表を用いた文脈情報を考慮した文の抽出を行う点で異なる.

2.2 技術文書マイニング

難波らはある分野の特許と論文から, 技術動向マップを自動的に作成することを最終目標としている特許マイニングタスクについて紹介している[難波 09]. このタスクでは,「学術論文分類サブタスク」,「技術動向マップ作成サブタスク」の 2 つのサブタスクを設定している. このうちの学術論文分類サブタスクの成果として学術論文自動分類システムを構築, 紹介している. このシステムは論文の概要を入力すると, 内容語(名詞, 動詞, 形容詞)を自動抽出し, それらの内容語を検索キーワードとして特許検索システムを用いて関連特許を検索する. この際, 検索結果上位 170 件の各特許に付与された IPC コードを抽出し, コード別にスコアを計算し, スコアの高い順に出力している.

評価は, 分類システムが出力した上位 n 件の分類コードが, 人手で付与した IPC コードをどの程度正しく抽出できているかによって調査し, 再現率は検索結果上位 1 件で約 20%, 上位 10 件で約 60%となった. この結果を受けて, 再現率のさらなる向上が必要ではあるが, 特許の検索初心者にとってはある程度有用であると述べている. 本研究においてもテキストの自動抽出を行うが, 図表に関連しているテキストのみを対象に抽出するという点で異なる.

技術動向情報の抽出, 可視化を行っている研究に福田らの研究がある[福田 13]. 福田らは論文および特許の表題と概要を解析することで技術動向情報の可視化を目指している. 一般に, 論文と特許では, 表現や形式が記述スタイルの面で大きく異なっており, ルールに対応付けて解析することは難しい. そこで福田らはこの問題を「要素技術とその効果を示すタグを付与」するという系列ラベリング問題として考え, 機械学習を用いたタグの自動付与を行っている. ここでの要素技術とは, 研究において使用されたアルゴリズムやツール, 技術的手法のことを指し, その要素技術から得られる知見を効果とする. 機械学習の素性として用いる要素技術や効果を示す手掛かり語のリスト作成する必要がある. そのため, 福田らは手掛かり語のリストを網羅的に作成するために, 係り受け関係や上位下位関係による人手での収集, さらに分布類似度を用いた語句の自動収集を行う手法を提案している. 実験では, NTCIR-8 特許マイニングタスクのデータを実験データとして使用し, 評価尺度には精度・再現率・F 値を用いた. 実験の結果, 上記の素性を用いた提案手法がすべての

連絡先:
篠田 広人, 仲榮眞 一朗, 難波 英嗣, 竹澤 寿幸
広島市立大学 情報科学部
〒731-3194 広島市安佐南区大塚東三丁目 4 番 1 号
{shinoda,nakaema,nanba,takezawa}@ls.info.hiroshima-cu.ac.jp

ベースライン手法を上回っており，提案手法の有用性を示した．本研究でも同様に，系列ラベリングによる文脈情報を考慮した文の抽出を行うが，文脈情報だけでなく論文内の図表の情報も用いる点で異なる．

2.3 文脈情報を考慮した情報抽出

Willot らは論文概要の各文に対し，「背景」，「目的」，「手法」，「結果」のラベルを自動付与する手法を提案している[Willot 15]. Willot らは，論文概要中の各文に付与されるラベルには，例えば「目的」→「手法」→「結果」のようにパターンがあると考え，このタスクを系列ラベリング問題と捉え，リカレントニューラルネットワークの一種である Long short-term memory (LSTM)を用いてラベルの自動付与を実現している．

本研究は，ある図表に関連する一連の文を対応付ける，というタスクであり，系列ラベリング問題として解くことができる．ただし，Willot らの研究では，概要中の文集合のみが与えられるのに対し，本研究では，論文本文中の文集合の他に図表そのものと図表のキャプションも同時に与えられる点が異なる．

3. 図表に関連する文の自動対応付け

3.1 タスクの概要

本研究では結果を示す図表を入力として，その図表と対応関係にある文章を自動的に抽出し，表示するシステムを構築する．例を図 3.1 に示す．

	Train	Dev.a	Dev.b
# of sent.	2,032,679	1,000	1,000
# of En words	48,322,058	31,890	31,935
Enju suc. rate	99.3%	98.9%	98.7%
parse time (sec./sent.)	0.30	0.38	0.48
# of Jp words	53,865,629	37,066	35,921

Table 3: Statistics of the experiment sets.

The statistics of the filtered training set, dev.a, and dev.b are shown in Table 3. The success parsing rate ranges from 98.7% to 99.3% by using Enju2.3.1. The averaged parsing time for each English sentence ranges from 0.30 to 0.48 seconds.

図 3.1：表とその対応文([Wu 11]より引用)

この例の場合，図 3.1 の上部にある表は Table 3 であるため，Table 3 の記載のある文と関連があると考えられる．さらに，キャプションだけでなく，表内の語句や数値が含まれている文も表と関連していると考えられる．特に表内の数値は結果に関するものが記載されていることがあるため，重要であるといえる．

次に，図の場合の例を図 3.2 に示す.図においても表と同様に，Figure の記載のある文が対応関係にあると考えられる．また，図内の語句が用いられている文についても，対応関係があると考えられる．

このように，学術論文においては図表に対応するテキストが必ず存在する．また，そのテキストは図表に対する説明等の言及をしている場合が多いため，対応文抽出は論文内容の把握において重要だと考えられる．本研究ではこの図表に対応文の自動抽出を目的とする．

3.2 システム概要

本節では，本研究で構築するシステムの概要について説明を行う．本システムの流れは以下のようになる．

(1) 学術論文中の図表番号の入力
(2) 図表画像の解析モジュール
(3) 図表関連テキスト抽出モジュール
(4) 抽出結果の出力

本システムの入力には Abekawa らの研究によって XHTML 形式で出力された ACL Anthology の論文データを用いる．3.3 節では，図表画像解析モジュールについて，3.4 節では，図表関連テキスト抽出モジュールについて説明を行う．

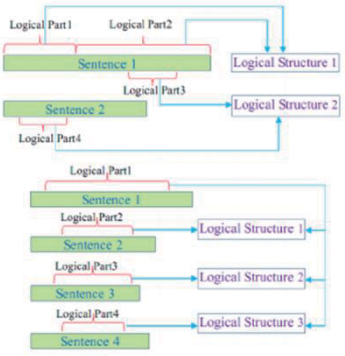


Figure 1: Two cases of inputs and outputs of the task.

Figure 1 shows two cases of the inputs and outputs of the task. In the first case, the input is a paragraph of two sentences, and the outputs are four logical parts, which are grouped into two logical structures. In the second case, the input is a paragraph consisting of four sentences, and the outputs are four logical parts, which are grouped into three logical structures.

図 3.2：論文中の図とその対応文([Bach 11]より引用)

3.3 図表画像の解析モジュール

本節では，図表中画像を解析し，図表中の文字・数値情報を抽出するモジュールについて説明を行う．Abekawa らは PDF 形式の論文ファイルから，論文表題，概要，著者名，節情報，参考文献等の論文の構造を抽出し，XHTML 形式で出力しており，図表はすべて png 形式で統一されている[Abekawa 16]. 本研究ではこの XHTML ファイルを用いて画像解析を行う．画像解析には Google Cloud Vision を用いる．図 3.3 に論文中の表の例を，図 3.4 にその解析結果を示す．

Chunking	F1	CCG tagging	Accuracy
Our model	93.21	Our model	92.41
Suzuki and Isozaki (2008)	93.88	Xu et al. (2015)	93.00

Table 4: Baseline model, comparison to existing systems

図 3.3：論文中の表の例([Plank 16]より引用)

Chunking
Our model
Suzuki and Isozaki (2008) 93.88Xu et al. (2015) 93.00
Fl CCG tagging Accuracy
93.21 Our model
92.41

図 3.4：図 3.3 の文字認識結果

図 3.4 から, 図 3.3 の Table 4 内の文字列がテキスト形式に変換されていることが分かる. また, この解析ではテキスト内の単語の位置情報を獲得することができる. この位置情報を用いることで, 例えば,「数字が規則正しく並んでいたら結果を示している図表」というような推測が可能になる. 本研究では図表の対応文抽出を行う際に, この画像の解析結果を用いることで, 図表内の情報を考慮したシステムの構築を目指す.

3.4 図表関連テキスト抽出モジュール

本節では, 学術論文内の図表に関連のあるテキストを抽出するモジュールについての説明を行う. ここでの, 図表に関連のあるテキストとは, その図表に対しての言及, または図表内の用語についての説明がある文章のことである. 図表とテキストの最も単純な対応関係は, テキスト内に図表のキャプション名 (Figure 1, Table 2 等) が含まれているかどうかとなる. しかし, 実際にはキャプション名が含まれている文のみが対応関係にあるというケースは少なく, キャプション名の含まれているテキストの前後にわたって対応関係にあるテキストが連なっていることが多い. 図 3.5 に図表と対応文の例を示す.

Chunking	F1	CCG tagging	Accuracy
Our model	93.21	Our model	92.41
Suzuki and Isozaki (2008)	93.88	Xu et al. (2015)	93.00

Table 4: Baseline model, comparison to existing systems

[Plank 2016]
Baseline model Both or baseline models are comparable to prior work, while being simpler. The results are summarized in Table 4. Our chunking baseline achieves an F 1 of 93.21 on CoNLL,compared to the F 1 of 93.88 of Suzuki and Isozaki (2008), who use a CRF and gold POS tags.

図 3.5: 論文中の表とその対応文([Plank 16]より引用)

図 3.5 の例の場合, Table 4 の記載のあるテキストが対応文となるが, この対応文に続く文が「Our chunking」で始まっている.「Our」で始める文はその研究における提案手法を指している場合が多く, 結果を示す図表と対応していることが考えられる. この他に,「The result ~」のように,「The」で始まる文が対応文に続いている場合は, それらの文も対応づいている場合が多いことが分かっている. また, Table 4 のキャプション名に「Baseline model」という語句が入っている. そのため,「Baseline model」から始まっている文も図表との関連が考えられる. さらに, この表に 3.3 節で述べた画像解析を行うと, Table 4 内に Suzuki and Isozaki という語句があることが分かる. このことから, Suzuki and Isozaki という語句が含まれる文も Table 4 に関連しているのではないかと考えられる. 同様に, 図表内の数値が含まれている文もその図表との関連があると判断できる. このように, 単純な Table, Figure の有無だけでなく, 3.3 節の画像解析や前後の文脈を考慮することで, より多くの対応文を抽出することができると考えられる.

そこで, 本研究では最初に出現したキャプション名の入っている文を「基準文」とし, 基準文の前後の文脈を考慮した対応文抽出を行う. 人手で対応付けがされた 290 件の論文データにおいて, 基準文と対応文の分布を調査したグラフを図 3.6 に示す.

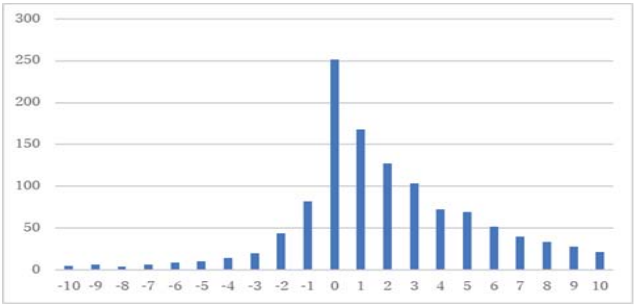


図 3.6: 基準文と対応文の分布

図 3.6 の横軸の 0 が基準文となっており, そこから正の方向が基準文の後ろ, 負の方向が基準文の前の対応文となっており, 縦軸はその数である. 図 3.6 から, 基準文の前後, 特に基準文の後ろの文が対応文となっている場合が多く, 対応文抽出においては, 文脈情報を考慮することが重要だといえる.

そこで, 本研究では文脈情報を考慮した対応文抽出を自動で行うために, 対応文抽出を系列ラベリング問題として解き, リカレントニューラルネットワークの一種である Long short-term memory (LSTM)を用いて解決する手法を提案する.

4. 実験

本節では, 提案手法の有効性を確認するために行った実験と結果について述べる. 4.1 節では実験設定, 4.2 節では実験結果及び考察について述べる.

4.1 実験設定

実験データ

本研究では, 実験データとして ACL Anthology を用いた. ACL Anthology は自然言語処理分野および計算言語学分野の論文を収集したもので, 年々データ量は増加している. 本研究では, そのうち自然言語処理分野の論文 31,812 件を取り扱う.

ACL Anthology の論文群は PDF 形式で出力されているが, このままでは形式の違いから図表の解析に用いることができない. そこで, Abekawa らは, ACL Anthology の PDF ファイルから論文の構造を抽出し, XHTML 形式で出力することに成功した [Abekawa 16]. これにより, 図表は png 形式, テキスト部分が XML 形式で統一されているため, 解析に用いることができるようになっている. 図表は全部で 417,237 件ある. 本研究ではこの XHTML 形式に変換されたデータセットを用いて実験を行う.

正解データには, 人手で図表とテキストの対応付けを行ったデータを用いる. 論文中の各図表について, その図表について述べていると判断された文をすべて選択してもらい, リストとした. 結果として 290 件の図表と, それに対応している文のリストを用意することができた.

実験条件

本実験では, データ数が少ないことから, 5 分割交差検定により実験を行った. 最初にキャプション名(Table 1, Figure 2 等)が出現した文にタグを付与し, このデータに LSTM を適用することにより学習を行った. 具体的には, まず, これらのタグを付与したデータを, まず 100 次元の実数ベクトルに変換し, 次に畳み込み関数を適用して 300 次元のベクトルにする. このベクトルに対し, 各次元の最大値を計算した結果として得られる 300 次元のベクトルを LSTM 関数に入力する. LSTM 関数の出力に線形関数を適用し, 最も値の大きい次元に対応するラベルを予測ラベルとする[石野 17].

本実験では, ベースライン手法として条件付き確率場(CRF)を用いて同様の実験を行う. 窓枠は 4, 素性は前後 4 語の uni, bi グラムとした.

評価尺度

CRF 及び LSTM を用いた実験では, 評価尺度として精度, 再現率, F 値を使用する. 以下に精度, 再現率, F 値の算出式を示す.

$$\text{精度} = \frac{\text{提案手法によって抽出された正しい対応文の数}}{\text{提案手法によって抽出された対応文の数}}$$

$$\text{再現率} = \frac{\text{提案手法によって抽出された正しい対応文の数}}{\text{すべての対応文の数}}$$

$$\text{F 値} = \frac{2 \cdot \text{精度} \cdot \text{再現率}}{\text{精度} + \text{再現率}}$$

4.2 実験結果

4.1 節で述べた図表と本文の自動対応付け実験の結果を表 4.1 に示す. 表 4.1 より, LSTM を用いた手法は CRF と比べ, 再現率が 0.1 程度低くなっているが, 精度は 0.26 高くなっており, 提案手法の有効性を示すことができたと考えられる.

表 4.1: 図表と本文の自動対応付け実験結果

	精度	再現率	F 値
LSTM	0.65	0.13	0.33
CRF (baseline)	0.39	0.23	0.29

4.3 考察

本節では, 4.2 節の実験結果に対する考察を行う. 4.2 節表 5 より, ベースライン手法よりも提案手法の精度が高くなっているが, 再現率に関しては低い値となってしまっている. 原因の一つとして, データ数が少なく, LSTM による学習が十分でないということが考えられる. これは, 人手による正解データを増やすことで改善することができる. そして, もう 1 つの原因として, タグの数が少ないことが考えられる. 本研究では, 最初に出現したキャプション名の入っている文にのみタグを付与している. しかし, キャプション内の語句や図表内の数値の有無は対応文抽出において重要な手掛かりになると考えられる. 「The」や「Our」などの図表の対応文に多く用いられている語句も多く存在すると考えられる. これらの要素についてもタグを付与することで精度, 再現率を向上させることができるのではないかと考えられる.

5. おわりに

本研究では, 論文中の図表に対応づいている文を自動的に抽出する手法を提案した. 4.2 節の実験により, 提案手法では精度 0.65 を得た. 比較手法の精度 0.39 と比べて, 0.26 ポイント向上させることができ, 提案手法の有効性を確認することができた.

参考文献

[Abekawa 16] Abekawa, Takeshi, and Akiko Aizawa: SideNoter: Scholarly Paper Browsing System based on PDF Restructuring and Text Annotation, the 26th International Conference on Computational Linguistics, (2016).

[Bach 11] Ngo Xuan Bach, Nguyen Le Minh, Tran Thi Oanh, and Akira Shimazu: Learning Logical Structures of Paragraphs in Legal Articles, Proceedings of the 5th International Joint Conference on Natural Language Processing, pp.20-28, (2011).

[福田 13] 福田悟志, 難波英嗣, 竹澤寿幸: 論文と特許からの技術動向情報の抽出と可視化, 情報処理学会論文誌 データベース Vol. 6, No. 2, pp.16-29, (2013).

[石野 17] 石野亜耶, 難波英嗣, 竹澤寿幸: Twitter を利用した旅行計画者の行動分析, 観光情報学会 第 16 回研究発表会, (2017).

[岩槻 98] 岩槻恵子: 説明文理解における要点を表す図表の役割, 教育心理学研究. Vol. 46, No. 2, pp.142-152, (1998).

[難波 09] 難波英嗣, 藤井敦, 岩山真, 橋本泰一: 論文と特許を対象にした技術動向分析, 第 7 回, 第 8 回 NTCIR ワークショップ 特許マイニングタスク, 情報管理 Vol.52, No.6, pp.334-342, (2009).

[Plank 16] Barbara Plank: Keystroke dynamics as signal for shallow syntactic parsing, the 26th International Conference on Computational Linguistics, (2016).

[Willot 15] Paul Willot, Kazuhiro Hattori, and Akiko Aizawa: Extracting Structure from Scientific Abstracts Using Neural Networks, In Proceedings of the 17th Asian Digital Library Conference (ICADL 2015), pp.329-330, (2015).

[Wu 11] Xianchao Wu, Katsuhito Sudoh, Kevin Duh, Hajime Tsukada, and Masaaki Nagata: Extracting Pre-ordering Rules from Predicate-Argument Structures, Proceedings of the 5th International Joint Conference on Natural Language Processing, pp.29-37, (2011).

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

意味解析システム ccg2lambda による金融ドキュメント処理

Semantic Parsing in ccg2lambda and its Application to Financial Document Processing

外園 康智 *1 Yasunori Hokazono
長谷川 貴博 *2 Takahiro Hasegawa
渡邉 知樹 *3 Kazuki Watanabe
馬目 華奈 *4 Kana Manome
簗 有紀子 *4 Yukiko Yana
谷中 瞳 *3 Hitomi Yanaka
田中 リベカ *4 Ribeka Tanaka
Pascual Martínez-Gómez*5 Pascual Martínez-Gómez
峯島 宏次 *4 Koji Mineshima
戸次 大介 *4 Daisuke Bekki

*1野村総合研究所 *2オメガ・パートナーズ *3東京大学 *4お茶の水女子大学
*5産業技術総合研究所

In this paper we study the capabilities of ccg2lambda to perform semantic parsing and natural language inferences in the financial domain. We observe that the system is conveniently modular and highly interpretable for humans since it includes graphical visualizations of semantic representations; these visualizations allow us to trace the process of semantic composition and easily identify points of failure. Moreover, it produces results in XML which make it easy to integrate in larger, in-house systems. The system separates the compositional mechanism from the specification of semantic theories, allowing extensions to handle new linguistic phenomena with a relatively small effort. Finally, we present our approach to adapt the system to the specialized vocabulary that arises in the financial domain by using axioms and ontologies.

1. はじめに

本稿では、日本語・英語のテキストを論理式に変換し、自動推論を行う意味解析システム ccg2lambda[*1] の基本的な機能を解説し、特にこのシステムを金融ドキュメントの処理へと応用する試みについて紹介する。

金融は情報産業とも言われるように、契約書、商品説明書、当局への届出書など、多くのドキュメントが生成され、関係者間でやり取りされる。その多くは、金商法などを元に、投資判断を誤解させないためのコンプライアンスや記載ルールが設定されている。商品や契約の細かな差異により単語や表現のバリエーションは多いが、ルール自体は適用範囲を広くするために抽象化された表現になっている。そのため、チェック担当者は、金融知識に加え、文の意味内容の理解と正確な推論が要求される。本研究では、このような専門性と正確性が要求されるチェックを自動で行うシステムの構築を試みる。

システムの対象業務は、上場申請書類の内容チェック、投資信託の商品概要書の記載チェック、取引契約書の不備チェックである。これらは、用語や表現が似ているので共通としたが、システムの応用範囲は、金融に限らず、法務関連や特許、契約書類など幅広く想定される。

深い意味解析と推論が要求されるテキスト処理のため、本研究では、形式意味論に基づく open domain の意味解析・推論システム ccg2lambda [Martínez-Gómez 16] を用いる。これは、組合せ範疇文法 (Combinatory Categorial Grammar, CCG) [Steedman 00, 戸次 10] に基づく統語・意味解析と自然言語推論を扱う高階論理の定理証明系を組み合わせたシステムであり、含意関係認識 [Mineshima 15, Martínez-Gómez 17] や文類似度計算 [Yanaka 17] に応用されている。

ccg2lambda では、統語・意味解析から推論までの各モジュールが明確に区別されており、統語情報・意味合成・意味表現を CCG 導出木としてグラフィカルに表現する機能をサポートしている。このため、処理プロセスのどの部分で解析エラーが起こったのかを容易に同定することが可能である。また、ccg2lambda は、特定の意味論からは独立な、ラムダ計算による一般的な意味合成メカニズムを用いているため、解析の対象となるドメインに特有の構文や言語現象に応じて、低コストで意味テンプレートを拡張することができる。ccg2lambda 自体は open domain の意味解析システムであるが、独自辞書や推論に必要となる公理を追加することで、特定ドメインに適合したシステムを構築・改良することが可能となっている。

本稿では、関連研究を紹介した上で (§2)、ccg2lambda の意味解析 (§3) と推論システム (§4) について解説する。特に金融ドキュメントを対象とした含意関係認識と矛盾検知について、具体例に基づいて説明する。金融ドキュメントチェックシステムの全体像、および、RTE テストセットに基づくシステムの評価については、[馬目 18] を参照してほしい。

2. 関連研究

論理式に基づく深い意味解析の手法は、英語 CCGBank [Hockenmaier 07]、及び、それに基づく高速な CCG パーザ [Clark 07] の出現により、大きな進展を遂げている。

CCG に基づいてテキストを論理式に変換する最初のシステムとしては、Boxer [Bos 04] がある。Boxer では、CCG の導出木は談話表示理論 (DRT) [Kamp 93] の意味表示、すなわち、談話表示構造 (Discourse Representation Structure, DRS) へと変換される。DRS は 1 階述語論理 (FOL) の論理式に変換可能であり、それを定理証明器・モデル構築器と接合することで、含意関係認識 [Bos 05] や意味類似度計算 [Bjerva 14] へと応用されている。他にテキストから DRS への変換を行う open domain の意味解析器としては、日本語と英語を対象にしたスコープ制御理論に基づく Treebank Semantics [Butler 12] や、フランス語を対象にした Type-Logical Grammar に基づく Grail [Moot 15] がある。

CCG に基づく意味解析・推論システムの最近の研究としては、CCG パーザの出力を、文の表層形に類似した意味表現である Lambda Logical Form (LLF) へと変換する LangPro [Abzianidze 17] がある。LangPro は、推論システムとし

*1 https://github.com/mynlp/ccg2lambda

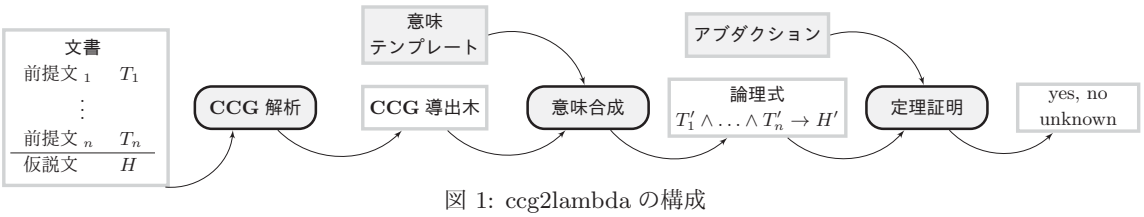


図 1: ccg2lambda の構成

て LLF に基づくタブローシステムを実装し、論理推論を含む含意関係認識のテストセットである SICK RTE データセットで高精度を達成している [Abzianidze 15]。

本研究が依拠する ccg2lambda は、FOL を部分系として含む高階論理に基づく推論システムを採用している。また、辞書項目の記述に比較的シンプルな設計に基づくテンプレートを用いているため、意味論を柔軟に拡張することが可能であり、多様なユーザーが比較的容易に扱えるような意味解析パイプラインを提供している。これは既存の論理ベースの意味解析システムと異なる点のひとつである。

3. 意味解析

含意関係認識とは、テキスト（前提文）$T_1, \ldots, T_n$ と仮説文 H との間に含意関係が成立するか否かを判定する課題である。ccg2lambda は、$T_1, \ldots, T_n$ と H を入力として、CCG パーザによる構文解析・意味解析により論理式 $T'_1, \ldots, T'_n, H'$ を得る。その上で、必要なドメイン知識を表現した知識ベースのもとで、$T'_1 \wedge \cdots \wedge T'_n \rightarrow H'$ が証明可能であるかどうかの判定を行う。図 1 に ccg2lambda の各モジュールの関係を示す。

以下では、より具体的な文の解析プロセスを順に説明する。

3.1 CCG パーザ

現在 ccg2lambda がサポートしている CCG パーザは、英語では C&C [Clark 07]、EasyCCG [Lewis 14]、depccg [Yoshikawa 17] の三つである。日本語 CCG パーザは、Jigg [Noji 16] と depccg の二つをサポートしている。複数のパーザの出力を用いることにより、パーザに由来するエラーを軽減することが可能となっている。

3.2 意味テンプレート

意味テンプレートは CCG の導出木の各ノードに対してラムダ項を割り当てる規則を記したものである。ラムダ項の形式は NLTK [Garrette 09] を用いている。意味テンプレートは、YAML[*2] ファイルに記述する。

意味テンプレートに記述される各規則には必ず `semantics` と `category` という属性が記述されなければならない。例えば、名詞に対応した規則として以下がある。

```
- category : N
  semantics : λE.λx.E(x)
```

この規則が適用されるノードとして、例えば、統語範疇 N をもつ「少年」という語のノードがあるとき、そこで得られる意味表現は、$(\lambda E.\lambda x.E(x))(\text{少年})$ となり、β 簡約が行われ、最終的な意味表現は $\lambda x.\text{少年}(x)$ となる。

名詞一般ではなく、「固有名詞」という品詞タグに適用するテンプレートを用意するには、`pos` という品詞に対応した属性を用いて、固有名詞のための規則を新しく作る。ノードに対して複数の規則が適用できる場合は、YAML ファイルの下に書かれた規則が優先して適用される。上記の規則は固有名詞に対しても適用可能であるので、以下の固有名詞だけを対象とする規則を新たに追加すればよい。

```
- category : NP
  semantics : λE.E
  pos1 : 固有名詞
```

形態素解析による品詞タグ付けには、kuromoji[*3] を用いている。また、CCG パーザから出力される統語範疇のより詳細な条件を属性に追加することができる。例えば、NP の統語素性 $[case = to]$ を以下のように指定することができる。

```
- category : S\NP[case = to]
```

Coq による自動推論に用いる意味表示の型は、自動で設定されるが、明示的に意味テンプレートで指定することもできる。例えば、自動詞の意味表示は `entity` を項にとって命題を返す関数であり、`coq_type` 属性で以下のように型を指定できる。

```
- category : S\NP
  semantics : λE.λx.E(x)
  coq_type : Entity → Prop
```

子を持つノードに対して適用される規則に対しては、`rule` という属性を用いることで、CCG の組合せ規則を参照する形で意味割り当てを行うことが可能である。また、子ノードを対象とした属性もある。子ノードに対して、左から順に 0、1 と順序を定めると、それぞれ child0、child1 として属性の対象にすることができる。例えば、右の子ノードに対して統語範疇を制限したいときは、`child1_category` 属性を用いる。子ノードのさらに子ノードに遡ることも可能であり、例えば、右の子ノードの左の子ノードの品詞を指定したいときは `child1_child0_pos` 属性を用いる。具体例として、$S\backslash NP$ を $NP\backslash NP$ へと変換する unary rule（いわゆる内の関係の連体修飾節を扱うための規則）は、次のように指定することができる。

```
- category : NP\NP
  rule : ANDint
  child0_category : S\NP
```

3.3 出力形式

CCG 導出木から意味表示を得るためには、semparse.py を用いる。

```
# python semparse.py ccgtrees.xml
templates.yaml semantics.xml
```

ここで、ccgtrees.xml は Jigg [Noji 16] の出力形式で記述された CCG 導出木の XML ファイルであり、templates.yaml は

*2 http://www.yaml.org/spec/

*3 https://www.atilika.com/ja/kuromoji/

```
<root>
  <sentences>
    <sentence>
      <tokens>
        <token base="tea" surf="tea" pos="NN"/>
        <token ...>
      </tokens>
      <ccg>
        <span id="s1" child="s2" category="N"
              rule="lex"/>
        <span ...>
      </ccg>
      <semantics>
        <span id="s1" child="s2" sem="\y._tea(y)"
              type="_tea : Entity -> Prop"/>
        <span ...>
      </semantics>
    </sentence>
  </sentences>
</root>
```

図 2: 意味合成結果の XML 形式

3.2 節で述べた意味テンプレートである。出力結果は semantics.xml に保存される。

出力形式は Stanford CoreNLP に従う。具体例を図 2 に示す。各ノードの属性の情報は ⟨*token*⟩ タグに記載されている。⟨*semantic*⟩ タグの内部にある ⟨*span*⟩ タグは sem 属性と type 属性をもつ。sem 属性には対象となるノードの意味表示が、type 属性には対象のノードの `coq_type` 属性が記述される。

visualize.py を用いて見やすい出力を得ることができる。

```
# python visualize.py semantics.xml
> semantics.html
```

このコマンドは、semantics.xml に保存されている意味表示の情報を HTML 形式の CCG 導出木に変換し、semantics.html に出力する。semantics.html の CCG 導出木では、各ノードを合成する組合せ規則が記載されており、各ノードに意味表示が付加されている。ルートノードの意味表示が入力文の意味表示（論理式）を表している。

4. 推論

4.1 含意関係認識と矛盾検知

得られた意味表示間の含意関係・矛盾関係の証明は、意味表示の XML ファイルを引数として、prove.py を実行することで実行可能である。次のコマンドを実行すると、semantics.xml に記述された意味表示間の含意関係・矛盾関係の証明が行われ、含意 (yes) か、矛盾 (no) か、不明 (unknown) かという証明の結果が出力される。

```
# python prove.py semantics.xml
```

prove.py では主に `--graph_out`、`--ncores`、`--proof` という三つのオプションがある。`--graph_out` オプションは、HTML 出力を指定するオプションである。出力 HTML ファイル名を引数に指定すると、CCG 導出木、意味表示、定理証明に要したスクリプトを表示した HTML ファイルを出力できる。`--ncores` オプションは、証明の同時実行数を指定するオプションである。大量の文について証明を行いたい場合に、証明の同時実行数を増やすことで効率的に処理することができる。`--proof` オプションは、XML 出力を指定するオプションである。ccg2lambda から得られた統語解析・意味解析・推論の結果を他のアプリケーションで利用したい場合に便利なオプションである。

(1) 本社債は、劣後特約が付されているため、発行者が発行する劣後特約が付されていない社債と比較して、元利金の弁済順位が低い劣後社債です。
(2) 本債券を含む劣後社債は、活発な流通市場が形成されていないため、一般の社債に比べて流動性が低くなります。
(3) 本社債は、売却できない、または希望する条件では売却できず、金利水準や発行者の経営状況または財務状況、格付けの状況等により元本を割り込む可能性があります。
(4) 劣後社債は、一般に流動性が高くなります。
(5) 本社債は、弁財順位が、一般の社債より高くなります。
(6) 本債券は、上場株式等の譲渡所得等として申告分離税の対象となります。

図 3: 矛盾検知の具体例

4.2 含意関係認識と矛盾検知の具体例

意味表示間の含意関係・矛盾関係の両方の証明を試みることにより、1 つのドキュメント内に互いに矛盾するような文が含まれていた場合に、その矛盾を検知することができる。図 3 の金融ドキュメントの具体例に基づいて説明しよう。このうち、(2) と (4)、(1) と (5) は互いに整合的でない。前者の矛盾は、記載内容のチェック項目として、例えば、「劣後社債は流動性が低い」という内容に注目したときに検知可能である。この項目の記載有無を (2) に対して調べると、(2) を前提文、上記チェック項目を仮説文とする入力に対して、出力結果は含意 (yes) となる。一方、同じ項目の記載を (4) に対して同様に調べた場合、(4) を前提文 T、上記チェック項目を仮説文 H とする入力に対して、出力結果は矛盾 (no) となる。これは形容詞「低い」「高い」が反義語であることによる。

T: 劣後社債は、一般に流動性が高くなります。
H: 劣後社債は流動性が低い。

このように、1 つの仮説文に対して含意 (yes) と矛盾 (no) の両方の結果が得られたことにより、それぞれの推論の前提文であった (2) と (4) の記述が矛盾していると判定できる。

4.3 アブダクション

自然言語の推論において、内容語間の意味的関係を語彙知識から補完する必要があるケースはしばしば存在する。たとえば、次の金融テキスト T にチェック項目 H の内容が含まれているかを含意関係の証明から示すことを考える。

T: 本債券は、上場株式等の譲渡所得等として申告分離税の対象となります。
H: 本債券は、分離課税の対象となる。

このとき、純粋な論理推論では「申告分離税」と「分離課税」は異なる述語として扱われるため、「分離課税」が「申告分離税」の上位概念であるという知識を推論に補完しなければ、T, H 間の含意関係を示すことができない。すなわち、語彙知識を用いて「申告分離税」と「分離課税」間の語彙関係を公理として推論に補完する（アブダクション）仕組みが必要である。ccg2lambda では、次のように prove.py のオプション `--abduction` に `spsa` を設定することで、アブダクション機能 [Martínez-Gómez 17] が利用できる。

```
# python prove.py --abduction spsa
```

アブダクションではまず、通常の証明を試みた結果、証明できずに残っている結論中の論理式に対して、共通の自由変数を持つ前提中の論理式を特定する。これは前提と結論の意味表示において単語間のアライメントを行うことと同じ意味合いを持ち、これによって効率的な前提探索を実現している。次に、特定された前提と結論の論理式間で意味的関係が成り立つか否かを語彙知識を用いてチェックする。語彙知識から意味的関係が確認できた場合、公理を補完して再度証明を実行する。

アブダクションに用いる語彙知識は、デフォルトでは英語 WordNet [Miller 95], VerbOcean [Chklovski 04] が語彙知識として登録されている。ccg2lambda に搭載されているアブダクション機能は、使用する語彙知識を限定しない。そのため、タスク固有のオントロジー知識など、他の語彙知識をユーザが追加することも容易である。

5. まとめと展望

本稿では、意味解析・推論システム ccg2lambda を用いて、金融ドキュメント解析を行う手法について解説した。含意関係認識・矛盾検知にこの種のシステムを応用する際のボトルネックの一つは、CCG パーザの精度にある [馬目 18]。この問題に対処するため、[Yoshikawa 18] では、前提文と結論文の文間整合性を考慮した CCG パージングの手法が提案されており、含意関係認識タスクでの精度向上が報告されている。

この他にも、ccg2lambda の拡張として、文類似度計算 [Yanaka 17] への応用や、アブダクション・システムを単語間の語彙知識だけでなく、フレーズ間の語彙知識を補完できるよう拡張する試みがある [Yanaka 18]。アブダクションを知識ベース補完 (Knowledge Base Completion) と組み合わせることで、自然言語推論のための定理証明を高速化する手法も提案されている [吉川 18]。こうした基本技術の発展により、個別ドメインへの応用はさらに進展するものと期待される。

参考文献

[Abzianidze 15] Abzianidze, L.: A Tableau Prover for Natural Logic and Language, in *Proceedings of EMNLP2015*, pp. 2492–2502 (2015)

[Abzianidze 17] Abzianidze, L.: LangPro: Natural Language Theorem Prover, in *Proceedings of EMNLP2017: System Demonstrations*, pp. 115–120 (2017)

[Bjerva 14] Bjerva, J., Bos, J., Goot, van der R., and Nissim, M.: The Meaning Factory: Formal semantics for recognizing textual entailment and determining semantic similarity, in *Proceedings of SemEval2014*, pp. 642–646 (2014)

[Bos 04] Bos, J., Clark, S., Steedman, M., Curran, J. R., and Hockenmaier, J.: Wide-coverage semantic representations from a CCG parser, in *Proceedings of COLING2014*, pp. 1240–1246 (2004)

[Bos 05] Bos, J. and Markert, K.: Recognising textual entailment with logical inference, in *Proceedings of HLT/EMNLP2005*, pp. 628–635 (2005)

[Butler 12] Butler, A. and Yoshimoto, K.: Banking meaning representations from treebanks, *Linguistic Issues in Language Technology*, Vol. 7, No. 1 (2012)

[Chklovski 04] Chklovski, T. and Pantel, P.: VerbOcean: Mining the Web for Fine-Grained Semantic Verb Relations, in *Proceedings of EMNLP2004*, pp. 33–40 (2004)

[Clark 07] Clark, S. and Curran, J. R.: Wide-coverage efficient statistical parsing with CCG and log-linear models, *Computational Linguistics*, Vol. 33, No. 4, pp. 493–552 (2007)

[Garrette 09] Garrette, D. and Klein, E.: An Extensible Toolkit for Computational Semantics, in *Proceedings of IWCS2009*, pp. 116–127 (2009)

[Hockenmaier 07] Hockenmaier, J. and Steedman, M.: CCGbank: a corpus of CCG derivations and dependency structures extracted from the Penn Treebank, *Computational Linguistics*, Vol. 33, No. 3, pp. 355–396 (2007)

[Kamp 93] Kamp, H. and Reyle, U.: *From discourse to logic: An introduction to modeltheoretic semantics of natural language, formal logic and DRT*, Kluwer (1993)

[Lewis 14] Lewis, M. and Steedman, M.: A* CCG Parsing with a Supertag-factored Model, in *Proceedings of EMNLP2014*, pp. 990–1000 (2014)

[Martínez-Gómez 16] Martínez-Gómez, P., Mineshima, K., Miyao, Y., and Bekki, D.: ccg2lambda: a compositional semantics system, in *Proceedings of ACL2016 System Demonstrations*, pp. 85–90 (2016)

[Martínez-Gómez 17] Martínez-Gómez, P., Mineshima, K., Miyao, Y., and Bekki, D.: On-demand Injection of Lexical Knowledge for Recognising Textual Entailment, in *Proceedings of EACL2017*, pp. 710–720 (2017)

[Miller 95] Miller, G. A.: WordNet: A Lexical Database for English, *Communications of the ACM*, Vol. 38, No. 11, pp. 39–41 (1995)

[Mineshima 15] Mineshima, K., Martínez-Gómez, P., Miyao, Y., and Bekki, D.: Higher-order logical inference with compositional semantics, in *Proceedings of EMNLP2015*, pp. 2055–2061 (2015)

[Moot 15] Moot, R.: A type-logical treebank for French, *Journal of Language Modelling*, Vol. 3, No. 1, pp. 229–264 (2015)

[Noji 16] Noji, H. and Miyao, Y.: Jigg: a framework for an easy natural language processing pipeline, in *Proceedings of ACL2016 System Demonstrations*, pp. 103–108 (2016)

[Steedman 00] Steedman, M.: *The Syntactic Process*, MIT Press (2000)

[Yanaka 17] Yanaka, H., Mineshima, K., Martínez-Gómez, P., and Bekki, D.: Determining Semantic Textual Similarity using Natural Deduction Proofs, in *Proceedings of EMNLP2017*, pp. 692–702 (2017)

[Yanaka 18] Yanaka, H., Mineshima, K., Martínez-Gómez, P., and Bekki, D.: Acquisition of Phrase Correspondences using Natural Deduction Proof, in *Proceedings of NAACL2018* (2018)

[Yoshikawa 17] Yoshikawa, M., Noji, H., and Matsumoto, Y.: A* CCG Parsing with a Supertag and Dependency Factored Model, in *Proceedings of ACL2017*, pp. 277–287 (2017)

[Yoshikawa 18] Yoshikawa, M., Noji, H., Mineshima, K., and Daisuke, B.: Consistent CCG Parsing over Multiple Sentences for Improved Logical Reasoning, in *Proceedings of NAACL2018* (2018)

[吉川 18] 吉川 将司, 峯島 宏次, 能地 宏, 戸次 大介 : 知識ベース補完を用いた高階論理推論のための自動公理生成, 言語処理学会第 24 回年次大会発表論文集, pp. 113–116 (2018)

[戸次 10] 戸次 大介 : 日本語文法の形式理論: 活用体系・統語構造・意味合成, くろしお出版 (2010)

[馬目 18] 馬目 華奈, 外園 康智, 長谷川 貴博, 小西 優祐, 渡邉 知樹, 簗 有紀子, 谷中 瞳, 田中 リベカ, 峯島 宏次, 戸次 大介 : 含意関係認識による金融ドキュメントチェックへの取り組み, 言語処理学会第 24 回年次大会発表論文集, pp. 1159–1162 (2018)

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

[3G2] [General Session] 9. NLP / IR

座長:西田 京介（NTT）

Thu. Jun 7, 2018 3:50 PM - 5:30 PM Room G (5F Ruby Hall Hiten)

[3G2-01] Proposal of Metrics Measuring Coherence Based on Sentence Similarity Graph with Document Structure

○Mana Ihori[1], Atsuko Tominaga[2], Yoshinari Takegawa[2], Keiji Hirata[2] （1. Future University Hakodate Graduate School, 2. Future University Hakodate）

3:50 PM - 4:10 PM

[3G2-02] Textual Evidence Inference for Debating AI

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

4:10 PM - 4:30 PM

[3G2-03] Automatically building English synonym dictionaries by using European Patent publications

○Koji Marusaki[1], Kazuhiko Tsuda[1] （1. Graduate School of Business Sciences, University of TSUKUBA）

4:30 PM - 4:50 PM

[3G2-04] Continuous Representation of Confusion Networks for Neural Spoken Utterance Classification robust to Automatic Speech Recognition Errors

○Ryo Masumura[1], Yusuke Ijima[1], Taichi Asami[1], Hirokazu Masataki[1], Ryuichiro Higashinaka[1] （1. NTT Corporation）

4:50 PM - 5:10 PM

[3G2-05] Lexical Simplification Using Word Embedding to Approximate Word Sense

Shohei Takada[1], ○Yuki Arase[1], Satoru Uchida[2] （1. Graduate School of Information Science and Technology, Osaka University, 2. Faculty of Languages and Cultures, Kyushu University）

5:10 PM - 5:30 PM

©The Japanese Society for Artificial Intelligence

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

文章構造を取り入れた文間類似度グラフに基づいた一貫性に関する評価指標の提案

Proposal of Metrics Measuring Coherence
Based on Sentence Similarity Graph with Document Structure

庵 愛 *1 Mana Ihori　冨永 敦子 *2 Atsuko Tominaga　竹川 佳成 *2 Yoshinari Takegawa　平田 圭二 *2 Keiji Hirata

*1公立はこだて未来大学大学院 Future University Hakodate Graduate School　*2公立はこだて未来大学 Future University Hakodate

Coherence of the document is having unity of semantic, fuher It is necessary to write a document that is easy to understand. It is difficult to evaluate coherence of long document, since demand of automatic evaluation of coherence is high. Also, previous method focused on adjacent sentences to evaluate coherence. However, it is necessary to consider document structure, since document consists of multiple segments. Therefore, in this research, we propose metrics measuring coherence based on sentence similarity graph with document structure. We performed comparative experiments with previous method. As a result, some output accuracies comparable to previous method, it is assumed that proposed method is valid to evaluate coherence.

1. はじめに

一貫性とは，文章の意味的なまとまりの良さであり [田窪 04]，わかりやすい文章の執筆に必要である．しかし，一般に文章が長くなるほど人手での一貫性の評価は難しいため，一貫性の自動評価における需要性は高い．

ここで，文章には章や段落といった粒度の異なる構造が多数存在する．例えば，いくつかの文が部分的にまとまって段落を成し，小さい段落が互いに結合し次第に章などの大きな構造を成す．これによって，最終的に 1 つの文章を成している．砂山らは，理解しやすい文章とは前後の構造間の関係が明確であり，全体を通して一貫した話の流れが存在すると述べている [砂山 06]．そのため，文章全体における一貫性を評価するためには，前後する 2 文間における一貫性から段落，節，章など構造間の一貫性の情報を含む必要がある．

本研究の目的は，論文執筆者によって書かれた文章の一貫性に関する自動評価である．本研究で対象とする論文における文章は，文章構造が顕著に表れているという特徴がある．本稿では，文章の構造を取り入れた一貫性に関する評価指標を提案し，その評価指標について従来手法との比較実験および考察を行う．

2. グラフに基づく一貫性モデル

Barzilay らは，前後する 2 文間における局所的な一貫性に関して，Entity grid モデルを提案した [Barzilay 05]．Entity grid とは，文章中における名詞句などの談話要素の分布パターンを捉える表現方法である．Entity grid の構成要素は各談話要素の構文役割であり，例えば以下の文章では表 1 のように表現される．

S1 ：エクセルには文字の置換機能があります．

S2 ：置換では文字を置き換えることができます．

S3 ：しかし，「すべて置換」には注意が必要です．

Eintity grid モデルは，Entity grid を用いて文章中に出現する談話要素がどのように遷移するかを捉えることで一貫性を評価している．このモデルは高い評価性能を算出したが，複雑な計算が必要であることや前後する 2 文間の一貫性しか評価できないといった問題があった．

表 1: Entity grid

	エクセル	文字	置換	機能	注意
S_1	S	X	O	O	-
S_2	-	X	S	-	-
S_3	-	-	S	-	O

S = 主語，O = 目的語，X = その他，- = 出現なし

そこで，Guinaudeau らは Entity grid のグラフ表現に基づくモデルを提案した [Guinaudeau 13]．この手法では，構文役割が数値（主語 : 3，目的語 : 2，その他 : 1，出現なし : 0）で表された Entity Grid を用いてグラフを作成し，そのグラフの特徴から一貫性を評価している．

以下に Guinaudeau らのモデルの実装方法を示す．表 1 から，要素を共有する文同士のみを用いて図 1 の従来手法のようなグラフを作成する．そのグラフから，枝の重みを利用することで一貫性の評価値を算出する．ここで，枝の重みづけは以下の 3 手法が提案されている ;（1）Unweighted:共有の要素が存在する場合に重みを 1 とする，（2）Weighted:共有の要素の数を重みとする，（3）Acc : 共有の要素の構文役割における数値を掛け合わせたものを重みとする．最終的な重みは，隣り合わない文同士の重要度を下げるため，各値と文同士の距離との除算によって得られる．文章 D における最終的な一貫性の値は，以下の通りに計算される（N=文章を構成する文の総和，S_i=i 番目の文における枝の重み）．この値が高いほど，一貫性も高くなる．

$$LocalCoherence(D) = \frac{1}{N}\sum_{i=1}^{N} OutDegree(S_i)$$

Guinaudeau らのモデルでは，より簡単な計算で従来の Entity grid モデルに匹敵する性能を算出し，非隣接の 2 文間における一貫性を考慮することが可能になった．しかし，Guinaudeau らのモデルでは単純な文同士の繋がりにしか着目して

連絡先: 庵 愛，公立はこだて未来大学，〒 041-8655 北海道函館市亀田中野町 116-2，0138-34-6462，g2117008@fun.ac.jp

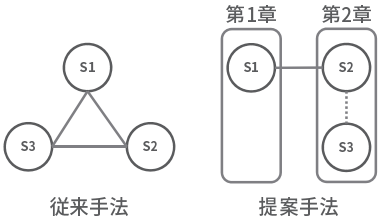


図 1: 従来手法と提案手法のグラフ表現

おらず，上記で述べた構造間の一貫性は考慮されていない．

3. 提案手法

3.1 文間類似度グラフ

本研究で用いる文間類似度グラフとは，文間のコサイン類似度に基づいた連結性行列を隣接行列として作成するものである．このグラフは複数文書要約手法などに用いられており，文書の全体像をまとめることに適している [Erkan 04]．本研究では，tf 値によって構成された文ベクトルを用いて，以下の式でコサイン類似度を計算する．

$$sim(v_x, v_y) = \frac{\sum_{i=1}^{n} v_{xi} \cdot v_{yi}}{\sqrt{\sum v_{xi}^2} \cdot \sqrt{\sum v_{yi}^2}} \quad (1)$$

ここで，v_x，v_y は文ベクトルを，n は文章中に出現するすべての単語数を，v_{xi}，v_{yi} は i 番目の単語における tf 値を表している．文ベクトルは 1 文という情報量の少ない単位から構成されるため，正確に算出できる値として tf 値を用いている．本研究では，文章における文に対して式（1）を用いて類似度を計算し，類似度が 0.1 以上になった文のみを用いてグラフを作成する．Guinaudeau らのモデルでは，談話要素が 1 つでも共有されているとグラフを作成していたため，本研究でもグラフが作成される条件を低く設定するために基準値を 0.1 とした．

ここで，Guinaudeau らのモデルでは取り入れられていなかった，文章構造の概念をグラフ作成時に用いる．S1 が第 1 章，S2，S3 が第 2 章に属する文であると仮定すると，図 1 の提案手法のようなグラフが作成される．従来手法では，文がどの章，段落といった構造に含まれているかが考慮されていなかったが，提案手法では，章や段落などの構造で区切られたグラフを作成することで，文章構造をグラフに取り入れる．

また，S2 と S3 は同じ第 2 章に属する文だが，同じ章でも違う段落に属している可能性がある．そのため，上位構造で同じ構造に含まれる文では，直下の構造に粒度を落として着目し，異なる構造に属するようになるまで構造の粒度を落としてグラフを作成する（図 2）．つまり，類似度が 0.1 以上の文同士が存在する限り，文章が持つ構造の数だけグラフが作成されることになる．

3.2 グラフごとの一貫性指標

前節で作成したグラフを用いて，グラフごとの一貫性を算出する．グラフ中の一貫性を表す特徴量として，我々は，構造網羅割合，枝の重み，構造同士の距離，枝数に着目した．構造網羅割合とは，グラフが直下の構造をどの程度網羅しているかを表した値である．例えば，図 1 における提案手法のグラフが 5 章構成の文章から作成されたとすると，出現する章の数

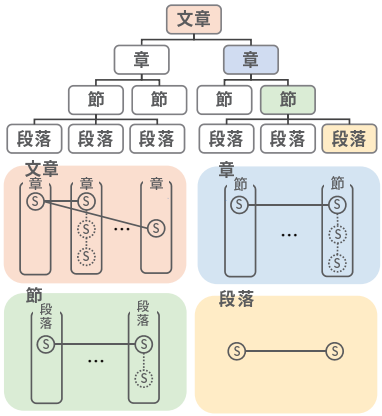


図 2: グラフの作成方法

は 2 である．従って，このグラフでの構造網羅割合は，2/5 で 0.4 となる．多くの構造を網羅するほど一貫性が高くなると考えられるため，この値が 1 に近づくほど評価値は高くなる．

次に，類似度グラフを用いているため，枝の重みは文同士の類似度とする．この重みは，先行研究が文同士の距離との除法によって算出されるのに対して，本研究では構造同士の距離との除法によって算出される．例えば，図 2 における節で作成されたグラフに着目すると，2 つの段落をまたぐグラフが形成されている．ここで，段落が第 3 段落と第 7 段落だとすると，構造同士の距離は 7-3 で 4 となる．以上の 2 つの特徴量は，文同士の類似度が高く，近くの構造に属しているほど評価値は高くなる．ここで，類似している文の総数はグラフごとに異なるため，グラフごとの一貫性の評価値を等しく見るためにグラフの総枝数で正規化する．以上の特徴量を踏まえ，n 個の枝を持つグラフ S の一貫性の値は以下の式で計算する．

$$LocalCoherence(S) = \text{構造網羅割合} \times \frac{1}{n} \sum_{i=1}^{n} \frac{\text{類似度}}{\text{構造同士の距離}} \quad (2)$$

3.3 文章全体における一貫性指標

式（2）では，構造ごとに作成されるグラフにおける一貫性の値が計算される．文章が複数の粒度の異なる構造から成り立つように，各構造ごとの一貫性の集合によって文章全体の一貫性が算出されると考える．我々は，グラフごとの一貫性を文章構造における特徴を踏まえて値を集約する方法を提案する．

図 2 に示すように，文章構造は章の下に節があり，節の下に項がある構造になっていることが多い．そのため，文章全体の一貫性を算出する際には下位構造の値の平均を掛け合わせていく．例えば，図 2 中の節は，3 つの段落を持ち合わせている．そのため，節の一貫性の値は，もともとの節の一貫性の値に，3 つの段落の一貫性の平均値を掛け合わせたものとなる．我々は，下位構造の一貫性の値が 0 であった場合を考慮するため，提案式に乗法を用いた．ここで，本研究における文章の構造は，章の下に節，節の下に項，項の下に段落，段落の下に文があることを基本と考える．

以下に，下位構造を考慮した一貫性を算出する式を示す．ここで，S_u は現在着目している構造を，S_d はその構造が持つ m 個の下位構造を表している．この計算を文章レベルまで繰り返して計算することで，文書全体にける一貫性の値を算出で

きる．

$$Coherence(D) = LocalCoherence(S_u) \times \frac{\sum_{i=1}^{m} LocalCoherence(S_d)}{m} \quad (3)$$

3.4 上位/下位構造を重視するパラメータの付与

本研究で提案する評価指標では，上位/下位構造における評価値の平均を掛け合わせることで文章全体の評価値を計算する．そのため，上位構造と下位構造それぞれに重視する構造を選択可能なパラメータを設定することで，どちらかの値を重視した一貫性の値を算出できる．例えば，上位構造では文章全体における一貫性を，下位構造では文同士における一貫性を重視した一貫性の値を算出する．我々は，このパラメータを調節することで，重視する構造を選択できると考えらる．そこで，式（3）に以下の様なパラメータ α(0〜1) を付与する．今回は，任意の値として重視する構造が上位の場合には 0.9 を，下位の場合には 0.1 を設定した．また，それぞれの構造を等しく重視する場合には，0.5 を設定した．

$$Coherence(D) = LocalCoherence(S_u)^{\alpha} \times (\frac{\sum_{i=1}^{m} LocalCoherence(S_d)}{m})^{1-\alpha} \quad (4)$$

4. 評価実験

以上の評価指標の性能を測るために従来手法との比較実験を行う．比較実験では，先行研究に従って，Discrimination [Barzilay 08] と Insertion [Elsner 11] の 2 種類の手法で人工的に一貫性の低い文章データを作成し，評価値を計算する．これらの手法では，元の文章データの文の順番を入れ替えることで一貫性の低い文章データを作成するため，文数や文章の構造が異なるデータの比較を防止できる．

まず，Discrimination とは元の文章における文の順番をランダムに入れ替えたデータを作成する手法である．本手法では，Discrimination によって作成された文章と元の文章において一貫性の評価値を算出し，元の文書における評価値が高い場合に評価指標の出力は正しいということになる．本研究では，先行研究に従って Discrimination を用いて 20 件の一貫性の低いデータを作成し，元の文書との一貫性の評価値を比較する．20 件のデータ中，元の文書より評価値が低くなったデータ数を正解データ数とし，F 値を算出することで従来手法との比較を行う．

次に，Insertion とはある 1 文を文章から抜き出し，抜き出した文の元の位置を検索する能力を評価する手法のことである．具体的には，文書中の各文を順番に抜き出し，可能性のあるすべての位置に挿入する．すべての位置に挿入するごとに，一貫性の評価値を算出する．本手法では，最も高い評価値が出力されたときの文の位置が元の位置と同じである場合，システム出力は正しいということになる．本研究では，実験時間の関係から各文ではなく，ランダムに選択した 20 文について，可能性のあるすべての位置に挿入する．ランダムに選択された 20 文のうち，最も高い評価値を出力したのが，元の位置と同じであった場合の割合を Insertion score（Ins）として算出することで従来手法との比較を行う．

また，本研究では文章の構造を考慮した一貫性指標を提案した．そのため，従来研究では Discrimination と Insertion を文のみを対象として行っていたが，ここでは章を対象としても同様の実験を行う．各評価も，同様の方法で実施する．

表 2: 各論文における構造ごとの枝数の平均

	文章	章	節	項	段落
dataA	3522.00	737.57	313.43	43.50	206.57
dataB	3116.43	841.86	627.29	149.14	182.86

本研究では，ジャーナル論文を対象としてこれらの実験を行う．ジャーナル論文は，厳格な査読を経ているため一般的な論文よりも一貫性が高いことが期待される．本実験では，同じ著者によって書かれた教育工学系のジャーナル論文 7 件，情報工学系のジャーナル論文 7 件を用いた．表 2 に，各ジャーナル論文から作成されるグラフの枝数を示す．なお，教育工学系の論文データセットを dataA，情報工学系の論文データセットを dataB とする．ここで，本研究で作成されるグラフは，図 2 に示すように構造をまたいで形成されるものと，同じ構造内で形成されるものがある．各データセットに対してグラフの形成に異なる性質があるかを調査するために，各構造間，構造内における枝数の差について対応なしの t 検定を行った結果，文章と章において有意差が認められた（t(12)=2.21, p<.05, t(12)=2.26, p<.05）．そのため，dataA で形成されるグラフでは，主に上位構造において dataB よりも構造間の枝数が多いといえる．

5. 結果

まず，文を対象とした Discrimination と Insertion を用いた従来手法との比較実験の結果を表 3 に示す．Discrimination の結果について，従来手法では，各データのすべての場合において最も高い F 値を算出した．一方，提案手法では，各データにおいて $\alpha = 0.1$ と $\alpha = 0.5$ で比較手法に匹敵する F 値であったが，$\alpha = 0.9$ で著しく値が低かった．Insertion の結果について，従来手法では，各データにおいて Weighted で最も高い Ins を算出した．一方，提案手法では，各データにおいて $\alpha = 0.1$ で高い Ins を算出したが，Weighted より低い値であった．そこで，Weighted と $\alpha = 0.1$ の Ins について，対応なしの t 検定を行った結果，有意な差は認められなかった（t(12)=1.80, p=0.1, t(12)=1.80, p=0.1）．つまり，文を対象とした入れ替えでは，提案手法のうち $\alpha = 0.1$ では従来手法に匹敵する精度で評価できるといえる．

次に，章を対象とした Discrimination と Insertion を用いた従来手法との比較実験の結果を表 4 に示す．Discrimination の結果について，従来手法では，各データにおいて Unweighted 以外で高い F 値を算出した．一方，提案手法では，各データにおいて $\alpha = 0.1$ で最も高い F 値を算出し，従来手法を上回った．Insertion の結果について，従来手法では，dataA については Acc で，dataB については Unweighted で高い Ins を出力した．一方，提案手法では，各データについて $\alpha = 0.9$ の場合に高い Ins を出力し，dataB においては従来手法を上回った．つまり，章を対象とした入れ替えでは，提案手法で従来手法を上回る精度で評価できるといえる．

6. 考察

まず，文を対象とした実験に関する考察を行う．実験の結果，Discrimination では，提案手法の $\alpha = 0.9$ は他と比べて著し

表 3: 文を対象とした実験の F 値と Ins の平均値

	F 値		Ins	
	dataA	dataB	dataA	dataB
Unweighted	1.0	1.0	0.086	0.036
Weighted	1.0	1.0	0.107	0.100
Acc	1.0	1.0	0.064	0.050
$\alpha = 0.1$	1.0	1.0	0.036	0.043
$\alpha = 0.5$	1.0	1.0	0.021	0.007
$\alpha = 0.9$	0.19	0.14	0.007	0

表 4: 章を対象とした実験の F 値と Ins の平均値

	F 値		Ins	
	dataA	dataB	dataA	dataB
Unweighted	0.71	0.71	0.51	0.69
Weighted	0.86	0.86	0.57	0.65
Acc	0.86	0.86	0.66	0.60
$\alpha = 0.1$	1.0	1.0	0.32	0.17
$\alpha = 0.5$	0.36	0.24	0.05	0.02
$\alpha = 0.9$	0.65	0.71	0.43	0.71

く F 値が低くなっていた．このことから，上位構造を重視することに問題があると考えられる．その原因として，文を対象とした Discrimination ではグラフの形成が大きく変化することが挙げられる．例えば，S1〜S5 の 5 文を持つ文章のうち S1 と S3 を入れ替える実験を行う．ここで，元の文章におけるグラフと文を入れ替えた後におけるグラフを図 3 に示す．従来手法では文同士の距離しか変わらないのに対して，提案手法ではグラフの構造自体が変わってしまう．具体的には，元の文章では S2 と S3，S4 と S5 が同じ構造内でグラフを形成しているのに対して，入れ替えた文章では同じ構造内でグラフは形成されない．このように，提案手法では文を入れ替えることによって下位構造のグラフが消失する可能性がある．そのため，下位構造に関する特徴量が減り上位構造に吸収されるために，上位構造の評価値が高くなり，下位構造の評価値が低くなると考えられる．これより，下位構造の変化を重視した方が一貫性の変化も捉えやすいと考えられる．

次に，章を対象とした実験に関する考察を行う．実験の結果，Discrimination では，提案手法の $\alpha = 0.1$ の場合に従来手法を上回る F 値を出力した．このことから，文章構造を取り入れた本評価指標では，章などの構造の入れ替えに対する一貫性の評価に従来手法よりも適していると考えられる．また，Insertion を行った結果では，dataA と dataB で異なる傾向が見られた．dataA では，従来手法の Acc で最も高い Ins を出力したのに対して，dataB では提案手法の $\alpha = 0.9$ で最も高い Ins を出力した．この結果と，dataA と dataB でグラフの特徴が異なることから，本評価指標で評価するのに適したグラフがあると考えられる．さらに，$\alpha = 0.5$ ではどちらの実験においても評価値が高くなかったことから，本評価指標では上位/下位構造のどちらかに重みを置いた方が高い性能で評価できると考えられる．今後，これらの要因を踏まえて評価指標について再検討を行う必要がある．

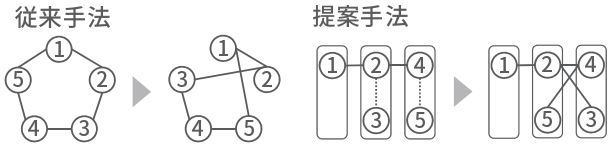


図 3: グラフの形成

7. おわりに

本研究は文章構造を考慮した一貫性の自動評価を目的に，文間類似度グラフに基づく評価指標を提案した．具体的には，文間の類似度を用いて章や段落といった文章の構造ごとにグラフから構造網羅割合，文同士の類似度，構造同士の距離，枝数を用いて一貫性を算出する式を作成し，章，節，項，段落といった粒度の異なる構造を考慮してすべての一貫性を掛け合わせる手法を提案した．その際に，上位構造，下位構造のどちらかを重視できるパラメータの設定も提案した．提案手法における評価性能の調査のため，従来手法との比較実験を行った．その結果，ある条件においては従来手法を上回る結果を出力した．

今後の課題として，入れ替える構造によっては，本評価指標に適していないデータも存在すると考えられるため，グラフの特性と評価指標の関係を分析する必要がある．また，今回は α の値を任意で定めていたが，最適な値を検討する実験を行うべきだと考える．

参考文献

[Barzilay 05] R. Barzilay and M. Lapata. "Modeling local coherence: an entity-based approach," Computational Linguistics, pp. 141-148, 2005.

[Barzilay 08] R. Barzilay and M. Lapata. "Modeling local coherence: An entity-based approach," Computational Linguistics, Vel. 34, No. 1, pp. 1-34, 2008.

[Elsner 11] M. Elsner and E. Charniak. "Extending the entity grid with entity-specific features," In Proceedings of the ACL 2011 Conference Short Papers, pp. 125-129, 2011.

[Erkan 04] G. Erkan and D. R. Radev, "LexRank: Graph-based Lexical Centrality as Salience in Text Summarization," Journal of Artificial Intelligence Research, Vol. 22, pp. 457-579, 2004.

[Guinaudeau 13] C. Guinaudeau and M. Strube. "Graph-based Local Coherence Modeling," Proceedings of the 51st Annual Meeting of the Association for Computational Linguistics, pp. 93-103, 2013.

[砂山 06] 砂山渡，橘啓八郎，" サブトピックモデルに基づく文章の流れの評価指標の提案，" 日本知能情報ファジィ学会誌，Vol. 18, No. 2, pp. 280-289, 2006.

[田窪 04] 田窪行則，西山佑司，三藤博，亀山恵，片桐恭弘．談話と文脈 言語の科学 7 岩波書店，pp. 193-232，2004.

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

ディベート型人工知能のための言語的証拠性推論問題の定式化

Textual Evidence Inference for Debating AI

柳井 孝介 *1 Kohsuke Yanai　佐藤 美沙 *1 Misa Sato　柳瀬 利彦 *1 Toshihiko Yanase　是枝 祐太 *1 Yuta Koreeda

*1日立製作所 研究開発グループ
Research & Development Group, Hitachi Ltd.

This paper defines textual evidence inference problem, a new NLP task for decision-making application. The objective of the textual evidence inference problem is to classify a given text into evidence categories based on a given decision-making question and a given set of sentences representing values and preferences of decision-makers. We report the technical difficulties of the problem by using newly developed dataset.

1. はじめに

著者らの研究グループでは，人と議論ができるディベート型人工知能の研究を進めている [Sato 15]．ディベート型人工知能は，与えられた議題に対して，その賛否の根拠を提示することで，政策決定者や経営者の判断を支援する．たとえば,「カジノを建設すべきか」という議題が与えられると,「地域経済の活性化につながるので禁止すべき」や「ギャンブル依存症の問題を引き起こすので建設すべきでない」などの賛否の理由と，その根拠となる事例をニュース記事や白書の中から抽出して提示する．

本稿では，ディベート型人工知能のコア部分の 1 つとなる証拠性推論を定式化し，その問題の性質を議論する．具体例として，以下の 2 文の関係性を考える．

q ： カジノを建設すべきか

t ： ミシシッピ州では 31 箇所あるカジノにより，およそ 35,000 人の雇用が創出されている

意思決定上の質問 q に対し，テキスト t は肯定的な証拠となっていると考えることができる．これを抽象化して，意思決定上の質問 q に対して，テキスト t が肯定的あるいは否定的な証拠になっているかどうかを判定する問題として，証拠性推論を定義することができる．

証拠性推論は，テキスト含意関係認識（Recognizing Textual Entailment）と形式的には似ている．テキスト含意関係認識とは，2 つのテキスト t_1 と t_2 が与えられたときに，t_2 が t_1 に意味的に含まれるかどうかを判定する問題である．たとえば，

t_1 ： ミシシッピ州では 31 箇所あるカジノにより，およそ 35,000 人の雇用が創出されている

t_2 ： 雇用を生み出すカジノもある

t_3 ： カジノは雇用を生み出す

の 2 文があったとき，t_1 から t_2 を厳密に導くことができる．一方，t_3 は一般論として述べているのだとすると，t_1 は特殊な事例について述べているかもしれないため，t_1 からだけでは導くことができず，含意関係は成り立たない．あきらかに上記の q と t は含意関係にはなく，証拠性推論はテキスト含意認識とは別の種類の問題といえる．

再度，q と t の関係に注目すると，本当に t が肯定的な証拠になっているか，に関しても考察を要する．仮に，カジノを建設しようとしている地域が，労働者不足だったとすれば，t は意思決定において肯定的な証拠にはならないと思われる．より簡単な例では,「商品 X を購入すべきか」という意思決定上の質問があったときに,「商品 X の色はグレー」というテキストが，肯定的な証拠になっているか，というものがある．購入しようとしている人がグレーが好きであれば，肯定的な証拠であるし，そうでなければ，肯定的な証拠にはならない．したがって，証拠性は，意思決定をしようとしている人の価値観のようなものに依存すると考えることができる．この価値観とは，意思決定をしようとしている人の願望，目的，好みなどとみなすことができる．たとえば，下記のものが，意思決定を行うときに価値観の一種と考えることができ，これらは，意思決定する人や組織のコンテクストによって変わると考えられる．

雇用を生み出す
色がグレー系である
アジアで新事業を立ち上げる
貧困をなくす
持続可能な生産消費形態を確保する

本稿では，2 章で関連研究を述べ，3 章で証拠性推論問題を定式化し，作成したデータに関して説明する．4 章で作成したデータに基づいて証拠性推論がどのような性質の問題なのかを分析し，5 章で今後の方向性を述べる．

2. 関連研究

著者らの研究グループでは，類似の自然言語処理のタスクとして，サポート性推定を定式化し，それを解く手法を提案している [佐藤 16]．サポート性推定では，議論の対象 o と注目する価値 v とテキスト t が与えられたときに，テキスト t が o と v の間の促進作用または抑制作用をサポートしているかどうかを推定する．サポート性推定は，本稿で議論する証拠性推論を解く際の部分問題の 1 つと考えることができる．証拠性推論は，サポート性推定で扱っていた問題を再整理し，より一般化された問題として定義したものと捉えることができる．

連絡先: 柳井 孝介，日立製作所 研究開発グループ，
kohsuke.yanai.cs@hitachi.com

また著者らの研究グループでは，人の価値観を体系化した価値オントロジを構築し，それに基づいてテキストデータを分類したり要約したりするシステムを提案している [柳井 15]．本稿では，価値観をオントロジで表すのには限界があると考え，オントロジではなく，自然言語文の集合で価値観を表現する．

Rinott らは Context Dependent Evidence Detection というタスクを提案している [Rinott 15]．たとえば「ドーピングはアスリートの健康に悪い」という主張が与えられたときに，文書の中から，定量的な証拠，専門家の見解，事例的な証拠を分類して抽出する．このタスクは，証拠に特化したテキスト含意関係認識に近いと考えられる．

3. 証拠性推論問題

3.1 定義

意思決定上の質問 q，価値観を表す文集合 $\{v_1, v_2, \cdots v_n\}$，テキスト t が与えられたときに，t が各 $\{v_i\}$ に対して，以下のいずれかであることを推定する．

- PE: 肯定する証拠（positive evidence）
- NE: 否定する証拠（negative evidence）
- N-PE: 肯定していない証拠（non positive evidence）
- N-NE: 否定していない証拠（non negative evidence）
- NA: 証拠ではないもの（not evidence）

肯定していない証拠とは，たとえば，「X 州では，カジノにより失業率は改善しなかった」のように，意思決定上の質問 q に対する肯定を否定するような証拠である．このテキストは「カジノを建設すべきか」を否定もしていないことに注意する必要がある．同様に，否定していない証拠もありうる．N-PE や N-NE は，数は少ないと思われるが，意思決定において反例を見つけるときに重要となる．

証拠性推論問題の具体例は，以下のようなものである．

q ： カジノを建設すべきか
v_1 ： 雇用を生み出す
v_2 ： 持続可能な生産消費形態を確保する
v_3 ： 陸域生態系の保護，回復，持続可能な利用を推進する
t ： ミシシッピ州では 31 箇所あるカジノにより，およそ 35,000 人の雇用が創出されている

このときに，t が，v_1，v_2，v_3 のそれぞれに対して，上記の PE，NE，N-PE，N-NE のどの証拠か，あるいは証拠になっていないかを推測する問題である．$\{v_i\}$ は 1 つでも，自然言語処理のタスクとしては成立するが，実用的なユースケースでは複数の価値を考慮する必要があることが多いため [*1]，あえて複数の価値があることを問題の定義に含めた．

通常，t は新聞や白書の 1 文やパラグラフを使うことが考えられるため，その長さを制限するのは難しい．一方で，意思決定上の質問 q と 価値観を表す文集合 $\{v_i\}$ は，ある程度，ユースケースで制御できる．あきらかに q や $\{v_i\}$ の文長が長くなれば，自然言語処理のタスクとして難しくなる．そこで，テキスト x に含まれる節の数 $L_{ph}(x)$ を用いて，タスクの難しさを表す近似として，

$$\mathrm{TEI}(L_{ph}(q), \frac{1}{n}\sum_{i=1}^{n} L_{ph}(v_i)) \quad (1)$$

と書くことにする．これは単に，意思決定上の質問 q に含まれる節の数と，価値を表す文集合の節の数の平均を表している．たとえば，上記の証拠性推論問題の例の場合は，係り受け解析ツールである CaboCha [Kudo 02] のチャンク数で節の数を数えることにすると，TEI(2, 5) と表せる．意思決定上の質問 q が複数あるときは，それぞれの数を q に対して平均を取るものとする．

表 1: 分析用のデータセット

項目	数
意思決定上の質問 q の種類	12
q あたりの平均の価値観数 n	4.2
(q, v_i) の数	52
(q, v_i, t) の数	101
肯定する証拠 (PE) の数	54
否定する証拠 (NE) の数	37
肯定しない証拠 (N-PE) の数	6
否定しない証拠 (N-NE) の数	4

4. 問題の性質の分析

証拠性推定の問題の性質を分析するための小規模のデータセットを作成した．日本語の新聞記事を文で区切ったものを t の対象とした．表 1 にデータセットの概要を示す．データセットを証拠性推論の評価用データとみなした場合のタスクとしての難しさは，TEI(2.3, 4.1) であった．以下では CD-毎日新聞データ集 [*2] のテキストから引用し，例を示しながら問題の分析をする．

[例 1]
q ： カジノを建設すべきか
v_1 ： 財政収入を増やす
t ： 政府の説明では，カジノの解禁で年間一億五千万スイスフラン（約百二十億円）の収入が見込まれるとしている．

肯定する証拠と人手で分類された例である．厳密に考えれば，「カジノの解禁」が「カジノを建設」することにつながり，「カジノを建設」することで，収入が増えることを，t が暗に示している．厳密に意味を考えれば，「カジノを建設」が間に挟まることを推論する必要がある．しかしこの例に限れば，そこまで深い意味解析や推論をせずに，単に「カジノ」や「収入」の文字列を追うだけでも，自動で分類ができる可能性がある．この例では，v_1 を「財政収入が増える」と読み替えれば，t と v_1 は含意の関係にある．もし t が「カジノを建設すれば年間一億五千万スイスフランの...」であれば，q の「カジノを建設（する）」が，t の仮定部分に含意されていると考えられる．一般的には，肯定する証拠（PE）の場合は，t が q と v_i を含意していることもあると予想される．ただしそれだけでは十分条件ではなく，t のうち q を含意している部分と，v_i を含意し

*1 ある商品を購入するケースであれば，色以外にも様々な観点を考慮するものと思われる．

*2 http://www.nichigai.co.jp/sales/mainichi/mainichi-data.html

ている部分で，因果関係等のなんらかの関係が成立していることが必要である．

[例 2]
q ： カジノを建設すべきか
v_1 ： 財政収入を増やす
t ： ただ先の「リスク」にも，カジノを解禁した米国のある州でカジノ収入 1 ドルあたり州政府が防犯対策などで 3 ドルのコストを負担したとの推計が紹介されている．

否定する証拠と人手で分類された例である．t の構造を簡潔に示すと下記のようになり，階層化された句構造を持っていることがわかる．

ただ先の「リスク」 にも，
　カジノ を
　解禁 した
米国のある州 で
カジノ収入 1 ドルあたり
州政府が防犯対策 などで
3 ドルのコスト を
負担 したとの
推計 が
紹介 されている．

t が階層化された句構造を持っているため，厳密に意味を追うには，階層構造を辿るやや複雑な処理が必要となる．「財政収入が増える」ことは，t の「カジノ収入 1 ドル」の部分に含意されているが，収入とコストを合計するとマイナスであると解釈される例である．ただ，「カジノ」「解禁」「コスト」「負担」などのキーワードが出現しているため，Bag-of-Words などで意味を理解せずに，ラベルを当てるだけなら正解できる可能性がある．この例からも分かるように，t と v_i の間に含意関係があっても，逆の証拠となる場合がある．

[例 3]
q ： クラブ活動を廃止すべきか
v_1 ： 健康的な生活を確保する
t ： 中学校の教員は「部活の過熱は過労死予備軍の育成」と訴えてきた．

肯定する証拠と人手で分類された例である．厳密に言えば，「部活動は過熱しやすい」という前提があれば，推論が成立する例と考えられる．データを作成する際には，どの程度，このような前提を許容するかを取り決める必要があると思われる．細かい点では，クラブ活動と部活動が，このコンテクストでは同一の意味を持つことを判定する必要がある．さらにクラブ活動とサークル活動は，似た意味を持つと解釈されるコンテクストもあるが，上記のコンテクストだとサークル活動では成立しないように思われる．一方で，「教員が訴えてきた」ということでもって，意思決定の証拠となるかどうかは，人によっても判断が分かれるところと考えられる．[Rinott 15] のように，一般的に人が証拠とみなすテキストの種類を分類し，どの種類まで証拠としてデータに含めるかを決める必要がある．

[例 4]
q ： クラブ活動を廃止すべきか
v_1 ： いじめをなくす
t ： 部活動は，いじめ問題に有効な方策になり得る．

否定する証拠と人手で分類された例である．ただし，t が事実ではなく一般論であるため，このような形式のテキストを証拠としてよいか，よく検討し，データセットを作成するときに定義しておく必要がある．

[例 5]
q ： クラブ活動を廃止すべきか
v_1 ： いじめをなくす
t ： 名門といわれる学校の運動部や地域の少年スポーツクラブの中では，しごきの名の下に日常的な暴力が正当化されている．

肯定する証拠と人手で分類された例である．同じ価値に対しても，肯定と否定の両方の証拠があることがわかる．従って矛盾のない公理系のようなもので推論するのは，難しいことがわかる．先の例と合わせて，実際の意思決定の際には，もう少し詳しい事例を知りたくなると思われる．ただし実用上は，t の出典元の t の前後に，具体的な例が書かれていると考えられるため，別の手法で，t の前後に具体例は事例が書かれているかどうかを判定し，その有無でフィルタリングする方法で対応できると考えられる．

[例 6]
q ： 貿易自由化を推進すべきか
v_1 ： 農林水産業・農山漁村の所得を向上させる
t ： フィリピン大学のサルバドル・カテロ教授は「貿易自由化による利益は，農民にまで届きにくい．

肯定しない証拠（N-PE）として人手で分類された例である．t は，否定もしていないことに注意が必要である．

5. おわりに

本稿では，証拠性推論問題を定式化し，問題を分析するための第一弾のデータセットを作成した．今後は，アノテーションの定義を厳密化し，より精密で大規模なデータセットを整備する．特に実用性を重視して，TEI がより高いデータセットを作成する．またアノテータアグリーメントを測定し，自然言語処理の問題としてどの程度成立しているかを明らかにすることが必要である．続いて，ディープラーニング等を用いて，証拠性推定問題を解くための手法を構築する．例えば，[柳瀬 16] で提案されているように，q と v_i と t を入力し，アテンション機構を使って，q と t のアライメントをとり，同様に v_i と t アライメントをとって，最終的な識別をする方法が考えられる．一方で，高精度のアルゴリズムの開発は困難と思われるため，精度が不十分でも有用性を発揮できるユースケースを探し，本問題の実用性を実証していく．

参考文献

[Kudo 02] Kudo, T. and Matsumoto, Y.: Japanese Dependency Analysis using Cascaded Chunking, in *Proceedings*

of CoNLL 2002 Post-Conference Workshops, pp. 63–69 (2002)

[Rinott 15] Rinott, R., Dankin, L., Perez, C. A., Khapra, M. M., Aharoni, E., and Slonim, N.: Show Me Your Evidence - an Automatic Method for Context Dependent Evidence Detection., in *EMNLP*, pp. 440–450 (2015)

[Sato 15] Sato, M., Yanai, K., Miyoshi, T., Yanase, T., Iwayama, M., Sun, Q., and Niwa, Y.: End-to-end Argument Generation System in Debating, in *Proceedings of ACL-IJCNLP 2015 System Demonstrations* (2015)

[佐藤 16] 佐藤 美沙, 柳井 孝介, 柳瀬 利彦, 三好 利昇, 是枝 祐太, 丹羽 芳樹：意見文章自動生成のための組合せ構文特徴を用いたサポート性推定, 人工知能学会論文誌, Vol. 31, No. 6 (2016)

[柳井 15] 柳井 孝介, 三好 利昇, 柳瀬 利彦, 佐藤 美沙, 丹羽 芳樹, Reisert, P., 乾 健太郎：ディベート人工知能における意見生成, 人工知能学会全国大会論文集, 第 29 巻, pp. 1–3 (2015)

[柳瀬 16] 柳瀬 利彦, 柳井 孝介, 佐藤 美沙, 三好 利昇, 丹羽 芳樹：Neural Attension Model を用いた観点付き評判分析, 人工知能学会全国大会論文集 (2016)

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

EP 特許公報を用いた英文同義語辞書の自動作成手法の提案

Automatically building English synonym dictionaries by using European Patent publications

丸崎　恒司[*1]　　津田　和彦[*1]
Koji Marusaki　　Kazuhiko Tsuda

[*1] 筑波大学大学院ビジネス科学研究科

Graduate School of Business Sciences, University of Tsukuba

Recently, conducting patent search becomes increasingly important, especially for foreign patent documents, in order to prepare for many overseas patent disputes and to avoid filing unnecessary patent applications. Therefore, we need to speed up patent research works. For doing so, building English synonym dictionaries is helpful as they can be used to find out suitable keywords during patent surveys and to raise the precision of automatic patent search system. However, developing synonym dictionaries is difficult since it requires a great deal of time and effort. Thus, in this study, we propose the method of automatically generating English synonym dictionaries from European patent documents by using reference signals in the claims and the specifications of them. Consequently, we could extract groups of English synonyms and it showed that the method was useful to create English synonym dictionaries.

1. はじめに

近年，企業の特許戦略が量から質へと変換しつつあること，企業間の特許係争が増加傾向であることを受け，不要な特許出願の抑制や，競合他社の保有する特許の無効化のため，特許調査の需要はますます増え続けている．中でも企業活動の国際化に伴い，外国特許調査の需要は高い．

これらの特許調査においては，漏れのない調査のために，調査対象となる発明に関連した用語のみならず，その同義語や上位概念あるいは下位概念の用語を検索語として調査することが一般的である．

また最近では，機械学習やテキストマイニングの手法により調査対象となる発明と類似する特許文書を自動的に抽出するツールも実用化されている．しかし，このようなツールの多くは，同義語は考慮されていない．その理由の一つに個々の検索対象技術分野に応じた同義語辞書を作成することの困難性がある．

特に特許文書では，「ベルト」に対して「無端伝動部材」など，通常の文書では用いられないような上位概念化した用語，一般化した用語が多く用いられている．

よって，これら特許文書に特有の上位概念化・抽象化した用語を網羅した同義語辞書を作成することができれば，特許調査における最適な検索語の抽出や，類似文書の自動抽出ツールにおける精度向上などに有益と考えられる．

そこで本研究では，欧州特許出願の European Patent publication, European Patent Specification（以下 EP 特許公報と記載する）から自動的に英文同義語辞書を構築する方法を提案する．

2. EP 特許公報を用いた同義語の抽出

2.1 EP 特許公報の特徴

Rule43(7) EPC には，「引用符号を含む図面を有する EP 特許出願では，クレームの理解の助けとなるときは，クレームに記載する技術的特徴には，それらの特徴に関する当該引用符号を括弧に入れて続けることが望ましい」と記載されている．

すなわち，請求項中に記載された技術的特徴が，図面中の各構成のいずれに対応するかを示すために，図面で使用されている番号を引用符号として請求項中の技術的特徴に対応する記載にも付与すべきことを，出願人に要求している[Höhfeld 2013].

通常，請求項に記載された発明は，図面を用いて明細書中でその詳細が説明されている．すなわち図面中の各構成を指し示す引用符号を用いて，特許公報中で当該発明が説明されている．

一方，上述の通り，欧州特許の実務においては明細書中のみならず，請求項に記載の技術的特徴についても当該引用符号が記載されていることが多い．

図1に，EP 特許公報 EP2453476A1 の例を示す．(a)の請求項中の a first contact area (12) は，その引用符号 12 から，(b)の明細書中の記載 a first contact portion 12 に対応することが分かる．

> wherein a raised portion of the leadframe adjacent to said recess defines a first contact area (12);

(a)請求項中の記載

> provided e.g. by stamping or etching with any suitable etch recipe to provide a leadframe 10 in which a first contact portion 12 is defined adjacent to the recess 14.

(b)明細書の記載

図 1　EP2453476A1 中の記載

通常，請求項では権利範囲を広く確保するために，発明の技術的特徴を上位概念で記載し，明細書中では当該技術的特徴の具体的な内容を下位概念で記載することが多い．つまり請求項中で，技術的特徴を表す上位概念の用語が，明細書中では請求項中の記載とは異なる下位概念の用語で記載されることがよく見られる．図 1 は，”area”という上位概念の用語に対して，”portion”という下位の用語が対応していると思われる．

連絡先:丸崎 恒司，筑波大学大学院 ビジネス科学研究科，
東京都文京区大塚 3-29-1，s1740127@u.tsukuba.ac.jp

2.2 引用符号を用いた照合モデル

上記の EP 特許公報の特徴を活かし, EP 特許公報の請求項中の発明の技術的特徴に対応する記載に付された引用符号と, 明細書中の当該技術的特徴を具体的に記載した部分に付された引用符号を対応付けることで, 上位概念化された用語と, より具体的な下位概念の用語とを対応させた同義語辞書を, 自動的に作成することが可能と思われる. さらには, 請求項内や明細書中で同一の引用符号が複数出現するものも多々あるため, これらも全て抽出して照合することで, 表記の揺れや俗称など様々な同義語が抽出できる可能性がある.

これまでも, 請求項中の発明の技術的特徴とそれに対応する明細書中の記載から上位概念, 下位概念の用語対を, 定型表現等を用いて抽出し, 同義語辞書やシソーラスを作成する手法は研究がなされてきた[難波 2007] [間宮 2011]. しかし, 請求項の記載箇所と, それに対応する明細書の記載箇所を自動的に特定することが困難であった.

そこで本研究では, EP 特許公報に特有の請求項中の引用符号と明細書中の引用符号を対応させることで, 請求項中の発明の技術的特徴に対応する明細書中の詳細説明部分を容易に対応させることができる点に着目し, 請求項中のフレーズと, それに対応する明細書中のフレーズを元に, 上位概念の用語と下位概念の用語, それらの表記の揺れや俗称などからなる用語対を作成し, それらを集めて同義語辞書を作成する方法を検討した.

3. 引用符号の抽出手法と評価

3.1 同一引用符号を持つフレーズの抽出

以下に, EP 特許公報, EP 2453476A1 を例に, 請求項と明細書から, 同一引用符号を持つフレーズを抽出する方法について, 説明する.

EP 特許公報は, ヨーロッパ特許庁(EPO)の提供する European Publication Server[data.epo]から pdf や xml の形式でダウンロードすることができる. 今回は同様に EPO の提供する European Patent Register[register.epo]の Advanced search を用いて, Keyword(s) in title で“semiconductor”かつ“packaging”をタイトルに含む 202 件(2017.10.14 確認)を選定し, そこから European Patent Publication を有し, 請求項中に引用符号を含む 10 件を検討対象とした. また当該 10 件については, Publication No.を European Publication Server に入力することで, xml 形式のファイルを取得した. 当該 xml ファイルはテキストデータとして読み込んだのち, それらをすべてトークン化した. 引用符号を持つフレーズは, その記載ルール従い, フレーズの後に引用符号が記載されている. それゆえ, 当該請求項中の丸括弧()で囲まれた数詞(引用符号), 及び明細書中の数詞(引用符号)を見出し, そこから前方に単語をたどればフレーズを抽出することができる. この際, 課題となるのは, 数詞から前方へ何単語目までがフレーズかという判断である. この判定は表1に示す抽出ルールに基づき, 行った. ただし丸括弧()で囲まれた対応する数詞(引用符号)を持たない数詞, すなわち明細書中にのみ記載されている引用符号を持つフレーズ, また英語以外の言語を含むフレーズはノイズとして対象外とした. また数詞であっても, Fig 1 や claim 1 などの数詞は引用符号とならないため, 数詞の直前に”Fig”(“Figs”)や”claim”(“claims”)を持つフレーズもノイズとして抽出対象外とした.

表1 フレーズの抽出ルール

	抽出終点	抽出起点
A	冠詞(a,the,said)	数詞
B	前置詞	数詞
C	and(数詞の直前の and は無視する)	数詞
D	接続詞	数詞
E	, () <>などの記号(ただし数詞直前の記号は除く)	数詞

請求項や明細書中の数詞(引用符号)から前方にどこまでを抽出すべきフレーズとするか, を定めたものが表1のルールである. 表1に従い, 実際の作業では請求項や明細書中の引用符号の位置から, 前方に, 例えば A のルールでは冠詞の直前までをフレーズとして抽出する.

図 1(a) (b)ではいずれも, 数詞(12)や 12 から前方に進むと冠詞が存在するので, 表1の A に従い, それぞれ first contact area, first contact portion が抽出されるべきフレーズとなる.

そのようにして得られたフレーズから, さらに表 2 に示す同義語抽出ルールを用いて, 同義語対を作成する. 表 1 のルールに基づき得られたフレーズは, 序数詞や分詞などの修飾語を含むため(先述の first contact area, first contact portion の例では, first), このままでは, 同義語辞書として活用することはできない. そこで, 抽出したフレーズにはさらに表 2 のルールを適用した.

表 2 同義語抽出ルール

フレーズから削除する項目
・序数詞・数詞 ・形容詞 ・分詞 ・副詞 ・接続詞 ・,や(などの記号

その結果, 先述の引用符号(12), 12 に対応するフレーズから, contact area, contact portion の2つの同義語からなる同義語対が抽出できた.

表 3 に EP2453476A1 から表 1, 表 2 のルールを適用して抽出した同義語対を示す.

表 3 EP2453476A1 から得られた同義語対

得られた同義語対
leadframe portion, leadframe
semiconductor device package, semiconductor device packages, package
contact area, contact portion, contact portions, contact surface, surfaces
recess, recesses
semiconductor device, dies
contact, contacts, carrier contact
surface, contact surface, contact surfaces, contact area, surfaces
layer, resin
layers, layer

表 3 から, 今回提案した手法を用いることで, layer と resin のように, “層”の材質を特定した, すなわち下位概念化した“樹脂”が抽出されていることが確認できた. よって layer と resin については, 上位概念と下位概念の同義語対が抽出できていると考えられる.

また例えば contact area と, contact surface のような, 上位・下位の関係とは言い難く, 言い換え表現となっている同義語対も得られていることが確認できた.

3.2 抽出ルールの正答率

表 4 に本手法を用いて抽出した 2354 フレーズの正答率を示す. ルール E までを用いることで, 最終的に 90%を超える正答率が実現され, 当該手法による同義語辞書作成の可能性が示された.

表 4 各抽出ルール適用時の正答率

	A	+B	+C	+D	+E
正答数	1506	1838	1889	1999	2126
抽出数	2354	2354	2354	2354	2354
正答率	0.640	0.781	0.802	0.849	0.903

また実際に得られた同義語対の結果から, 例えば表 3 に示す semiconductor device, dies の他に die, electronic device が得られることが確認できた. それぞれ semiconductor device, electronic device が dies, die の上位概念になっている. 以上から, dies と die という複数, 単数の相違はあるものの, dies, die を共通の用語とみなし, semiconductor device, dies と die, electronic device を1つの同義語対とみなすことで, dies(die)の上位概念として semiconductor device, electronic device の2つを対応させ得ることが確認できた. このように共通用語を介して2つの同義語対を結合することで, 本手法で得られる同義語辞書をシソーラスに発展させられる可能性があることが示された.

4. おわりに

本研究では, EP 特許公報の請求項及び明細書の記載に対して共通に付されている引用符号を用いることで, 英文同義語辞書を自動作成する手法について, 提案した.

今回, 提示した抽出ルールによって, 一定の正答率での同義語対を抽出可能なことが分かった. これによって本手法により自動的に英文同義語辞書を作成する可能性が示された.

今後は, 当該同義語辞書を用いて, 意味的な階層構造を持つシソーラスの作成が可能か, またこれらを実際の特許調査に応用して, 類似文書抽出精度を上げることが可能か検証していく.

参考文献

[register.epo] https://register.epo.org/advancedSearch?lng=en, accessed:2017-10-14

[data.epo] https://data.epo.org/publication-server/?lg=en, accessed:2017-10-14

[Höhfeld 2013] Jochen Höhfeld, 田中 紫乃: 欧州特許出願においてすべきこと,すべきでないこと, パテント, 2013.

[難波 2007] 難波英嗣 , 奥村学 , 新森昭宏 , 谷川英和 , 鈴木泰山: 特許データベースからのシソーラスの自動構築, 言語処理学会第 13 回年次大会, 2007.

[間宮 2011] 間弓沙織, 難波英嗣, 竹澤寿幸: 日英特許データベースからのシソーラスの自動構築論文, 言語処理学会 第17 回年次大会 発表論文集, 2011.

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

音声認識誤りに頑健なニューラル発話意図推定のための コンフュージョンネットワークの連続表現

Continuous Representation of Confusion Networks for Neural Spoken Utterance Classification robust to Automatic Speech Recognition Errors

増村 亮 *1　井島 勇祐　浅見 太一　政瀧 浩和　東中 竜一郎
Ryo Masumura　Yusuke Ijima　Taichi Asami　Hirokazu Masataki　Ryuichiro Higashinaka

*1日本電信電話株式会社 NTT メディアインテリジェンス研究所
NTT Media Intelligence Laboratories, NTT Corporation

In this paper, we present a novel fully neural network based spoken utterance classification method that utilizes word confusion networks. Spoken utterance classification modules are essential for spoken dialogue systems. Main issue is that performance on the spoken utterance classification is degraded by automatic speech recognition errors. Our solution is to leverage the confusion networks, which are compact and efficient representations of automatic speech recognition hypotheses, in neural network based modeling. Key idea is to convert the confusion networks into a continuous representation which is compatible with the neural network based modeling. This paper examines two types of continuous representation; a weighted sum representation and a modified weighted sum representation. Our experiments show effectiveness of the proposed method in three spoken utterance classification tasks.

1. はじめに

音声対話システムにおいて，発話意図推定はユーザの入力発話に対して意図ラベルを推定するために用いられる技術であり，円滑な音声対話を行うために不可欠である．発話意図推定は，主に 2 つの観点でさらなる高度化が求められている．1 つは言葉を深く理解するための精緻なモデル化，そしてもう 1 つは音声認識誤りに対して頑健なモデル化である．

言葉を精緻に理解するための手段として，近年深層学習技術が注目されている．特に，特徴抽出を含めてニューラルネットワークでモデル化を行うニューラル発話意図推定では，人手による素性エンジニアリングなしでも強力な性能を示すことが報告されている．高度化のために，ニューラルネットワークのモデル構造についての工夫が検討されており，長短期記憶を用いた再帰型ニューラルネットワーク (LSTM-RNN) [Ravuri 16]，畳み込みニューラルネットワーク [Kim 14]，注意機構等の工夫を加えたネットワーク [Yang 16] など，様々に検討されている．

一方，音声認識誤りに対する頑健性を向上させる手法についても，発話意図推定を含む音声言語理解分野において，これまで様々な検討がなされている．音声認識誤りを含まないデータから発話意図推定のモデルを学習しておく場合，音声認識誤りを含む発話に対して高い性能が得られないことが知られている．そのため，音声認識結果を用いて発話意図推定のモデルを学習することが一般的である．さらに，n-best リスト [He 03, Morbini 12, Khan 15]，ラティス [Saraclar 04, Saleem 04]，コンフュージョンネットワーク [Hakkani-Tur 06, Henderson 12, Yang 15] などの音声認識時の複数仮説を利用して特徴抽出を行うことで，音声認識誤りに頑健となることが報告されている．

しかしながら，ニューラル発話意図推定の枠組みで音声認識誤りに対する頑健性を高めるための検討は，これまでほとんどなされていない．近年，ニューラル発話意図推定においてラティスの利用が試みられているが，ラティスは複雑なグラフ構造を持つため，ラティスに特化したニューラルネットワークが必要となる [Svec 16, Ladhak 16]．すなわち，ラティスを用いる場合は，単語系列を扱うために検討されてきたニューラルネットワークのモデル構造を直接利用することができないことが課題である．

この課題を解決するための我々のアプローチは，コンフュージョンネットワークをニューラル発話意図推定の枠組みで利用することである．コンフュージョンネットワークは，音声認識時の複数仮説を表すための効率的なグラフ構造である．このグラフ構造において注目すべき特徴は，ノードが単一の系列として表される点である．本研究ではこの特徴に着眼し，重み付きアーク集合として表されるコンフュージョンネットワークの各ノード間の情報を，連続表現に変換するニューラルネットワーク構造を導入する．これにより，単語の連続表現系列が入力となっていたモデル構造に，直接コンフュージョンネットワークを接続して最適化することが可能となる．

本稿では，コンフュージョンネットワークを連続表現に変換するために，2 種類の方法を提案する．1 つは，重み付きアーク集合の各単語について，音声認識時の信頼度を考慮して連続表現に変換する方法である．この方法により，音声認識時の仮説情報を積極的に利用することが可能となる．そしてもう 1 つは 1 つ目の方法を改良したものであり，注意機構 [Zhou 16, Yang 16] を用いることで，各単語の音声認識時の信頼度とタスクにおける重要性の両者を考慮した連続表現を構成する方法である．

本稿では，コンフュージョンネットワークを用いたニューラル発話意図推定について詳細を述べる．評価実験では，対話行為，拡張固有表現，質問種別の 3 つ発話意図推定タスクについて，提案手法が音声認識誤りに頑健に動作することを示す．

2. ニューラル発話意図推定

発話意図推定は，入力発話の単語系列 $\mathcal{W} = \{w_1, \cdots, w_T\}$ から発話意図を表すラベル $l \in \{l_1, \cdots, l_K\}$ を決定する問題である．ニューラル発話意図推定では，入力発話 $\mathcal{W}$ が与えられた場合のラベル l に対する条件付き確率 $P(l|\mathcal{W}, \mathbf{\Theta})$ をニューラルネットワークを用いてモデル化する．なお，$\mathbf{\Theta}$ はモデル

連絡先: 増村 亮，日本電信電話株式会社 NTT メディアインテリジェンス研究所，神奈川県横須賀市光の丘 1-1，046-859-3921，ryou.masumura.ba@hco.ntt.co.jp

パラメータを表す．

ニューラル発話意図推定は，音声認識結果の複数仮説である n-best リストを用いる場合にも利用できる [Ladhak 16]．n-best リスト $\mathcal{L}$ が与えられた場合のラベル l に対する条件付き確率を (1) 式に従いモデル化する．

$$P(l|\mathcal{L}) = \sum_{\mathcal{W}\in\mathcal{L}} P(l|\mathcal{W}, \boldsymbol{\Theta})P(\mathcal{W}) \tag{1}$$

ここで，$P(\mathcal{W})$ はある仮説 $\mathcal{W}$ の事後確率であり，音声認識における信頼度を表す．

2.1 モデル化

ニューラル発話意図推定では，様々なニューラルネットワークのモデル構造が利用できる．本稿では，LSTM-RNN によるモデリングと，注意機構付きの双方向 LSTM-RNN (BLSTM-RNN) によるモデリングの 2 つのモデル構造を検討する [Zhou 16, Yang 16]．

両者のモデルにおいて，入力発話 $\mathcal{W}$ の各単語は，連続表現に変換して利用される．t 番目の単語の連続表現 $\boldsymbol{w}_t$ は (2) 式で定義される．

$$\boldsymbol{w}_t = \texttt{EMBED}(w_t; \boldsymbol{\theta}_\text{w}) \tag{2}$$

ここで，EMBED() は単語を連続表現に埋め込むための線形変換関数であり，$\boldsymbol{\theta}_\text{w}$ はモデルパラメータを表す．

2.1.1 LSTM-RNN によるモデル化

LSTM-RNN によるニューラル発話意図推定について詳細を述べる．このモデル化では，LSTM-RNN を用いることで，各単語の連続表現をコンテキストに依存した隠れ表現に変換する．t 番目の単語に対応する隠れ表現は (3) 式に従い計算できる．

$$\boldsymbol{h}_t = \texttt{LSTM}(\boldsymbol{w}_1, \cdots, \boldsymbol{w}_t; \boldsymbol{\theta}_\text{h}) \tag{3}$$

ここで LSTM() は，LSTM-RNN の機能を持つ関数であり，$\boldsymbol{\theta}_\text{h}$ はそのモデルパラメータを表す．この場合，$\boldsymbol{h}_T$ は発話全体が埋め込まれていることに相当する．出力層では，ラベルの予測確率分布を (4) 式に従い生成する．

$$\boldsymbol{o} = \texttt{SOFTMAX}(\boldsymbol{h}_T; \boldsymbol{\theta}_\text{o}) \tag{4}$$

ここで，SOFTMAX() はソフトマックス関数を表し，$\boldsymbol{\theta}_\text{o}$ はそのモデルパラメータを表す．$\boldsymbol{o}$ の k 番目の次元は，$P(l_k|\mathcal{W}, \boldsymbol{\Theta})$ に対応する．モデル全体をまとめると，$\boldsymbol{\Theta}$ は $\{\boldsymbol{\theta}_\text{w}, \boldsymbol{\theta}_\text{h}, \boldsymbol{\theta}_\text{o}\}$ に対応する．

2.1.2 注意機構付き BLSTM-RNN によるモデル化

注意機構付き BLSTM-RNN によるニューラル発話意図推定について詳細を述べる．このモデル化では，BLSTM-RNN を用いることで，各単語の連続表現を前後のコンテキストに依存した隠れ表現に変換する．t 番目の単語に対応する隠れ表現は (5) 式に従い計算できる

$$\boldsymbol{h}_t = \texttt{BLSTM}(\boldsymbol{w}_1, \cdots, \boldsymbol{w}_T, t; \boldsymbol{\theta}_\text{h}) \tag{5}$$

ここで，BLSTM() は BLSTM-RNN の機能を持つ関数であり，$\boldsymbol{\theta}_\text{h}$ はそのモデルパラメータを表す．次に，各隠れ表現は注意機構により発話全体を表す連続表現にまとめ上げる．注意機構は，各隠れ表現の重要性を考慮することができ，発話全体の連続表現 $\boldsymbol{s}$ は (6)-(7) 式に従い計算できる．

$$\boldsymbol{z}_t = \tanh(\boldsymbol{h}_t; \boldsymbol{\theta}_\text{z}) \tag{6}$$

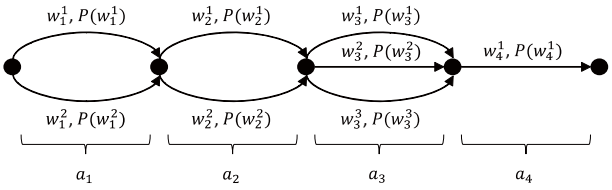


図 1: コンフュージョンネットワークのグラフ構造．

$$\boldsymbol{s} = \sum_{t=1}^{T} \frac{\exp(\boldsymbol{z}_t^\top \bar{\boldsymbol{z}})}{\sum_{j=1}^{T} \exp(\boldsymbol{z}_j^\top \bar{\boldsymbol{z}})} \boldsymbol{h}_t \tag{7}$$

ここで，tanh() は双曲線正接関数によるアクティベーションを含む非線形変換関数を表し，$\boldsymbol{\theta}_\text{z}$ はそのパラメータを表す．$\bar{\boldsymbol{z}}$ は学習可能なコンテキストベクトルであり，隠れ表現の重要性を測るために用いられる．出力層では，ラベルの予測確率分布を (8) 式に従い生成する．

$$\boldsymbol{o} = \texttt{SOFTMAX}(\boldsymbol{s}; \boldsymbol{\theta}_\text{o}) \tag{8}$$

モデル全体をまとめると，$\boldsymbol{\Theta}$ は $\{\boldsymbol{\theta}_\text{w}, \boldsymbol{\theta}_\text{h}, \boldsymbol{\theta}_\text{z}, \bar{\boldsymbol{z}}, \boldsymbol{\theta}_\text{o}\}$ に対応する．

2.2 最適化

モデルパラメータは，正解の確率分布と予測確率分布の交差エントロピーを最小化するように，次式に従い最適化できる．

$$\hat{\boldsymbol{\Theta}} = \underset{\boldsymbol{\Theta}}{\text{argmin}} - \sum_{\mathcal{W}\in\mathcal{D}} \sum_{k=1}^{K} \hat{\boldsymbol{o}}_{\mathcal{W}}^{l_k} \log \boldsymbol{o}_{\mathcal{W}}^{l_k} \tag{9}$$

ここで，$\hat{\boldsymbol{o}}_{\mathcal{W}}^{l_k}$ と $\boldsymbol{o}_{\mathcal{W}}^{l_k}$ は，入力発話 $\mathcal{W}$ のラベル l_k に対する正解の確率と予測確率を表す．なお，$\mathcal{D}$ は学習データセットを表す．

3. コンフュージョンネットワークを用いたニューラル発話意図推定

3.1 コンフュージョンネットワーク

コンフュージョンネットワークは，音声認識時の複数仮説の表現方法の 1 つであり，ノードが単一の系列となるグラフ構造として表される [Hakkani-Tur 06]．コンフュージョンネットワークのグラフ構造を図 1 に示す．黒丸がグラフにおけるノードであり，コンフュージョンネットワークではノードが単一の系列として表される．したがって，コンフュージョンネットワーク $\mathcal{A}$ は，重み付きアーク集合の系列 $\{a_1, \cdots, a_T\}$ として表される．t 番目の重み付きアーク集合は (10) 式で表される．

$$a_t = \{(w_t^1, P(w_t^1)) \cdots, (w_t^{I_t}, P(w_t^{I_t}))\} \tag{10}$$

ここで，I_t は t 番目の重み付きアーク集合に含まれる単語数を表し，w_t^i はそこに含まれる i 番目の単語，$P(w_t^i)$ は w_t^i の事後確率を表す．なお，空文字を表す null も，重み付きアーク集合において単語の 1 種として扱われることに注意されたい．

3.2 モデル化

コンフュージョンネットワークを用いたニューラル発話意図推定では，$P(l|\mathcal{A}, \boldsymbol{\Theta})$ を直接モデル化する．そのために我々は，コンフュージョンネットワークの連続表現を導入する．

ここでは，重み付きアーク集合 a_t の連続表現を $\boldsymbol{a}_t$ と表すこととする．この場合，コンフュージョンネットワークを用い

たニューラル発話意図推定は，前述の LSTM-RNN や注意機構付き BLSTM-RNN におけるモデル構造に重み付きアーク集合の連続表現を結合することにより構成することができる．つまり，(3) 式や (5) 式における $\boldsymbol{w}_t$ を $\boldsymbol{a}_t$ に入れ替えることで，コンフュージョンネットワークを用いたニューラル発話意図推定を導出できる．本稿では，コンフュージョンネットワークの連続表現として，重み付き和表現と修正重み付き和表現の 2 種類を検討する．

3.2.1 重み付き和表現

重み付き和表現は，重み付きアーク集合内の各単語を連続表現に変換し，事後確率を用いて重み付き和をとることで構成される．a_t の重み付き和表現は (11) 式で計算できる．

$$\boldsymbol{a}_t = \sum_{i=1}^{I_t} P(w_t^i)\texttt{EMBED}(w_t^i; \boldsymbol{\theta}_{\texttt{w}}) \tag{11}$$

ここで，EMBED() は式 (2) で用いる関数と同じ機能を持つ．この方法により，音声認識時の信頼度を考慮した上で重み付きアーク集合全体を 1 つの連続表現に埋め込むことができる．

3.2.2 注意機構を用いた修正重み付き和表現

コンフュージョンネットワークにおける事後確率は，音声認識時の信頼度を表す一方で，識別タスクを解くにあたって重要かどうかの指標は含まれていない．そこで，我々は注意機構を用いることで重み付き和表現を修正する．a_t の修正重み付き和表現は (12)-(14) 式で計算できる．

$$\boldsymbol{q}_t^i = P(w_t^i)\texttt{EMBED}(w_t^i; \boldsymbol{\theta}_{\texttt{w}}) \tag{12}$$

$$\boldsymbol{v}_t^i = \texttt{tanh}(\boldsymbol{q}_t^i; \boldsymbol{\theta}_{\texttt{v}}) \tag{13}$$

$$\boldsymbol{a}_t = \sum_{i=1}^{I_t} \frac{\exp(\boldsymbol{v}_t^{i\top}\bar{\boldsymbol{v}})}{\Sigma_{j=1}^{I_m}\exp(\boldsymbol{v}_t^{i\top}\bar{\boldsymbol{v}})}\boldsymbol{q}_t^i \tag{14}$$

ここで，$\boldsymbol{\theta}_{\texttt{v}}$，$\bar{\boldsymbol{v}}$ は注意機構を行う際のモデルパラメータである．このようなモデル化により，各単語の音声認識時の信頼度とタスクにおける重要性の両者を考慮した連続表現を構成することが可能となる．例えば，注意機構付き BLSTM-RNN と修正重み付き和表現を組み合わせたモデル構造の場合，$\boldsymbol{\Theta}$ は $\{\boldsymbol{\theta}_{\texttt{w}}, \boldsymbol{\theta}_{\texttt{v}}, \bar{\boldsymbol{v}}, \boldsymbol{\theta}_{\texttt{h}}, \boldsymbol{\theta}_{\texttt{z}}, \bar{\boldsymbol{z}}, \boldsymbol{\theta}_{\texttt{o}}\}$ に対応する．

3.3 最適化

コンフュージョンネットワークを用いたニューラル発話意図推定におけるモデルパラメータの最適化は，単語系列が入力であった場合と同様に，(15) 式の通り正解の確率分布と予測確率分布の交差エントロピーを最小化に従う．

$$\hat{\boldsymbol{\Theta}} = \underset{\boldsymbol{\Theta}}{\text{argmin}} - \sum_{\mathcal{A}\in\mathcal{D}}\sum_{l}\hat{\boldsymbol{o}}_{\mathcal{A}}^{l}\log\boldsymbol{o}_{\mathcal{A}}^{l} \tag{15}$$

ここで，$\hat{\boldsymbol{o}}_{\mathcal{A}}^{l}$ と $\boldsymbol{o}_{\mathcal{A}}^{l}$ は，コンフュージョンネットワーク $\mathcal{A}$ のラベル l に対する正解の確率と予測確率を表す．なお，$\mathcal{D}$ は学習データセットを表す．

4. 評価実験

4.1 実験条件

本稿では，3 種類の異なる発話意図推定タスクで提案手法の評価を行う．3 種類のタスクは，対話行為推定 (DA)，拡張固有表現推定 (ENE) [Higashinaka 12]，および質問種別推定 (QT) であり，言語は英語である．例えば拡張固有表現推定は，入力発話で問われていることの固有表現ラベルを推定するタスクであり，「What is the highest mountain in the world?」という入力発話に対して，「Mountain」といった固有表現ラベルを推定する．我々は，各タスクのデータセットを，それぞれ学習データ，開発データ，評価データに分割して用いた．なおラベリングは，音声認識誤りを含まない正解の書き起こしテキスト (正解文) に対して，人出で行った．様々な音声認識条件での性能を調査するために，本稿では，正解文から音声合成を用いて音声データを生成し，音声認識誤りを引き起こすためにノイズを重畳した．N-best やコンフュージョンネットワークなどの音声認識時の複数仮説は，50 万語彙の音声認識器を用いて生成した．表 1 に，各データセットの詳細と，各条件下での単語誤り率 (Word Error Rate; WER) を示す．学習時，評価時ともに，音声認識誤りを含まない正解文を用いる場合を条件 1 とし，2 つの音声認識条件について，それぞれ条件 2，条件 3 とした．なお，各タスクでデータ量が同一であるが，それぞれ異なるデータセットであることに注意されたい．

表 1: 実験に用いるデータの詳細．

	対話行為 (DA)	拡張固有表現 (ENE)	質問種別 (QT)
学習データの発話数	26,220	26,220	26,220
開発データの発話数	2,622	2,622	2,622
評価データの発話数	2,623	2,623	2,623
条件 1 の WER (%)	0.0	0.0	0.0
条件 2 の WER (%)	11.8	14.2	14.0
条件 3 の WER (%)	22.9	28.9	28.1
ラベル数	28	168	17
ラベル例	Greeting Apology Thanks	Age Company Country	True/false Quantity Name

評価のために，モデル化としては，2 節で説明した LSTM-RNN と注意機構付き BLSTM-RNN の 2 種類のモデル構造を用いた．両者のモデル構造において，単語の連続表現の次元数は 128，LSTM-RNN のユニットサイズは 200 と統一した．なお，EMBED()，LSTM()，BLSTM() において，0.5 の割合でドロップアウトを行った．N-best を用いた実験を行う場合は，学習時は正解文か 1-best を使用し，評価時に 1-best，10-best，50-best を用いた実験を行った．なお，10-best や 50-best を使った評価を行う場合は，(1) 式にしたがって識別を行った．コンフュージョンネットワークを用いる場合は，重み付き和表現，修正重み付き和表現によるモデル化をそれぞれ行った．また，各条件において，学習データ中に 1 回しか出現しない単語を未知語と扱うこととした．最適化には，Adam をデフォルトの設定で用い，開発データに対するロスが 5 回連続で改善しない場合にアーリーストッピングを行った．

4.2 結果

表 2 に各タスクのテストセットに関する発話意図推定の正解率の結果を示す．表 2 において，コンフュージョンネットワークは CN と示す．なお，各セットアップにおいて，ランダムに初期値を変化させて 5 つのモデルを作成し，その平均正解率を評価した．

まず，学習時評価時ともに音声認識誤りがない条件である (a) において，ほとんどの条件の中で最も高い性能を示した．このことから，音声認識誤りが無い条件下が理想的であることが確認できた．なお，モデル構造に関しては，LSTM-RNN，注意機構付き BLSTM-RNN で大きな差はなかった．一方，条件 2 の (b)，および条件 3 の (g) において，音声認識誤りがな

表 2: 各タスクのテストセットに関する発話意図推定の正解率 (%).

	条件	学習時のデータ種別	評価時のデータ種別	CN の連続表現	LSTM-RNN DA	LSTM-RNN ENE	LSTM-RNN QT	注意機構付き BLSTM-RNN DA	注意機構付き BLSTM-RNN ENE	注意機構付き BLSTM-RNN QT
(a).	条件 1	正解文	正解文	-	63.7	65.7	82.9	63.5	65.5	82.8
(b).	条件 2	正解文	1-best	-	58.8	57.0	79.1	57.8	57.2	79.5
(c).		1-best	1-best	-	61.6	60.6	82.5	61.9	60.5	82.2
(d).		1-best	10-best	-	62.0	62.0	82.7	62.2	61.7	82.3
(e).		1-best	50-best	-	61.8	62.3	82.7	61.8	62.3	82.4
(f).		CN	CN	重み付き和表現	62.7	62.7	82.7	62.9	63.0	82.7
(g).		CN	CN	修正重み付き和表現	**63.4**	**64.0**	**82.8**	**63.6**	**65.0**	**83.0**
(j).	条件 3	正解文	1-best	-	53.2	41.8	69.1	52.0	42.0	69.3
(i).		1-best	1-best	-	58.8	49.6	79.0	58.4	50.1	78.8
(j).		1-best	10-best	-	59.6	52.7	79.5	59.2	53.4	78.8
(k).		1-best	50-best	-	59.8	53.2	79.6	59.3	54.2	79.0
(l).		CN	CN	重み付き和表現	60.2	55.0	79.7	60.7	55.5	80.2
(m).		CN	CN	修正重み付き和表現	**61.2**	**57.0**	**80.1**	**61.5**	**58.2**	**80.7**

い発話からモデルを学習しておき，音声認識誤りを含む入力である 1-best で評価を行った場合，(a) と比較して大幅な性能劣化が確認できる．特に，音声認識誤りが多い条件下である (g) では，(a) と比較して大幅な性能劣化が確認できる．このことから，学習時と評価時の音声認識率のミスマッチが，発話意図推定に悪影響を及ぼすことが示された．

次に，(c) や (j) のように音声認識結果の 1-best を用いてモデルを学習しておくことにより，(b) や (g) と比較して，高い性能が得られていることが確認できる．さらに，評価時に 10-best や 50-best まで考慮することにより，1-best のみを用いる場合よりも高い性能が得られ，複数仮説を考慮することが有効であることが示された．10-best を用いる場合と 50-best を用いる場合を比較すると，両者の性能は同等であり，これ以上の仮説候補も用いても改善効果はほとんどないことが推測される．

提案手法のコンフュージョンネットワークを用いる方法 (f)，(g)，(m)，(l) は，重み付き和表現，修正重み付き和表現ともに，n-best を用いる (e) や (k) よりも高い性能実現していることが確認できる．条件 2，条件 3 において，最高性能は修正重み付き和表現を用いてコンフュージョンネットワークを連続表現にする場合に得られ，重み付きアーク集合における各アークの重要性を考慮することが有効であることが示された．特に，条件 2 においては，提案手法により，理想条件である条件 1 と同等の性能を達成した．なお，提案手法は，LSTM-RNN よりも注意機構付き BLSTM-RNN の方が全体的に高い性能を示した．これは，注意機構や双方向のネットワークにより，下層であるコンフュージョンネットワークの連続表現の変換関数にまで勾配が伝搬し，モデル全体がうまく学習できたことに起因すると考えられる．

5. まとめ

本稿では，音声認識誤りに頑健な発話意図推定を目指して，音声認識時の複数仮説表現であるコンフュージョンネットワークを直接ニューラルネットワークの枠組みで扱うことが可能なモデル化手法を提案した．提案手法のポイントは，コンフュージョンネットワークを連続表現に変換することであり，注意機構を利用した修正重み付き和表現を用いることで，仮説内の単語の重要性と音声認識時の信頼度を両者を考慮できる枠組みを実現した．実験から，提案手法は n-best を用いる方法よりも音声認識誤りに頑健に動作することを確認した．

参考文献

[Hakkani-Tur 06] Hakkani-Tur, D., Bechet, F., Riccardi, G., and Tur, G.: Beyond ASR 1-best: Using word confusion networks in spoken language understanding, *Computer Speech and Language*, Vol. 20, pp. 495–514 (2006)

[He 03] He, Y. and Young, S.: A data-driven spoken language understanding system, *In Proc. ASRU*, pp. 583–588 (2003)

[Henderson 12] Henderson, M., Gasic, M., Thomson, B., Tsiakoulis, P., Yu, K., and Young, S.: Discriminative Spoken Language Understanding using Word Confusion Networks, *In Proc. SLT*, pp. 176–181 (2012)

[Higashinaka 12] Higashinaka, R., Sadamitsu, K., Saito, K., Makino, T., and Matsuo, Y.: Creating an Extended Named Entity Dictionary from Wikipedia, *In Proc. COLING*, pp. 1163–1178 (2012)

[Khan 15] Khan, O. Z., Robichaud, J.-P., Crook, P., and Sarikaya, R.: Hypotheses Ranking and State Tracking for a Multi-Domain Dialog System using Multiple ASR Alternates, *In Proc. INTERSPEECH*, pp. 2022–2026 (2015)

[Kim 14] Kim, Y.: Convolutional Neural Networks for Sentence Classification, *In Proc. EMNLP*, pp. 1746–1751 (2014)

[Ladhak 16] Ladhak, F., Gandhe, A., Dreyer, M., Mathias, L., Rastrow, A., and Hoffmeister, B.: LATTICERNN: Recurrent Neural Networks over Lattices, *In Proc. INTERSPEECH*, pp. 695–699 (2016)

[Morbini 12] Morbini, F., Audhkhasi, K., Artstein, R., Segbroeck, M. V., Sagae, K., Georgiou, P., Traum, D. R., and Narayanan, S.: A Reranking Approach for Recognition and Classification of Speech Input in Conversational Dialogue Systems, *In Proc. SLT*, pp. 49–54 (2012)

[Ravuri 16] Ravuri, S. and Stolcke, A.: A comparative study of recurrent neural network models for lexical domain classification, *In Proc. ICASSP*, pp. 6075–6079 (2016)

[Saleem 04] Saleem, S., Jou, S.-C., Vogel, S., and Schultz, T.: Using Word Lattice Information for a Tighter Coupling in Speech Translation Systems, *In Proc. ICSLP*, pp. 41–44 (2004)

[Saraclar 04] Saraclar, M.: Lattice-based search for spoken utterance retrieval, *In Proc. NAACL-HLT*, pp. 129–136 (2004)

[Svec 16] Svec, J., Chylek, A., Smidl, L., and Ircing, P.: A Study of Different Weighting Schemes for Spoken Language Understanding based on Convolutional Neural Networks, *In Proc. ICASSP*, pp. 6065–6069 (2016)

[Yang 15] Yang, X. and Liu, J.: Using Word Confusion Networks for Slot Filling in Spoken Language Understanding, *In Proc. INTERSPEECH*, pp. 1353–1357 (2015)

[Yang 16] Yang, Z., Yang, D., Dyer, C., He, X., Smola, A. J., and Hovy, E. H.: Hierarchical Attention Networks for Document Classification, *In Proc. NAACL-HLT*, pp. 1480–1489 (2016)

[Zhou 16] Zhou, P., Shi, W., Tian, J., Qi, Z., Li, B., Hao, H., and Xu, B.: Attention-Based Bidirectional Long Short-Term Memory Networks for Relation Classification, *In Proc. ACL*, pp. 207–212 (2016)

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

単語分散表現による語義の近似を用いた語彙平易化手法

Lexical Simplification Using Word Embedding to Approximate Word Sense

高田祥平 *1　荒瀬由紀 *1　内田諭 *2
Shohei Takada　Yuki Arase　Satoru Uchida

*1大阪大学大学院情報科学研究科
Graduate School of Information Science and Technology, Osaka University

*2九州大学大学院言語文化研究院
Faculty of Languages and Cultures, Kyushu University

Authentic English passages are not always appropriate for learners due to their vocabulary level; hence teachers sometimes have to modify the text by making sentences simpler or replacing difficult words with easier ones. This process, however, takes time and could be a burden for teachers. The present study aims to build an automatic lexical simplification system that can assist teachers in preparing materials for classes and examinations. The proposed system first selects target words based on CEFR levels and then lists candidates from a thesaurus. Then, the paraphrasablity of each candidate is examined using a word embedding method. The results show that the proposed method can provide correct candidates for more cases than the baseline and existing methods and is robust even when the target is a polysemous word.

1. はじめに

英語の教育現場では，教育者は学習者の英語の習熟度に合わせて教材として用いる英文の難易度の調整を行う．例えば，学習者の理解の妨げになる難しい語について，平易な語への言い換えや注釈をつけるなどの処理が必要となる．これは教育者自身の経験に基づいて行われ，多くの時間と労力を要する作業であるため負担が大きい．そこで本研究では，英語教育者の教材作成支援を目的とし，入力された英文中の難単語を自動で抽出し，言い換え可能で平易な語を提示する手法を提案する．英語習熟度の高い教育者は，提示された候補語から言い換えに適切な候補を選定できると期待できる．一方で，不要に多くの候補を提示することは，返って教育者の負担となってしまう．そこで本研究では，多くの難単語に対してできるだけ精度の高い候補語のリストを出力するシステムの実現を目指す．

本研究では語彙平易化を以下の 3 つのステップで実現する．まず，言い換え対象となる難しい単語 (TARGET と呼ぶ) を特定する．次に，TARGET の言い換え先候補となる平易な語 (CANDIDATE と呼ぶ) を選定する．最後に，入力文の文脈に応じた CANDIDATE を判定して出力する．TARGET と言い換え可能な CANDIDATE は，TARGET が表れる文脈において，TARGET と同一の意味を表現し，かつ文法的にも整合性を保たなければならない．そこで，この条件を満たす CANDIDATE を判定するための指標として，本研究では語義とコロケーションを用い，教育支援に適した言い換え手法を提案する．提案手法では世界的な言語能力の評価指標である Common European Framework of Reference for Language (CEFR) [Alderson 07] に準拠した難易度辞書を使用して TARGET を特定する．次に，類義語辞書から難易度辞書を用いて CANDIDATE の選定を行う．最後に，コロケーションの評価指標を用いて有意に共起する語を特定し，単語ベクトルの学習を行う．これにより TARGET を言い換え可能な CANDIDATE を機械学習により判別する．

連絡先: 荒瀬由紀，大阪大学大学院情報科学研究科，〒 565-0871
大阪府吹田市山田丘 1 － 5，arase@ist.osaka-u.ac.jp

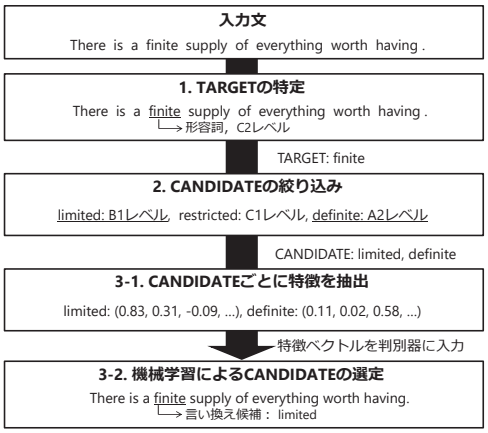


図 1: 手法の概要図

言い換え精度の評価実験の結果，既存の単語ベクトルを用いるベースラインや品詞情報を付与した単語ベクトルを用いる既存手法と比較して，提案手法はより多くの TARGET に対して正解 CANDIDATE の提示が可能であり，教育支援として望ましい性質を持つことが明らかとなった．

2. 提案手法

提案する語彙平易化手法の概要を図 1 に示す．提案手法では，まず入力文から難易度の高い語を特定し，TARGET とする．次に，類義語辞書から TARGET の類義語を取得し，平易なものを CANDIDATE とする．得られた CANDIDATE と入力文から各種特徴量を抽出し，機械学習により言い換えが可能と判定した CANDIDATE のリストを出力する．各手順における処理について，詳細を以下に記述する．

2.1 TARGET の特定

Leroy ら [Leroy 13] は大規模コーパスにおける単語の出現頻度を難易度の指標として TARGET を特定している．一般的に，難易度の高い語は出現頻度が低く，平易な語は出現頻度

が高い傾向にある [Leroy 11] が，出現頻度の閾値を適切に設定することは困難である．

本研究では，単語難易度の付与のため，CEFR-J Wordlist Version 1.3[*1] を用いる．このリストは CEFR に基づいて単語を簡単なものから順に A1，A2，B1，B2 の 4 段階のレベルで示したものである．これに English Vocaburaly Profile[*2] のリストを結合することで，さらに上位の C1，C2 レベルの単語を追加し，合計で 9,277 個の見出し語を含む 6 段階の単語難易度辞書を作成した．この辞書では単語の原形と品詞ごとに難易度が関連付けられている．入力文中の語に難易度を対応させるには各単語の原形と品詞の情報が必要であるため，Stanford CoreNLP [Manning 14] を用いた解析を行う．難易度の上位 3 段階である B2，C1，C2 レベルが付与された名詞，動詞，形容詞，副詞となる語を TARGET とする．

2.2 CANDIDATE の絞り込み

CANDIDATE の絞り込みにおいて，Glavaš ら [Glavaš 15] は単語ベクトルの類似度を用いている．TARGET とのベクトルのコサイン類似度の高い語を CANDIDATE としているが，対義語が含まれる割合も高く，CANDIDATE リストに多くの不正解候補が含まれるため，後の CANDIDATE 判別に高い精度が要求されることになる．

本研究では，CANDIDATE リストの品質を担保するため，CANDIDATE を Thesaurus.com[*3] から作成した類義語辞書から抽出する．CANDIDATE の選定手法について，まず入力文から抽出した各 TARGET について類義語辞書から，同一の見出し語と品詞に関連付けられた類義語を取り出す．得られた類義語に対して難易度付与を行い，TARGET 難易度が下位 3 段階である A1，A2，B1 レベルが付与された語を CANDIDATE とする．

2.3 CANDIDATE の選定

本研究では，言い換え可能な CANDIDATE の判別において考慮すべき要件を TARGET との語義が一致すること，入力文における TARGET と周辺の語との文法的，文脈的整合性を維持することと定義する．これらを考慮する特徴量を抽出し，入力文において言い換えが可能な CANDIDATE を機械学習によって分類する．

Paetzold ら [Paetzold 16] は品詞情報を付与した TARGET のベクトルと CANDIDATE のベクトルの類似度，2-gram および 3-gram の言語モデルスコア，CANDIDATE の品詞別の出現頻度比を特徴量として組み合わせている．しかし，この特徴量セットでは同じスペル，同じ品詞を持つが語義が異なるケースに対応できないと考えられる．語義曖昧性解消の既存研究では，Navigli ら [Navigli 09] は 25% 以上の単語について正確に語義を判別することができておらず，語義の高精度な判定は未だ困難である．

既存の単語分散表現では，周辺に出現する単語によって意味を近似するが，一単語につき一つの分散表現となるため，複数の語義が混在した表現となってしまう．本研究では，ある単語と有意に共起する単語が語義を限定する手がかりとなると仮定する．そして，このような共起語を制約として単語分散表現に加えることで，語義を近似する単語分散表現を生成する．具体的には，TARGET と CANDIDATE の組み合わせについて，入力文中に TARGET と CANDIDATE の両方と有意に共起する語 (PairWord) があると仮定し，PairWord を付与した単語ベクトルの類似度を用いることで語義推定を模倣した特徴量を加える．生成する単語ベクトルは単語と PairWord の 2 つ組から生成するため，学習データがスパースになると予想される．そこで提案手法ではカバレッジを向上させるため，PairWord を付与した単語ベクトル類似度に通常の単語ベクトルの類似度，言語モデルスコアを加えた 3 種類の特徴量を用いる．そして Support Vector Machine (SVM) [Cortes 95] を用いて CANDIDATE の言い換えの可否を分類する．以下では PairWord を付与したベクトル類似度を取得する手順について詳細を述べる．

2.3.1 PairWord の特定

提案手法では，入力文において TARGET と最も共起関係の強い語を PairWord として付与する．共起関係の指標として Mutual Information (MI スコア) [Barnbrook 96] を用いる．2 単語 a，b の MI スコアは以下の式で表され，$f(a)$ および $f(b)$ はそれぞれ単語 a と b のコーパス内での出現頻度，$f(a,b)$ は a と b のコーパス内での共起頻度，N はコーパスの総単語数を示す．MI スコアは 2 単語の共起頻度が大きいほど高い値を示す．一方で，高頻度語については MI スコアは値が小さくなる．MI スコアは事前に Wikipedia の dump データ [*4] を用いて計算したものを使用する．入力文中の全単語から TARGET との MI スコアが最も高い語を PairWord として抽出する．

$$MI(A,B) = \log_2 \frac{Nf(A,B)}{f(A)f(B)}$$

2.3.2 単語ベクトル類似度の計算

PairWord の情報を付与した単語ベクトルの生成のため，事前に Wikipedia の dump データを学習データとし，word2vec の continuous bag-of-words [Mikolov 13a, Mikolov 13b] によりベクトルの生成を行う．学習データの各単語にアンダーバーで PairWord を結合することで，PairWord の情報を各トークンに付与することができる．得られたベクトルを用いて，TARGET と PairWord を付与したトークン，CANDIDATE と PairWord を付与したトークンのベクトルの類似度を求め，特徴量として用いる．

3. 評価実験

本章では，提案手法による CANDIDATE の言い換え性能を評価する．

3.1 データセット

評価用データとして，CANDIDATE の言い換えの可否をネイティブ話者がアノテートした Gold-standard データセットを用いる．このデータは類義語辞書と CEFR レベルに基づいた TARGET と CANDIDATE について，文法的整合性，語義的な類似度，入力文におけるコロケーションの 3 項目について判定することで言い換え可能な CANDIDATE の判別を行う．アノテーションの対象テキストは Rice 大学の公開教科書データ [*5] と九州大学の英語リーディングの授業で用いられる上級レベルのテキストを用いる．Rice 大学の教科書データを基に作成したデータは CEFR-LS [Uchida 18][*6] として公開している．

∗1 東京外国語大学投野由紀夫研究室．（http://www.cefr-j.org/download.html より 2018 年 1 月ダウンロード）
∗2 http://www.cefr-j.org/download.html
∗3 http://www.thesaurus.com/
∗4 https://dumps.wikimedia.org/enwiki/
∗5 http://cnx.org/
∗6 http://www-bigdata.ist.osaka-u.ac.jp/arase/pj/lex-simplification.zip

データの種類	TARGET 数	CANDIDATE 数
学習データ	450	2,123
開発データ	72	811
テストデータ	270	3,140

表 1: 実験データの内訳

アノテーションの結果，言い換え可能な CANDIDATE を一つ以上持つ TARGET 792 個，その CANDIDATE 9531 個 (このうち，言い換え可能な正解 CANDIDATE は 1954 個) を評価用データとして用いる．実験には，データセットを表 1 のように分割して使用する．テストデータについてはドメインの偏りを避けるため，Rice 大学の教科書データ 9 種類それぞれから TARGET 30 個ずつをランダムに抽出したものを使用する．学習データについては，正例と負例の偏りを小さくするため，各 TARGET について正解 CANDIDATE と不正解 CANDIDATE の数が同数になるようにサンプリングする．

3.2 評価指標

英語習熟度の高い教育者は候補リストから言い換え可能な CANDIDATE を選定できると期待できる．そのため，教育者の教材作成支援においては，より多くの TARGET に対して正確に正解 CANDIDATE を少なくとも一つは出力できることが望ましい．この評価指標として，以下の式で示す T_{Eval} を用いる．T は TARGET の集合，$f(t)$ は TARGET の t に対して正解 CANDIDATE を一つ以上出力すれば 1，それ以外は 0 をとる関数を示す．

$$T_{\mathrm{Eval}} = \frac{1}{|T|}\sum_{t\in T} f(t)$$

一方で，言い換え候補として示すリスト中の不正解 CANDIDATE は少ない方が，教育者の判断の負担を減らすため望ましい．そのため，各 CANDIDATE リストに含まれる言い換えが可能な正解 CANDIDATE の割合が高いリストを出力することも重要である．そこで，以下に示す $C_{\mathrm{Precision}}$ を用いた評価を行う．T' は正解 CANDIDATE を一つ以上出力した TARGET の集合，c_{correct} は TARGET の t が持つ正解 CANDIDATE 数，c_{output} は t に対して出力した CANDIDATE 数を示す．

$$C_{\mathrm{Precision}} = \frac{1}{|T'|}\sum_{t\in T} \frac{c_{\mathrm{correct}}}{c_{\mathrm{output}}}$$

一般的に，出力 CANDIDATE 数が増えると，多くの TARGET に対して正解 CANDIDATE を出力できるようになる一方で，各出力リストに含まれる不正解 CANDIDATE の割合も増加する．そのため，T_{Eval} と $C_{\mathrm{Precision}}$ はトレードオフの関係にある．

3.3 実験設定

比較手法として，Paetzold ら [Paetzold 16] の特徴量セットを用いる．また，PairWord を付与した単語ベクトル類似度の有効性を評価するため，通常の単語ベクトル類似度，言語モデルスコアのみを組み合わせたものをベースラインとし，比較手法とする．

SVM の実装としては Libsvm*7 を用いる．RBF カーネルを使用し，ハイパーパラメータは c と γ の 2 種類を開発データを用いてチューニングする．

特徴量セット	$C_{\mathrm{Precision}}$	T_{Eval}	T_{out}	C_{out}
提案手法	0.43	**0.81***	**255**	**1,245**
既存手法	0.43	0.76	250	1,173
ベースライン	**0.50***	0.67	228	782

表 2: 特徴量セット毎の言い換え精度と出力 TARGET および CANDIDATE 数．* は他の手法と統計的有意差を確認したことを示す．また，T_{out} と C_{out} はそれぞれ出力 TARGET と 出力 CANDIDATE の合計数を表す．

特徴量セット	$C_{\mathrm{Precision}}$	T_{Eval}	T_{out}	C_{out}
提案手法	0.39	**0.80***	**116**	**622**
既存手法	0.37	0.71	113	588
ベースライン	**0.42***	0.55	99	343

表 3: 多義語のみを TARGET とした場合の言い換え精度と出力数．* は他の手法と統計的有意差を確認したことを示す．

He took Psyche to his palace and showered her with gifts, yet she could never see his face.

TARGET: shower
正解 CANDIDATE: give
提案手法の出力: give (PairWord: gift)
既存手法の出力: pour
ベースラインの出力: storm

表 4: 言い換え成功例

3.4 実験結果

評価実験の結果を表 2 に示す．表 2 より，ベースラインや既存手法と比較して，提案手法の方が T_{Eval} が高い．これは，提案手法がより多くの対象語に対して正解候補語を出力できることを示している．一方で，$C_{\mathrm{Precision}}$ は T_{Eval} とトレードオフの関係となるが，$C_{\mathrm{Precision}}$ は最も高いベースラインに比べ 7% の減少に抑えられている．このことから，提案手法は教育者支援のための語彙平易化において望ましい性能を持つことが分かる．また，表 2 の右側より，他の手法と比較して提案手法がより多くの TARGET について CANDIDATE を出力できていることが分かる．

Thesaurus.com において複数タブを持つ語を多義語とし，テストデータから多義語 (122 個) のみを TARGET とした場合の評価結果を表 3 示す．全ての TARGET を使用したときと比較し，$C_{\mathrm{Precision}}$ と T_{Eval} は全体的に減少しており，多義語の言い換えが困難であることが分かる．しかし，提案手法の T_{Eval} は全ての TARGET を対象とした場合とほぼ同等の値を示しており，他の手法と比較して多義語に頑健な手法であるといえる．

言い換えの成功例を表 4 に示す．動詞の shower は多くの場合「雨が降る」や「浴びせる」という語義で用いられるが，表 4 の入力文においては「与える」という語義で用いられている．通常の単語ベクトルや品詞情報のみを付与した単語ベクトルでは，出現頻度が高いと考えられる前者の語義に近い語の類似度が高い．一方で，提案手法では PairWord として gift を抽出しており，正解 CANDIDATE である give を出力できている．

言い換えの失敗例を表 5 に示す．表 5 では，pioneer は「開

*7 https://www.csie.ntu.edu.tw/~cjlin/libsvm/

Think back to pioneer days, when individuals knew how to do so much more than we do today, from building their homes, to growing their crops, to hunting for food, to repairing their equipment. TARGET: pioneer 正解 CANDIDATE: settler 提案手法の出力: innovator (PairWord: equipment)

表 5: 言い換え失敗例 (1)

Some disciplines such as biophysics and biochemistry build on both life and physical sciences and are interdisciplinary. TARGET: discipline 正解 CANDIDATE: area 提案手法の出力: curriculum (PairWord: biochemistry)

表 6: 言い換え失敗例 (2)

拓者」という語義で用いられているが，PairWord として不適切な equipment を抽出しており，不正解となった．この例では，day を PairWord として抽出できれば正解である settler を出力できると考えられる．そこで，入力文の構文解析を行い，TARGET との依存関係を持つ語を優先的に PairWord の検索対象とすることで，言い換え精度を高めることができると考えられる．このような依存関係を利用して PairWord を特定するため，対象単語との依存関係を持つ頻度を用いた MI スコアデータの拡充が今後の課題である．

また，PairWord は適切であるが，不正解となった例を表 6 に示す．表 6 では discipline は「分野」という語義で用いられている．PairWord としてはその分野名である biochemistry が抽出されており，適当であると考えられるが，正解である area の出力はできなかった．この原因として，提案手法では各単語と Pairword を連結した単語ベクトルの学習を行うため、学習データのスパース性が顕著となったためと考えられる．この例における biochemisry と area は学習データにおいて 2 回しか Pairword の関係を持っておらず，ベクトルの学習が困難であったと推察できる．これは TARGET や PairWord が専門用語などの低頻度語である場合において特に問題となる．そのため，目的のドメインに応じたコーパスを学習データとして用いることが必要であることが分かる．

4. まとめ

本研究では，英語教育支援を目的とした語彙平易化手法を提案した．提案手法では，CEFR レベルに基づいた TARGET の特定，類義語辞書を用いた CANDIDATE の選定，共起語を付与した単語ベクトルを用いた CANDIDATE の判別の 3 つのステップで語彙平易化を実現した．言い換え精度の評価実験の結果，提案手法では既存手法よりも多くの TARGET に対して正解 CANDIDATE を出力することができた．出力結果を解析したところ，構文解析を利用した PairWord の特定や，目的のドメインに適したコーパスを用いたベクトルモデルの学習により精度の向上が見込まれる．

今後は，依存構造を考慮した MI スコアデータの拡充，フレーズを対象とした平易化への手法の拡張を行う予定である．

謝辞

本研究は公益財団法人 KDDI 財団の助成を受けたものです．また，Gold-standard データセットの作成にあたり，アノテーションを行って頂きました九州大学大学院言語文化研究院の Christopher G. Haswell 准教授に感謝の意を表します．

参考文献

[Alderson 07] Alderson, C.: The CEFR and the Need for More Research, The Modern Language Journal, Vol. 91, pp. 659–663 (2007)

[Barnbrook 96] Barnbrook, G.: Language and Computers: A Practical Introduction to the Computer Analysis of Language, Edinburgh University Press (1996)

[Cortes 95] Cortes, C. and Vapnik, V. N.: Support-vector Networks, Machine Learning, Vol. 20, No. 3, pp. 273–297 (1995)

[Glavaš 15] Glavaš, G. and Štajner, S.: Simplifying Lexical Simplification: Do We Need Simplified Corpora?, in Proc. of ACL-IJCNLP, pp. 63–68 (2015)

[Leroy 11] Leroy, G. and Endicott, J. E.: Term Familiarity to indicate Perceived and Actual Difficulty of Text in Medical Digital Libraries, Digital Libraries: For Cultural Heritage, Knowledge Dissemination, and Future Creation, pp. 307–310 (2011)

[Leroy 13] Leroy, G., Endicott, J. E., Kauchak, D., Mouradi, O., and Just, M.: User Evaluation of the Effects of a Text Simplification Algorithm Using Term Familiar- ity on Perception, Understanding, Learning, and Infor- mation Retention, Journal of medical Internet research, Vol. 15, No. 7 (2013)

[Manning 14] Manning, C. D., Surdeanu, M., Bauer, J., Finkel, J., Bethard, S. J., and McClosky, D.: The Stanford CoreNLP Natural Language Processing Toolkit, in Proc. of ACL, pp. 55–60 (2014)

[Mikolov 13a] Mikolov, T., Chen, K., Corrado, G., and Dean, J.: Efficient Estimation of Word Representations in Vector Space, in Proc. of ICLR (2013)

[Mikolov 13b] Mikolov, T., Sutskever, I., Chen, K., Corrado, G., and Dean, J.: Distributed Representations of Words and Phrases and their Compositionality, in Proc. of NIPS, pp. 3111–3119 (2013)

[Navigli 09] Navigli, R.: Word Sense Disambiguation: A Survey, ACM Computing Surveys, Vol. 41, No. 2, p. 10 (2009)

[Paetzold 16] Paetzold, G. H. and Specia, L.: Unsupervised Lexical Simplification for Non-Native Speakers, in Proc. of AAAI, pp. 3761–3767 (2016)

[Uchida 18] Uchida, S., Takada, S., and Arase, Y.: CEFR-based Lexical Simplification Dataset, in Proc. of LREC (2018, to appear)

Oral presentation | Organized Session | [Organized Session] OS-25

[3H1-OS-25a] [Organized Session] OS-25

Thu. Jun 7, 2018 1:50 PM - 3:30 PM Room H (10F Sky Hall)

[3H1-OS-25a-01] The comparison of AI Ethics Guidelines among Japan, the US and Europe, focusing on issues related to national character

○Keiko Uemura[1], Akio Kozato[1], Takahiro Shiga[1], Keiichiro Hayakawa[1] （1. TOYOTA CENTRAL R&D LABS.,INC.）

1:50 PM - 2:10 PM

[3H1-OS-25a-02] Challenges for AI which promotes humans' ethical behaviors

○Keiko Fukuhara[1] （1. Nagoya University）

2:10 PM - 2:30 PM

[3H1-OS-25a-03] Can AI Involve AI Engineers in Ethical Design Activities?

○Kaira Sekiguchi[1], Koichi Hori[1,2] （1. Graduate School of Engineering, The University of Tokyo, 2. Center for Advanced Intelligence Project, RIKEN）

2:30 PM - 2:50 PM

[3H1-OS-25a-04] Extraction of new guideline items from the view point of ELSI (Ethics, Legal, Social Issues) for service utilized AI

○Shin'ichi Fukuzumi[1], Mariko Jinno[1], Kasumi Inagaki[1], Hiroko Yasu[1], Toshihiko Hiroaki[1], Haruka Maeda[2], Takuya Mizukami[2], Osamu Sakura[2] （1. NEC Corporation, 2. University of Tokyo）

2:50 PM - 3:10 PM

[3H1-OS-25a-05] Design dialogue and community to discuss IEEE "*Ethically Aligned Design*"

○Arisa Ema[1], Katsue Nagakura[2], Fumiko Kudo[3] （1. The University of Tokyo, 2. Science Writer, 3. Makaira KK）

3:10 PM - 3:30 PM

©The Japanese Society for Artificial Intelligence

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

日米欧の地域特性に着目したAI倫理ガイドラインの比較

The comparison of AI Ethics Guidelines among Japan, the US and Europe, focusing on issues related to national character

上村 恵子[*1] 小里 明男[*1] 志賀 孝広[*1] 早川 敬一郎[*1]
Keiko Uemura Akio Kozato Takahiro Shiga Keiichiro Hayakawa

[*1] (株)豊田中央研究所
TOYOTA CENTRAL R&D LABS., INC.

With the progress of the technology of artificial intelligence (AI), there have been various groups that discuss the problem of ethical, legal and social issues provided by the AI technology. Although they cooperate with each other to formulate guidelines for the development of AI products, the variety of these guidelines will require great effort to international companies to follow all of these guidelines. One possible factor of such differences is the national character, namely the aspect emphasized in these guidelines is different depending on the country or area in which they are discussed. To examine this, we show the difference of these guidelines and discuss it focusing on a matter of national character.

1. はじめに

科学技術は人々の生活を豊かにすることを目的に医療、産業、経済などを発展させ、これまでに多大な貢献をもたらしてきた。一方、我が国では他国に先駆けて少子高齢化が進み、遠くない将来における労働力低下が懸念される中、技術革新による生産効率や利便性の向上などに、期待が高まっている。特に、AI 技術は、もっとも期待されている技術の一つであり、家電など身近な商品への実装が進んでいる。しかし、どのような技術も、開発者が意図しない使われ方により、社会に深刻な損害をもたらす危険性がある。近年では、システムへのハッキングによって利用者が不利益を被る事件や、トーキングトイからの個人情報漏洩の問題が指摘され始めている。このような技術の負の側面による社会への悪影響を未然に防ぐために、様々なステークホルダーが集まってその危険性について議論し、新技術導入以前の研究開発の段階から、なんらかの規制や開発ガイドラインを設ける動きがみられる。

AI 技術の倫理、法、社会的課題(Ethical, Legal and Social Issues - ELSI)の検討を行う団体は、政府が中心となって開かれる会議や関連学会が主催する委員会、民間企業や有志が集まって構成される団体など様々である。その取り組みは 2014 年頃から国内外で盛んになり、特に 2016 年からの 1 年間で多くの検討結果がガイドラインや提言の形で報告されている[総務省情報通信政策研究所 16a]。企業が AI を用いた製品を市場に投入する際には、このようなガイドラインを遵守する必要がある。しかし、グローバルに製品を展開する企業にとって、国・地域ごとに異なるガイドラインに対応する製品を展開することは多大な労力を要するため、ガイドラインの制定における国際的な協調が望まれている。

ところが、AI のガイドラインの位置づけの捉え方は、国や地域によって異なっているため、重視される項目にもそれぞれの国・地域ごとに特徴がみられる。本研究ではこのような背景をふまえ、日本・米国・欧州の各国および地域の違いに着目し、それぞれの検討団体が策定したガイドライン(報告書)の特徴と相違点を整理し、各国および地域の国民性と関連付けて考察する。

連絡先:上村恵子, (株)豊田中研 都市・交通システムデザインプログラム, uemura@mosk.tytlabs.co.jp

2. 既往研究

世界各国で発表されている AI 倫理に関するガイドラインについて、その内容や相違点を整理する研究事例は、数多く存在する。例えば、江間[江間 17]は、学会誌「人工知能」2017 年 9 月号の特集「AI 社会論」の中で、国内外の5団体が策定したガイドラインの特徴を報告している。この報告では、これらのガイドラインの共通点として、AI 技術がもたらすリスクの軽減と便益の最大化をめざし、異業種間協働の検討機関を設置して適切な運用を図ることを掲げているという点を挙げている。一方で、「倫理」を考える際の論点として、主に研究の責任や心構えなどの「研究者倫理」、技術の開発原則や影響分析などの「人工知能の倫理」や、道徳的にふるまう AI の研究である「倫理的な AI」の3つの論点を挙げ、それぞれのガイドラインが取り扱う論点の比重が異なっていることを示している。

本研究では、このような研究事例を参考に、各報告書が発行された国および地域の違いに着目して、それぞれの特徴を整理する。

3. 日米欧のガイドラインの特徴

本研究では、日・米・欧の各地域で発行された AI 倫理のガイドラインを対象として、頻出している語句や項目をこだわり度として捉え、キーワードを抽出し、その特徴を整理した。調査の対象は、表 1 に示す 15 報の報告書とした。これらは、総務省「AI ネットワーク社会推進会議」の報告資料 [総務省情報通信政策研究所 16a]および内閣府「人工知能と人間社会に関する懇談会」における報告資料 [内閣府 2016]から選出したものである。

3.1 欧州のガイドライン

欧州のガイドラインの特徴は、人の権利や責任に重点を置いていることである。欧州委員会がまとめた「ロボティクス規制のガイドライン」の議論では、「AI」というよりは学習するタイプを含める「ロボット」が議題となり、「ロボットとはなにか」や「なぜ規制が必要なのか」という、そもそも論から議論されている。英国下院のガイドラインでは「ロボットは道具・製品・人工製造物である」と定義し、人間が責任主体であることを強調している。すなわち、AI 搭載の高度なロボットが労働者となった場合には、ロボットの所有者は、人間の労働者を雇用する雇用主と同様に、ロボット

表 1.分析対象の AI 倫理ガイドライン

年	国	検討団体	ガイドライン・提言（案）
2010年9月	英	工学・物理科研究会議	「ロボット五原則」
2014年9月	欧	欧州委員会	「ロボティックス規制のガイドライン」
2016年4月	英	英国規格協会	「ﾛﾎﾞｯﾄとﾛﾎﾞﾃｨｯｸｽ端末：ﾛﾎﾞｯﾄとﾛﾎﾞﾃｨｯｸｽ・ｼｽﾃﾑの倫理的なﾃﾞｻﾞｲﾝと応用のためのガイド」
2016年5月	欧	欧州議会 法務委員会	「ロボティックスにかかる民法規則に関する欧州員会への提言に関する報告書案」
2016年6月	日	総務省 AIﾈｯﾄﾜｰｸ化検討会議	「報告書2016」
2016年9月	英	下院 科学技術委員会	「ロボティクスと人工知能」
2016年9月	米	Stanford AI100	「2030年のAI」
2016年9月	米	Partnership on AI	「信条」
2016年10月	米	ホワイトハウス	「人工知能の未来に備えて」
2016年12月	米	IEEE Global Initiative	「倫理的設計ver.1」
2016年12月	米	ホワイトハウス	「AI,自動化,そして経済」
2017年2月	米	Future of Institute	「アシロマAI 23原則」
2017年2月	日	人工知能学会 倫理委員会	「人工知能学会 倫理指針」
2017年3月	日	内閣府懇談会	「人工知能と人間社会に関する懇談会」報告書
2017年7月	日	総務省 AIﾈｯﾄﾜｰｸ社会推進会議	「報告書2017」

の労働に関連する責任を負うことを求める動きがある。欧州議会法務委員会が 2016 年 5 月に草案を作成し、2017 年 2 月に採択した決議案 [欧州議会 17]では、比較的高度な自律型ロボットに対しても、固有の権利と義務を有する「電子人間」という法的地位を与え、損害に対する社会保障費および納税などの義務をオーナーに負担させる内容をすでに含んでいる。今後は責任のみならず、ロボットの権利に関する議論が進むことも考えられる [久木田 17]。

また、欧州では Google や facebook などの米国 IT 企業による個人情報収集や管理について、徹底して自国民のプライバシーを保護すべきであるという考えのもとに [1]、2018 年 5 月には EU 一般データ保護規則（General Data Protection Regulation -GDPR）[EU 2016]が施行予定である。この内容は、個人データの収集・利用は原則として本人の明確な同意がない限り、例外を除いて取り扱うことを禁止するもので、2017 年 10 月には自動処理によるプロファイリングに関する規定で、子供を対象とした自動処理による決定についての指針が示されるなど[総務省情報通信政策研究所 17a]、人権やプライバシーに関して日本や米国に比べて極めて厳格な規則となっている。

欧州議会の決議案の付属文章(Annex)の中では、スマートロボットを登録制やライセンス制にするような提案も出ており、欧州ではこのような AI やロボット開発に関連する規制の検討が積極的に進む可能性がある。

一方で、2017 年 3 月に総務省が開催した国際フォーラム「AI ネットワーク社会推進フォーラム」[2]では、これらの規制を強化せず、行動規範にとどめるという方針も言及しており、今後の欧州の動向を注意深く見守っていく必要がある。

3.2 米国のガイドライン

米国のガイドラインの特徴は、AI 技術による社会便益の最大化を進めると同時に、自律型兵器などの長期的なリスクにも積極的に言及している点である。例えば、ホワイトハウスの提言「人工知能の未来に備えて」[ホワイトハウス 2016]では冒頭に、AI の有益な利用や便益の最大化などの戦略的な政策方針となる要項が述べられ、最終項には自律型および半自律型兵器についての政策策定を提言している。Future of Life Institute (FLI)が報告した「アシロマ AI23 原則」[FLI 17]においても AI の軍拡競争禁止の要項があり、IEEE Global Initiative の「倫理的設計 ver.2」[IEEE 17]でも、自律型兵器システムの再定義と管理が議題として取り上げられている。IEEE Standard Association はここでの議論を反映する形で、IEEE－SA P7000 シリーズとして、自律システムの透明性(P7001)やデータプライバシーの処理（P7002）など、11 項目について数年後の標準化を目指してドラフトを作成中であるが、認証制度というよりは「透明性をどう確保するか」という議論が中心で、ただちに厳格な規定を設ける動きはない[江間 17]。ホワイトハウス科学技術政策局の Edward W. Felten 氏も、先述した「AI ネットワーク社会推進フォーラム」[2] の中で、「政府では、AI ネットワークのガバナンスにおいて、ソフトな規制にとどめており、新しい規制を設けるのではなく、既存の規制を AI の進展に適応させていくアプローチをとっている」と述べている。

3.3 日本のガイドライン

総務省や内閣府のガイドラインは、AI 技術の普及促進と同時に、人々の不安解消を目的とした倫理原則に重点を置いており、例えば透明性、制御可能性、安全性やプライバシー保護など技術面の原則が中心となっている。一方、人工知能学会の「倫理指針」でも以上の点は同様であるが、主に学会員自身の「研究者倫理」に焦点を合わせていることと、作られた人工知能側にも人間同様に倫理指針を遵守できることを求めているという特徴がある。

安全性については一般論の範囲であり、自律型兵器については具体的に触れていない。欧米がソフトな規制を強調する中で、当初日本では、総務省が開発原則の実効性を確保する方法の例として、「開発者が自発的に提供する情報に基づき、第三者機関が当該AIの開発原則への適合性を評価して認証する制度」を 2016 年の中間報告書 [総務省情報通信政策研究所 16b]で提案した。しかし 2017 年 1 月に行った一般を対象にした意見募集[総務省情報通信政策研究所 17b]で、「開発原則の実効性確保に関して、（中略）このような制度は、開発者の自由な開発を萎縮させ、AIの発展を妨げる可能性を有するものであり、ガイドラインに書き込むことには極めて慎重であるべき」との指摘を受けて、そのような誤解を招くことのないように、認証制度に関する項目はのちに削除されたようである。

4. 日米欧のガイドラインの比較に関する考察

前章で述べたように、日本、米国、欧州で制定されたガイドラインには、論点の違いがみられる。本章では、この違いについて、各国および地域の国民性に着目して考察する。

人々の価値観について国別の特徴を調査している「世界価値観調査」は、ミシガン大学ロナルド・イングルハート教授が中心となり、世界各国の研究機関が協力する国際プロジェクトである。1981 年から実施しており、各国・地域ごとに全国の 18 歳以上の男女 1,000 人程度を対象に、政治観、労働観などの意識調査を行っている。 2005 年の価値観調査では、日々生活していく上で「大切にしたいこと」について、10 項目の選択肢を挙げて質問し、各国別の回答を示している[電通総研 08]。図 1 は、その結果を日本、米国、欧州に分けて示したものである。以下では、この調査の結果に加えて、他の公知文献や国内有識者との議論などを参考に、それぞれの国、地域における、「リスクに対する考え方」、「宗教感の違い」、「ルール作りに対する考え方」、「議論の進め方」、「労働需要」の5つの観点でガイドラインの論点の違いについて考察する。

[1] 日本経済新聞電子版：[FT]EUの新規制案、米ネット企業に大打撃，2016 年 12 月 14 日掲載.

[2] ZDNet Japan: 人類は人工知能を使いこなせるのか--AI の未来と社会実装を議論，2017 年 4 月 6 日掲載.

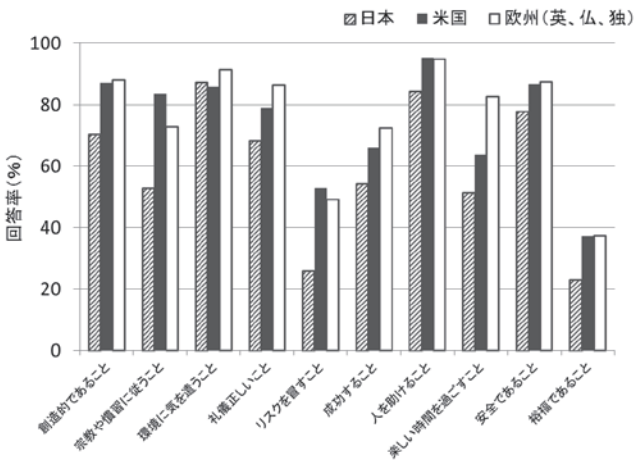


図 1. 世界主要国価値観調査([電通総研 08]を元に作成)

(1) リスクに対する考え方

図 1 に示す価値観調査[電通総研 08]の結果によると、「冒険し, リスクを冒すこと, 刺激のある生活が大切な人」に「あてはまる」(「非常によくあてはまる」+「あてはまる」+「まあてはまる」+「少しあてはまる」) と回答した人の割合は、日本が 25.8%であるのに対し、米国は 52.8%、欧州(イギリス、フランス、ドイツの平均)は 49.1%であり、米国が最もリスクに対して積極的に向き合う傾向が見られる。米国のガイドラインで、AI 技術による利益の最大化と同時に、自律型兵器のリスク検討と政策に重点を置いているが、日本のガイドラインでは自律型兵器についてあまり言及されていない理由の一部は、こうしたリスクに対する考え方の影響を受けている可能性がある。

(2) 宗教観の違い

人型ロボットに対する感情は、それぞれの国の宗教観に作用されるとの見解は多い [1] [北野 07]。キリスト教やイスラム教などの一神教の多くは偶像崇拝を禁止しており、人を作ることは神のみであり、人と似たものを人間が作ることに抵抗感を持ちやすい。一方、多神教である神道の考えをベースに持つ日本では、すべてのものに魂があるとするアニミズム的思想が強く、さらに鉄腕アトムやドラえもんのように手足を持ち、人と話せて人を助けてくれるアニメキャラクターの影響から、「人に似せたロボットを作ること」に抵抗感が比較的少ないと推察される。また、図 1 に示す価値観調査[電通総研 08]の結果では、「伝統や, 宗教や家族によって受け継がれてきた慣習に従うことが大切な人」に「あてはまる」と回答した人の割合は、日本が 52.7%であるのに対し、米国は 83.5%、欧州は 73%と高い数値を示し、日本よりも欧米の方が宗教や慣習を拠り所としていることが分かる。欧州での議論で、ロボットは「道具である」と定義し、人とはっきり区別するところから始まり、ガイドラインにおいて人間の権利や責任に重点が置かれているのも、このような宗教観からくるものと推察される。

(3) ルール作りに対する考え方

本田技研工業(株)で国内外の自動車産業に関わるルール作りに携わった青木高夫の著書 [青木 13]では、日本人と欧米人のルールにまつわる考え方の違いとして、次のように指摘している。

> **大方の日本人にとって、”ルールはほかの誰かが作るもの“であり、立ち居ふるまいの美しさや行動の美学は、”作られたルールの下で最善の努力をすること“にある**、(中略)さらに、現代の官、昔のお上の側にも”ルールは自分たちだけが作るものだ“という権威意識があると思います。
>
> 極論になりますが、これに対して**欧米人にとってはルールとはあくまでも”決めごと“**であり、守ることは大切であっても、それが自分に不利となれば、有利になるように変更するか、そのために利害関係者と交渉すればよいものです。
>
> ([青木 13]:p30-31)

日本では事故などの問題発生時に、負わなければならない責任を意識するあまり、ルールが無い場合には慎重にならざるを得ない風潮があるため、企業が製品化する場合は標準規格など、政府や第三者機関によってある程度のお墨付きが得られることに前向きな傾向があるように思われる。一方で、欧米ではルールは一時的な「決めごと」であり、それは自分に有利になるように交渉して変えていけるものと理解しているようであり、日本と欧米では、ルールそのものに対する考え方が異なるようである。

さらに、この著書[青木 13]によると、ルール作りにおいても違いが見られるという。欧米では「議論の場に参加しない者の利害は考慮されない(If you are not at the table, you are on the menu.)」ということわざがあるように、まず議論に参加することが自らの利益や権利を守る第一歩であると考えられている。また政府は公僕であり、民が主体となって発言し、官民が一緒になってルール作りを行ってきた歴史があるという。一方、日本は歴史的にどちらかというと官が主導し、有識者が作成し、それに民が守り従う官主民従のシステムを続けてきていると言われている。

電通総研の価値観調査[電通総研 08]の中で、理想の社会システムについて、「国民皆が安心して暮らせるよう国はもっと責任を持つべきだ」か、「自分のことは自分で面倒を見るよう個人がもっと責任を持つべきだ」かについて、どちらの意見に近いかを 10 段階で尋ねた結果、「国が責任をもつべき(1~5)」と回答した割合は、イギリス 41.5%、フランス 45.8%、ドイツ 66.7%、アメリカ 42.5%であった。一方、日本は 71.4%と国家の役割に対する人々の期待が他国に比べて大きいことがわかる。以上のような価値観が日本のガイドラインにおいて、一時的ではあるが、第三者認証機関による実効性確保が提案された一因と考えられる。

(4) 議論の進め方

議論の進め方として、日本ではルールや技術による解決が望まれがちである。たとえば、交通政策において、交通安全のために「交通ルール」、「信号機、標識」や「サポートカー」 など、主にインフラや技術を中心に整備されてきている。これに対し、欧州では、信号や標識など道路のインフラは最低限のみを残して撤去し、インフラに頼らず、右方優先など最低限のルールだけの混合空間「シェアードスペース」が導入された地域がある[Elfferding 10]。これは、道路利用者全員が安全について意識し、相互にコミュニケーションをとることで交通事故を減らすもので、ドイツやオランダで実施され成果を上げている試みである。このように、欧州では機械や技術ありきではなく、そもそもその技術は必要なのかどうか、存在意義から議論される傾向がみられる。欧州のガイドラインにおいても、技術が普及して得られる

[1] 原野城治:なぜ、日本の研究者は人型ロボットを作るのか, Nippon.com, 2012, https://www.nippon.com/ja/views/b00901/

「社会便益」というよりは、どちらかというと人間の尊厳の保護など「人」を中心としたまとめられ方がされているのは、こうした議論方法の背景によるものと考えられる。

(5) 労働需要

労働政策研究・研修機構が発行する「データブック国際労働比較 2017」で報告された ILO 定義失業率のグラフ［JILPT 17］によると、2008 年のリーマンショック後にどの国も失業率が増加したが、その後十分に回復できていない他国の状況と比べて、日本ははるかに失業率が低い。その上、日本は少子高齢化の世界のトップランナーであるため、AI などの技術発展により人手不足を補えることへの期待が高まる。一方、欧米ではリーマンショック後の長期にわたる高い失業率の影響に加え、欧州ではかつて産業革命期に導入された工業機械に対して、雇用喪失の不安を抱えたイギリスの労働者たちが、機械破壊運動（ラッダイト運動）を引き起こした歴史的背景を持ち、AI の実装化で再び起こりうる AI 搭載機器への雇用代替によって、さらに不安が高まると推察される。欧州のガイドラインでは特に人権が重視され、一方日本のガイドラインでは社会便益が重視されているのは、このような歴史的背景と労働需要が影響している可能性がある。

5. まとめ

本研究では、日本・米国・欧州の各国および地域で策定された AI 開発ガイドラインの特徴を整理し、その違いについて考察した。その結果、ガイドラインの論点の違いの一部は、それぞれの国および地域の国民性や価値観の違いから生じるものと推察される。

米国では背景に宗教的抵抗感がある上に、高い失業率が続いていることで、AI への恐怖感や警戒心は日本よりもずっと強い一方で、AI 技術はビジネスチャンスでもあり社会便益向上のための国策であるため、リスク検討も含んだ積極的な議論が進むと思われる。欧州では、人とは何か、その技術は本当に必要か、などそもそも論から議論がなされる傾向があり、技術よりも人の権利や責任を重視した指針となるため、国際的なガイドラインとしてはそれぞれが現時点ではソフトロー的なガイドラインで合意しているものの、プライバシーなど一部の権利に関して規制を設け始めるなど慎重な動きも見せている。日本では人型ロボットへの宗教的な抵抗感が少ない上に、少子高齢化による人手不足の解決策として、どちらかというと技術ありきの議論が行われる結果、社会便益を重視した指針となる。またルール作りは官主民従であり、ルールがない場合には慎重にならざるを得ない風潮があるため、第三者認証機関による実効性確保への抵抗感は他国と比べると低い可能性がある。

今後、国際的な AI 倫理指針がまとめられていく中で、このような価値観や考え方の違いについて、より深い相互理解が求められるだろう。

謝辞

本研究を進めるにあたり、適切な助言を賜り、また丁寧にご指導を頂いた名古屋大学 久木田水生准教授，東京大学 江間有沙特任講師に深く感謝致します。また、ワークショップ等の議論を通じて多くの知識や示唆を頂いた皆様に感謝致します。

参考文献

［Elfferding 10］ Susanne Elfferding: ドイツにおけるシェアードスペースの法的枠組みとその実践，国際交通安全学会誌，公益財団法人国際交通安全学会，2010.

［EU 2016］ European Union: REGULATION (EU) 2016/679 OF THE EUROPEAN PARLIAMENT AND OF THE COUNCIL of 27 April 2016 on the protection of natural persons with regard to the processing of personal data and on the free movement of such data, and repealing Directive 95/46/EC (General Data Protection Regulation), 2016.

［FLI 17］ Future of Life Institute: Asilomar AI Principles, 2017. https://futureoflife.org/ai-principles/

［IEEE 17］The IEEE Global Initiative for Ethical Considerations in Artificial Intelligence and Autonomous Systems：Ethically Aligned Design, Version 2, 2017. http://standards.ieee.org/develop/indconn/ec/autonomous_systems.html

［JILPT 17］ 労働政策研究・研修機構：データブック国際労働比較 2017, 2017.

［青木 13］ 青木高夫: なぜ欧米人は平気でルールをかえるのか，ディスカヴァー携書 096, 2013.

［江間 17］ 江間有沙: 倫理的に調和した場の設計：責任ある研究・イノベーション実践例として，人工知能 ，人工知能学会，2017.

［欧州議会 17］ European Parliament : Report with recommendations to the Commission on Civil Law Rules on Robotics, 2017.

［北野 07］ 北野菜穂: Animism, Rinri, Modernization: The Base of Japanese Robotics, University of Sussex Library, 2007.

［久木田 17］ 久木田水生，神崎宣次，佐々木拓：第 8 章 働くロボット，ロボットからの倫理学入門，名古屋大学出版会，2017.

［総務省情報通信政策研究所 16a］ 総務省: AI ネットワーク社会推進会議 第 1 回 配布資料, 2016. http://www.soumu.go.jp/main_sosiki/kenkyu/ai_network/02iicp01_04000075.html

［総務省情報通信政策研究所 16b］ 総務省: AI ネットワーク社会推進会議 第 2 回, 2016. http://www.soumu.go.jp/main_content/000456706.pdf

［総務省情報通信政策研究所 17a］ 総務省: AI ネットワーク社会推進会議 第 8 回 配布資料, 2017. http://www.soumu.go.jp/main_sosiki/kenkyu/ai_network/02iicp01_04000120.html

［総務省情報通信政策研究所 17b］ 総務省: AI ネットワーク社会推進会議「整理した論点に関する意見募集に寄せられた主な意見に対する考え方」, 2017. http://www.soumu.go.jp/main_content/000490303.pdf

［電通総研 08］ 電通総研、日本リサーチセンター（編）：世界主要国価値観データブック， 同友館，2008.

［内閣府 2016］ 内閣府: 人工知能と人間社会に関する懇談会 第 1 回 配布資料, 2016. http://www8.cao.go.jp/cstp/tyousakai/ai/1kai/1kai.html

［ホワイトハウス 2016］ ホワイトハウス: PREPARING FOR THE FUTURE OF ARTIFICIAL INTELLIGENCE, 2016. https://obamawhitehouse.archives.gov/sites/default/files/whitehouse_files/microsites/ostp/NSTC/preparing_for_the_future_of_ai.pdf

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

倫理的行動を促進するAIを社会で活用するための課題

Challenges for AI which promotes humans' ethical behaviors

福原 慶子[*1]
Keiko FUKUHARA

[*1] 名古屋大学大学院情報学研究科
Graduate School of Informatics, Nagoya University

In this paper, I consider challenges we would be faced with if an ethical Artificial Intelligence (AI) suggests ethical behaviors for humans. When a human agent follows an ethical AI and takes any action suggested by it, is the behavior or the agent ethical? Through tackling on this question, we will advocate a view of the relationship between humans and an ethical AI in which they are not separated a subject and an object but together constitute an agent as alliance. If we can design an ethical AI that not only teaches humans ethics but also learns it from humans, it would promote the more ethically developed society.

1. はじめに

1.1 背景

ソーシャルメディアなどインターネット上での反社会的な発言を、人工知能(AI)を使って発見しようとする研究がおこなわれている。たとえば、東フィンランド大学ではヘイトスピーチや暴力を示唆する書き込みを見つける機械学習モデルを考案している[Science Daily 2017]。国内では、クーロン株式会社が機械学習・自然言語処理・行動分析に基づいた AI が、書き込みの内容を自動的に分析し、必要と判断すればフィルタリングを施す「QuACS（クアックス）」というシステムを提供している [クーロン 2015]。

これらのように、AI を使って人々の言動の倫理的向上を目指す動きが国内外で進められる。個人には言論の自由が認められているとはいえ、度を越した差別や罵倒のヘイト表現をインターネット上でむやみに表明することは、やはり社会通念上好ましくない。このような書き込みによってユーザが精神的苦痛を被ったり他のユーザとの対立やトラブルへと発展してしまったりということは今や日常的に起きている。そのようなことが起きたときのサービス提供者の責任を考えると、ユーザの行き過ぎた放埒な振る舞いを律することは望ましく思われる。

だが一方で、AI によって行動が示唆されること、特にそれが倫理的な判断を伴っている場合の検討や議論はまだ途上である。倫理的な判断をどう実装するかといった技術面だけではなく、社会的・倫理的側面からも十分検討する必要がある。

1.2 本稿の目的

本稿では、人々の倫理的行動を促進するような AI を今後社会的に広く利用していく場合の課題について考察する。「人々の倫理的行動を促進する AI」と一口で言っても、その実現は方法も程度もさまざまだが、ここでは、我々人間の行動について倫理的に善いとみなされる行動を提案してくれるようなシステムを考える。たとえば SNS に投稿しようとした際に、それがヘイトスピーチに該当するかを判断して投稿を却下したり修正を要求したりするようなシステムがこれに相当する。悪いことを防ぐだけではなく、逆に善い行いを推奨するような応用も考えられるだろう。これ以降、本稿ではこのような機能を持つ AI を「倫理 AI」と表記する。

本稿では、倫理 AI を社会で使うためには何が必要かを検討し、人間と倫理 AI が一体となって倫理的行為をしているという考えを強調する。さらに、両者が相互作用的な関係であることで、より倫理的に発展していく社会を展望する。

1.3 本稿の構成

主張をするために、まず既存の倫理理論では限界があるということを示す(2 節)。次に、この限界を乗り越えるため、ピーター=ポール・フェルベークが支持する、人間と人工物が一体で道徳的行為を成すという主張を説明する(3 節)。最後に、この主張を適用したことから受ける利点と社会への展望について述べる(4 節)。

2. 既存の倫理理論の限界

倫理 AI がさらに開発され、インターネット上のより多くの場面で使われるようになると、悪意あるインターネットユーザによる悪辣な発言が抑えられていくことが予想される。社会全体としては、善い方向へと進んでいるように思えるが、現在でも既に、ビッグデータを AI で解析して、ユーザにとって最適と思われる商品や就職先や結婚相手を示すことに対して、自由が奪われていると感じる人もいる（[デュガン他 2017],[山本 2017]など）。さらに、内部のアルゴリズムがわからなければ、倫理 AI の出力結果に不信感を持つだろう。

こうした不信感の元では、倫理 AI に従っての行為は、自由な行動ではなくただ押し付けられていると考えられるだろう。この行為や行為者は倫理的行為・倫理的行為者ではないと考えるかもしれない。

そうした人々は、倫理学の一つの立場である義務論的アプローチから倫理 AI を評価しているだろう。このアプローチでは、行為の動機などの行為者の内面状態から、道徳的善悪が判断される[品川 2015, p.80]。義務論の代表的論者であるイマヌエル・カントによると、道徳的に振舞うためには、その行為者が自分で普遍的道徳法則を思い浮かべそれに従って行為を決定する自律性が必要である。そしてこうした自律性を持てることに、人間の尊厳があるという。逆に、自分の理性を働かせずに、自身の欲望や、他人や神の指示・命令に従って生きるのは他律である。

連絡先：福原慶子, fukuhara.keiko@g.mbox.nagoya-u.ac.jp

また別の立場である帰結主義では、倫理 AI に従っての行動は、結果が善ければ倫理的に善い行為であると結論する。なぜなら、このアプローチは義務論とは反対に、行為の善悪をその行為がもたらした結果から判定するためである[品川 2015, p.107]。倫理 AI に提示された行動は善いことでありそうすべきだという理解が行為者にはなかったにせよ、行動の結果が善にむすびついた、というところに着目する。

倫理 AI の指示に従った行為は倫理的に善いという考えを推し進めていくと、究極的には、行為者自身が倫理について何も考えなくなっても問題ないということになる。その状態にまでなってしまうと、ただ行動を倫理 AI に押し付けられ、強制されているだけになる。上に示したようなそれは自由な行動ではないと感じる人からは、倫理 AI を利用することへの理解がますます得られないだろう。

倫理 AI からの単なる押し付けを避けるために、複数の選択肢を提示させ、ユーザが自分の意思で行動を選択できるようにしようと設計者は考えるかもしれない。たとえば、SNS に投稿しようとした内容が、倫理 AI によってヘイトスピーチと判断されたとしよう。そのまま倫理 AI が投稿を禁止してしまえば、それは他者からの押し付けであるし、投稿者自身の自律性が侵害されている。だが、もし、投稿内容の修正あるいは取りやめをするか、それともそのまま投稿するかをユーザが選択することができるようになったらどうだろうか。これならば投稿者の意思を反映する余地がある。選択の見せ方として、[セイラー他 2009]で考えられているような、デフォルト状態を一番望ましいものにしておくというデザインも適用されるかもしれない。デフォルトでの選択はあるが、それが変更できないわけではない。選択肢として他の行為もまた、行為者自身の意思で選べる。

だが、完全に放任でも強制でもないリバタリアン・パターナリスティックなシステムやデザインを採用したとしても、与えられたものの中から選ぶというのはやはり倫理 AI、あるいはそのデザイナーやプログラマにより与えられた中での他律的な行動でしかない。

以上のように、倫理 AI に従っての行為あるいは従った行為者は倫理的であるかという問いを義務論・帰結主義からとらえようとすると、それぞれ倫理的ではない・倫理的であるという反対の答えを出す。そしてこの枠組みでとらえているうちは、我々は倫理 AI に従うか拒否するかのどちらかを選ぶことになる。

3. 人工物の道徳

ピーター=ポール・フェルベークの分析では、これまでの倫理学の主要な立場は、人間が主体であり、世界の事物が客体であるという主体と客体の二分法に基づいている。カントのような義務論は道徳的行為の主体に、帰結主義は行為の客体にそれぞれ焦点を当てている[フェルベーク 2015]。

フェルベークは、技術の倫理的問題はこうした主客二分法によっていては適切に扱えないと批判し、「倫理は人間-技術連合体の問題として考えられるべき[フェルベーク 2015, p.26]」という主張を擁護する。なぜなら人工物は客体にとどまらず、ときに人間の道徳的判断や行動に介入してくるからである。たとえば学校付近の道路や駐車場の敷地内にあるスピードバンプは、運転手にここでは減速しなければならないということを思い出させている。

同様に、倫理 AI も人工物の一つであり、人間と倫理 AI は、それぞれが主体と客体の関係ではなく、一緒になって道徳的行為をおこなう連合体であると考えてみよう。

倫理 AI は人間に行為を促すものであり、人間と一体になって道徳的行為者となる。ただし、倫理 AI はスピードバンプとは違い、機械学習によって促す行動を変化させる可能性がある。その可能性を広げるために、人間と倫理 AI が互いの倫理性を高め合うという関係を次に考える。

4. 利点と展望

我々人間は、最初から道徳や倫理を知っていたり、誰の手も借りずに自力で身につけたりしているわけではない。自律的に道徳的な行動をするには、外部に頼った訓練がある程度は必要である。小学校で道徳の教科書を読んだり、悪戯をして大人に怒られたり、浅慮な言動で自分自身がひどい目に遭ったり、といった経験を重ねて行為の善悪を学ぶ。そして理解して内在化していき倫理的行為者となるものである。

Microsoft が開発したチャットボット Tay は、言葉を教えてもらったが、それが倫理的に善いかどうかまでは教えられなかった。このシステムは Twitter を通じて機械学習で言葉を学習し、ユーザとコミュニケーションを図る目的で開発された。話しかけられた内容を繰り返すという方法で学習していったが、差別的な内容や汚い言葉遣いばかり覚えていき、すぐにそのアカウントは停止された。

これに陥らないためには、倫理 AI にも人間のほうから倫理を教えることができるインタフェースデザインも必要になる。人間と倫理 AI とが相互作用でき、倫理 AI が作り上げる倫理体系を永続化・固定化せず、変化可能にする。ただしそれは、恣意的に結果を変えるという意味ではない。倫理を教えるにあたり、設計者やプログラマのバイアスも入り込むことがありうるし、偏った教え方では結局 Tay の時と同じようになってしまう。したがって、倫理 AI に関する課題は、一部の技術者や有識者だけでなく、このシステムに関わる全ての人の関心事へと変えていかなければならない。

倫理が可変的であるということは、行動の指針としようとした場合に頼りないものに思われるかもしれない。だが、ここには一つ利点がある。社会が変われば倫理もまた変わるものである。倫理をアップデート可能にしておけるということは、いつまでも旧態依然とした悪い意味で伝統に縛られた価値観からの脱却をいくらか容易にするかもしれない。政治への参加、性別や人種に関わらない平等など、人類が自由を獲得してきた道筋のひとつは、そのようなものであった。もし、倫理 AI と人間の相互作用がうまくいったとしたら、倫理的善の発展を一層促す社会を構想することができるだろう。

5. まとめ

本稿では、倫理 AI を社会で利用するための課題を検討した。人間が主体であり人工物は客体であるという主客二分法を超え、人間と倫理 AI が一体となり倫理的行為者になるという考えを強調した。さらに、こう考えることで、人間と倫理 AI が互いに倫理を教えあうという相互作用を生み、善をより促進する社会を展望した。

参考文献

[デュガン他 2017] マルク・デュガン、クリストフ・ラベ、鳥取絹子訳:『ビッグデータという独裁者:「便利」とひきかえに「自由」を奪う』, 筑摩書房, 2017.

[セイラー他 2009] リチャード・セイラー, キャス・サンスティーン著、遠藤真美訳:『実践行動経済学：健康、富、幸福への聡明な選択』, 日経 BP 社 , 2009.

[フェルベーク 2015] ピーター=ポール・フェルベーク, 鈴木俊洋訳:『技術の道徳化：事物の道徳性を理解し設計する』, 法政大学出版局 , 2015.

[品川 2015] 品川哲彦:『倫理学の話』, ナカニシヤ出版, 2015.

[山本 2017] 山本龍彦:『おそろしいビッグデータ 超類型化 AI 社会のリスク』, 朝日新聞出版, 2017.

[クーロン 2015] クーロン株式会社:プレスリリース, https://www.quelon.co.jp/release_20150707_01/

[Science Daily 2017] Science Daily : New machine learning models can detect hate speech, violence from texts, https://www.sciencedaily.com/releases/2017/04/170412091222.htm.

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

AIはAI技術者を倫理的な設計に巻き込むことができるか？

Can AI Involve AI Engineers in Ethical Design Activities?

関口　海良 *1　　堀　浩一 *1*2
Kaira Sekiguchi　　Koichi Hori

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

*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

Although the importance of AI ethics has been increasingly recognized, it is hard to say that the results of the discussion is incorporated into research and development of AI technologies, so there is a gap between them. In this research, we provide an organic and dynamic AI ethics library with the aim of resolving this gap by supporting the practice of ethical design by AI engineers. Here, organic means that it deals with complex relations among different AI ethics discourses. And dynamic means that, in interaction with users, it dynamically adopts new issues and helps users think in their own contexts.

For example, AI ethics library visualizes a structure of each AI ethics discourse in a standard form, presents the distance and relationships among the discourses, and seamlessly connects them on the extension of AI technologies. Furthermore, AI ethics library is expected that the AI ethics side can also be reconstructed as a more practical one through the practices.

In this paper, with clarifying the framework of AI ethics by applying the ethical design theory, we introduce the overview and cases of AI ethics library and evaluate its effects.

1.　序論

AI 倫理の重要性は近年益々大きく認識されており，学会，財団，行政機関等によって多くの指針やケースが提供されている [IEEE 16, IEEE 17, FLI 17, AI ネ 17a, AI ネ 17b]．しかし，AI 技術者がこれら成果を自身の研究開発に取り入れているとは言い難く，両者の間にギャップが存在している．理由としては，AI 倫理は多様で情報量が多く，AI 技術者としては工学的な仕事と同時に AI 倫理と自身の研究開発との関連を理解するための時間的余裕がないためと考えられる．さらに時間が取れたとしても，提供される AI 倫理の議論は抽象度が高く，上記関連の理解には困難を伴うものと考えられる．

そこで本研究では，AI 技術者が自身の研究開発の延長線上に倫理的な課題を手軽に把握できるようにするための支援を行うこととした．またギャップを埋めることを通じて，倫理的な AI 及び社会的な価値をより一層実現することを目指す．

実現手段として筆者らは，有機的で動的な AI 倫理ライブラリを実装し，提供を開始した [Sekiguchi 17]．ここで有機的とは，AI 倫理ライブラリが異なる AI 倫理間の複雑な関連を踏まえて支援することを意味する．また動的とは，AI 倫理ライブラリが AI 技術者とのインタラクションの中で，AI 技術者が有する／生み出す新たな文脈を考慮しながら支援することを意味する．

具体的には，AI 倫理ライブラリは各種の AI 倫理の言説が持つ構造の違いを明確にしたり，AI 倫理の言説相互の意味的な距離を提示したり，また，AI 技術の延長線上にシームレスに AI 倫理を繋げるようなシナリオパスの推薦を行う．

さらに，AI 倫理ライブラリによって AI 技術と AI 倫理を繋ぐことを通じて，AI 倫理の側もより実践的なものへと再構築され得るものと考えている．

次章より，AI 倫理ライブラリの概要を紹介し，具体例を紹介した上で，上記点について評価を行う．

連絡先: 関口 海良，東京大学大学院工学系研究科航空宇宙工学専攻 知能工学研究室，kaira @ dfrome.com

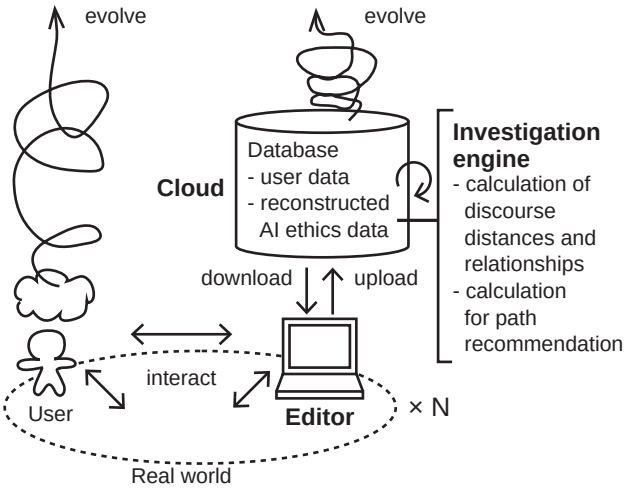


図 1: Overview of the system for the organic and dynamic AI ethics library

2.　AI 倫理ライブラリの概要

初めに，AI 倫理ライブラリの概要を述べる．

2.1　AI 倫理ライブラリの構成

AI 倫理ライブラリの構成を示したのが図 1 である．

図 1 が示す様に，AI 倫理ライブラリは大きく三つの技術から成る．エディタ（Editor），クラウド（Cloud）環境と，探求用エンジン（Investigation engine）である．

エディタは背景として倫理的な視点を提供しながら，編集作業の負荷を下げることでユーザが設計行為により没入できるようにする．次に，クラウド環境はアプリのインストールの手間を省くと共に，設計アイデアを端末に依存せずに管理可能とし，また，ユーザ間で容易に共有できるするようにする．最後に，探求用エンジンは AI 倫理や設計アイデア間の距離を計算

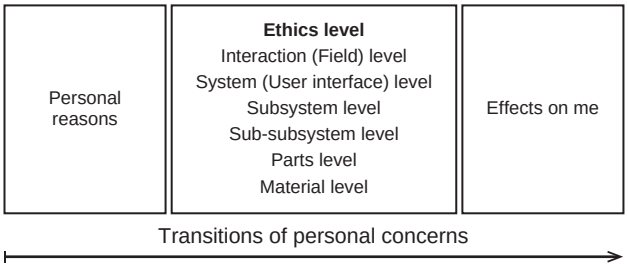


図 2: Redefined version of the hierarchical representation of artifacts [Sekiguchi 10]

する機能と，設計者の文脈において考慮すべきシナリオパスを計算する機能を備えている．

本研究では上記技術に基づき，AI 技術者と AI 倫理ライブラリとのインタラクションを通じて，AI 技術者が持つアイデアとライブラリに蓄積されたコンテンツが動的に発展（evolve）しながら，より倫理的な価値を踏まえた設計が生まれていくものと仮定している．

2.2 倫理的設計学の適用による表現の標準化

AI 倫理ライブラリに蓄積されるデータは倫理的な設計学に基づき標準化された形式に従う．ここで倫理的な設計学とは，筆者らが「倫理レベルからの設計」と呼ぶ視点と，「言説による設計」と呼ぶ方法から成るものである．

2.2.1 倫理的な設計のための視点：倫理レベルからの設計

「倫理レベルからの設計」とは，人工物の階層表現 [Simon 96, 吉川 81] を再定義したもので，工学的に倫理を扱えるようにしたものである．筆者らは，システムのレベル（System level）の上に，時間や流れ，変化を扱うインタラクション [中小路 07] のレベル（Interaction level）を位置付け，さらにその上に社会的な意味や価値を記述するレベルとして倫理レベル（Ethics level）を位置付けた [Sekiguchi 09]．

続いて，これら人工物の階層表現を客観的事象の軸とすると，設計者の主観的な視点の軸を設定することができる [Sekiguchi 10]．図 2 は再定義した階層表現の全体像である．

図 2 において，中央の面における縦方向が階層表現の軸で，全体の横方向が主観的な軸である．両者を直行させているのは，設計者が各レベルに対して知識やアイデアを同様に持つことができることと対応させている．また設計者にとっての時間推移を考えることで，個人的な理由（Personal reasons）と，個人としての影響（Effects on me）の二つの面を階層表現の両側に分けて配置することができる．

関連する議論として，JSAI2017 の公開討論にて江間は「倫理と社会の（ざっくりした）関係」を「研究（者）倫理」,「AI の倫理」,「倫理的な AI」の三つに分類した [人工 17]．本研究との関連では，主観的な軸に関する議論が江間の研究（者）の倫理に対応し，階層表現における議論が AI の倫理に対応し，考察の対象となる人工物のひとつが倫理的な AI に対応する．

また，ELSI との関連では，E の Ethics は上述の通りであり，倫理レベルの主体のひとつとして文節されるのが S の Society である．L の Low はそれら倫理的な意味や価値を実現ないし制約するための人工物として位置付けられる．

2.2.2 倫理レベルからの設計のための方法：言説による設計

「言説による設計」に関して最も重要な特徴は，人工物が生み出す変化をつなげて記述する点である．図 3 はこの記述を可視化したイメージである．

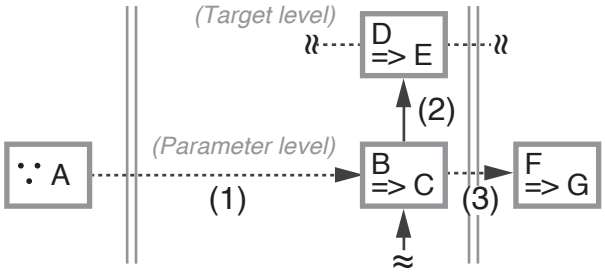


図 3: Visualization of the grammar of design with discourse: (1) Since A is a personal reason, I/we generate a design that B will change to C in the hierarchical representation of artifacts, (2) If B is changed to C at the parameter level, then D will change to E at the target level, (3) If B is changed to C, then F will change to G as the effects on me [Sekiguchi 10]

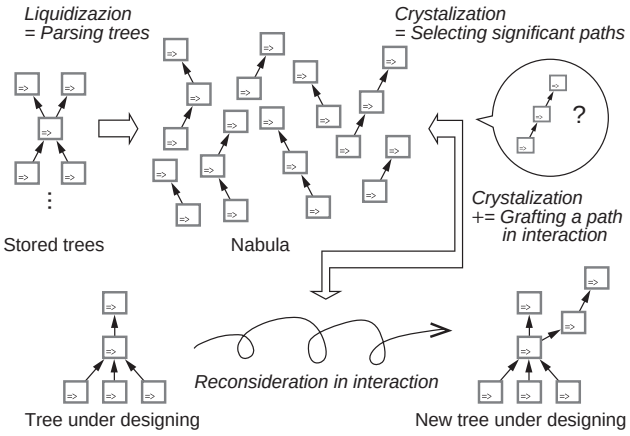


図 4: Overview of the approach for the path recommendation based on knowledge liquidization and crystallization

図 3 に示す通り，設計は三種類の記述から構成されるものとしている．

関連研究との位置付けでは，Knowledge graph の記述は Entity をノードとする [Nickel 16] のに対して，筆者らは Entity の Attributes の変化をノードとしている．倫理的な設計を扱う記述法としてはスピーカーマンのものがあるが，これは客観的な軸と主観的な軸の区別をしていないため，サイモンや吉川らの階層表現等の工学的な視点を生かせていない [Spiekermann 16]．

2.3 知識の液状化・結晶化モデルの適用

創造活動を支援するに際して，AI 倫理ライブラリは知識の液状化・結晶化モデルを適用している [Hori 04]．このモデルでは，知識は静的に蓄積されるものではなく，人と AI がインタラクションをする中で新たな文脈に応じながら動的に発展していくものと考える．AI 倫理ライブラリの中でこれを最も陽に取り入れているのがシナリオパスの推薦である．図 4 はそのアプローチの概要である．

設計者は手元のツリー内のひとつの記述をクエリとして，蓄積されたパスの中から類似したものや発散させる様なものの推薦を受ける．そして，そのインタラクションの中で設計者の視点や思考，設計アイデアが更新される．さらにこれら新しい設計アイデアが保存されるとデータベースも更新され，推薦候補群も更新されることになる．以下，これが繰り返される．

表 1: Overview of Stored Active and Public Trees

Tag	Document	Details	N
EAD	Ethically Aligned Design	Principles of Version 1	4
EAD2	Ethically Aligned Design	Principles of Version 2	5
AAP	Asilomar AI Principles	Ethics and Values	14
RDP	AI R&D Guidelines	Principles	10
RDU	AI R&D Guidelines	Use cases	10
ML	Machine Learning	Overview of the algorithm	5
EIT	Ethical IT Innovation	RFID case	1
OTH	Others	Authors' design etc.	5
			54

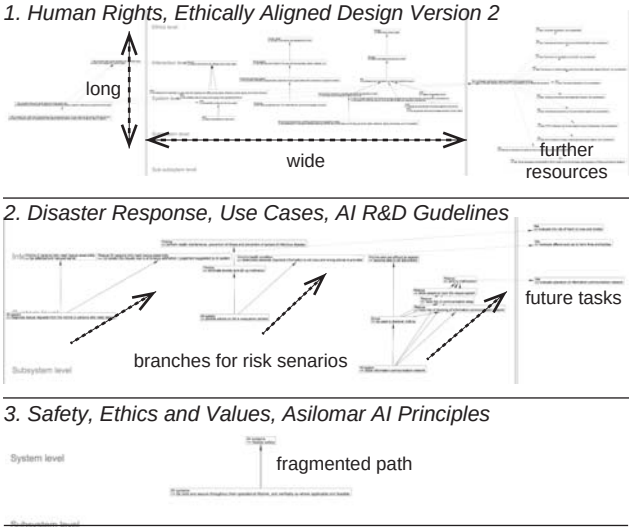


図 5: Visualized images of AI ethics discourses [IEEE 17, AI ネ 17b, FLI 17]

3. AI 倫理ライブラリによる支援の具体例

AI 倫理ライブラリによる支援の具体例を紹介する．実験は 2018 年 3 月 8 日時点で公開しているツリーを対象に，ローカル環境にて行なった．表 1 はデータの内訳である [IEEE 16, IEEE 17, FLI 17, AI ネ 17a, AI ネ 17b, Spiekermann 16]．

3.1 AI 倫理ライブラリによる表現例

初めに，AI 倫理の各言説が持つ構造を可視化した具体例として，三つのツリーを図 5 に示す．

ひとつ目の IEEE の原則（Principle）は広い課題を列挙しておりツリーは広くなり，また長く繋がる傾向がある．総務省から出ているユースケースは，リスクシナリオを併記する形になっているため上向きの分岐（branch）を持つことになる．アシロマの原則はひとつひとつは短文であるため，断片的なパスとなる．

重要なことは，各種の AI 倫理の言説が持つ構造の違いは，いずれも筆者らの倫理的設計学の枠組みの中における表現のされ方の違いとして理解できることである．

表 2: Results of calculation of distances and relationships of Trees ("R" at the top of the left column signifies the Rank)

R	Query tree	
	Human Rights, EAD2	Paragraph vectors, ML
1	Human Rights, EAD2	Paragraph vectors, ML
2	Human Benefit, EAD	Convolutional neural networks, ML
3	Human Values, AAP	RFID case, EIT
4	Ethics, RDP	Knowledge graph, ML
5	Safety, AAP	Education and Human Resource Development, RDU
50	Public Works and Infrastructure, RDU	Value Alignment, AAP
51	Retail and Logistics, RDU	Safety, AAP
52	Failure Transparency, AAP	Fix examples, AAP
53	Liberty and Privacy, AAP	Failure Transparency, AAP
54	AI Arms Race, AAP	Responsibility, AAP

3.2 距離と関係性の計算例

続いて，ツリー間の意味的な距離を計算した例として，Ethically Aligned Design の Human Rights [IEEE 17] をクエリとしたケースと，AI 技術の例として Paragraph vectors [Le 14] をクエリとしたケースの結果を表 2 に示す．

表 2 が示す様に，対象やカテゴリが同じ等，類似したツリーを提示できている．Human Rights のケースでは一般的な倫理的価値に関するものが近く計算されており，Paragraph vectors でも機械学習の手法が近く，特にニューラルネットワークに関するものが自身を除き一番上に判定されている．遠い方のツリーでは個別性が強くなる傾向があり，個別の解釈が必要となるが,「なぜそれが遠いか？」との解釈を促すことで，AI 技術者が AI 倫理を考えるきっかけになるものと考えられる．

3.3 シナリオパスの推薦例

最後に，シナリオパスの推薦例として，Paragraph vectors [Le 14] の記述をクエリとした例を図 6 に示す．

クエリの図中の記述（a）で,「Paragraph vectors => provide state-of-art results on several text classification」である．データベースには二千個程度のパス候補が存在しており，実装したクラスタリング手法及び評価関数に基づき推薦される．今回はトップ 10 位以内の結果の中から筆者が選択して「接木」した．まずは，クエリから上方に向かうパス（A）の推薦を受け，最上部の (d) を次のクエリとしてさらに上方へのパス（B）の推薦を受けた．この時点で，Paragraph vectors の研究は安心安全の実現を通じて，倫理レベルにおいて社会の自由（freedoms）の促進（e）に繋がる可能性が示唆される．さらに，今度はここから下方に向けて検索をすることでパス（C）によりガバナンスの枠組み（governance framework）が並列する解として示唆された．並列の関係は，元のアイデアとの類似点や相違点を考察することで理解を深めるきっかけとなる．

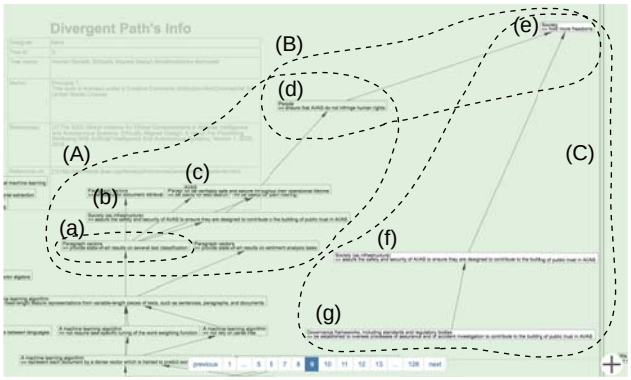


図 6: A case of the path recommendation: (a) Paragraph vectors => provide state-of-art results on several text classification; (b) Society (as infrastructure) => assure the safety and security of AI/AS to ensure they are designed to contribute to the building of public trust in AI/AS; (c) AI/AS => be verifiably safe and secure throughout their operational lifetime; (d) People => assure that AI/AS do not infringe human rights; (e) Society => hold more freedoms; (f)=(b); (g) Governance framework, including standards and regulatory bodies => be established to oversee processes of assurance and of accident investigation to contribute to the building of public trust in AI/AS [Le 14, IEEE 16, FLI 17]

重要なことは，論理の繋がりを示すことで容易には思い付かない様な長いパスや大きな広がりを関連付けられる様にし，高位のレベルを含めて暗黙とせず俎上に乗せていることである．

4. 結論と今後の課題

AI 倫理ライブラリによって，AI 技術者が自身の研究開発と AI 倫理を繋げることが容易になった．AI はこれを通じて AI 技術者を倫理的な設計に巻き込むことができる．さらに AI 倫理も工学的に議論の俎上に載せられたことから，AI 倫理の側もより実践的なものへと再構築される可能性が確認できた．

今後は，AI 倫理ライブラリの透明性を高めるため等，基盤技術の改善を継続すると共に，具体例を増やしながら，AI 倫理の専門家との対話も進めていく予定である．

参考文献

[AI ネ 17a] AI ネットワーク社会推進会議：報告書 2017 別紙 1 – 国際的な議論のための AI 開発ガイドライン案, http://www.soumu.go.jp/menu_news/s-news/01iicp01_02000067.html (2017)

[AI ネ 17b] AI ネットワーク社会推進会議：報告書 2017 別紙 3 – AI ネットワーク化が社会・経済にもたらす影響 – 先行的評価, http://www.soumu.go.jp/menu_news/s-news/01iicp01_02000067.html (2017)

[FLI 17] FLI, : Future of Life Institute, Asilomar AI Principles, https://futureoflife.org/ai-principles/ (2017)

[Hori 04] Hori, K.: Do Knowledge Assets Really Exist in the World and Can We Access Such Knowledge?; Knowledge Evolves Through a Cycle of Knowledge Liquidization and Crystallization, in Grieser, G. and Tanaka, Y. eds., *Intuitive Human Interfaces for Organizing and Accessing Intellectual Assets*, Lecture Notes in Artificial Intelligence, pp. 1–13, Springer (2004)

[IEEE 16] IEEE, : The IEEE Global Institute for Ethical Consideration in Artificial and Autonomous Systems, Ethically Aligned Design: A Vision for Prioritizing Wellbeing with Artificial Intelligence and Autonomous Systems, Version 1, http://standards.ieee.org/develop/indconn/ec/autonomous_systems.html (2016)

[IEEE 17] IEEE, : The IEEE Global Institute for Ethical Consideration in Artificial and Autonomous Systems, Ethically Aligned Design: A Vision for Prioritizing Wellbeing with Artificial Intelligence and Autonomous Systems, Version 2, http://standards.ieee.org/develop/indconn/ec/autonomous_systems.html (2017)

[Le 14] Le, Q. and Mikolov, T.: Distributed Representations of Sentences and Documents, in *Proceedings of the 31st International Conference on International Conference on Machine Learning - Volume 32*, ICML'14, pp. II–1188–II–1196, JMLR.org (2014)

[Nickel 16] Nickel, M., Murphy, K., Tresp, V., and Gabrilovich, E.: A Review of Relational Machine Learning for Knowledge Graphs, *Proceedings of the IEEE*, pp. 11–33 (2016)

[Sekiguchi 09] Sekiguchi, K., Tanaka, K., and Hori, K.: "Design with Discourse" to Design from the "Ethics Level", in Družovec, T. W., Jaakkola, H., Kiyoki, Y., Tokuda, T., and Yoshida, N. eds., *Volume 206: Information Modelling and Knowledge Bases XXI:*, Frontiers in Artificial Intelligence and Applications, pp. 307–314, IOS Press (2009)

[Sekiguchi 10] Sekiguchi, K.: The Fifth Rule of "Design with Discourse" for the Orthogonal Representation of Moral Concerns in Design from the Ethics Level, http://www.ethics-level.com/ (2010)

[Sekiguchi 17] Sekiguchi, K.: dfrome; website for Design FROM the Ethics level, https://www.dfrome.com (2017)

[Simon 96] Simon, H. A.: *The Sciences of the Artificial, Third Edition*, MIT Press (1996)

[Spiekermann 16] Spiekermann, S.: *Ethical IT Innovation: A Value-Based System Design Approach*, p. 220, CRC Press (2016)

[吉川 81] 吉川 弘之：一般設計過程, 精密機械, Vol. 47, No. 4, pp. 405–410 (1981)

[人工 17] 人工知能学会倫理委員会：2017 年度人工知能学会全国大会「公開討論人工知能学会　倫理委員会」開催報告（詳細版）, http://ai-elsi.org/archives/583 (2017)

[中小路 07] 中小路 久美代：インタフェースからインタラクションへ — ヒューマンインタフェース研究会（研究会千夜一夜）, 情報処理学会誌, pp. 202–203 (2007)

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

AIを活用したサービスにおけるELSI的観点の新たなガイドライン項目の抽出 -デジタルヘルスを対象とした検討-

Extraction of new guideline items from the view point of ELSI (Ethics, Legal, Social Issues) for service utilized AI –focus on healthcare area

福住伸一[*1],神野真理子[*1],稲垣香澄[*1],安浩子[*1],広明敏彦[*1],前田春香[*2],水上拓哉[*2],佐倉統[*2]
Shin'ichi Fukuzmi[*1], Mariko Jinno[*1], Kasumi Inagaki[*1], Hiroko Yasu[*1], Toshihiko Hiroaki[*1], Haruka Maeda[*2], Takuya Mizukami[*2], Osamu Sakura[*2]

[*1] 日本電気株式会社
[*1] NEC Corporation

[*2] 東京大学
[*2] University of Tokyo

The purpose of this study is to extract new guideline items about AI development by analyzing ELSI (Ethics, Legal, Social Issues) focuses on service utilized AI from the view point of service provider and service user. Use case (sample service) in healthcare area is considered and interview related to this service is carried out. From the result of the interview and analysis, five guideline items modified from original AI development guideline and seven new guideline items are extracted. To the future, valid verification of these items will be carried out through extension of target area and evaluation.

1. はじめに

AI技術の発展は目覚ましく、従来の単なる便利ツールではなく、AI が自律的に動き、判断し、社会(人間)に対して指示/示唆できるようになってくると考えられる。また、外見も含めて、AI(ロボット)と人との関わり合いのあり方も変わってきている[上野、2016]。これらのことが現実になったときに、技術的には可能である AI の指示/示唆を社会(人間)が受け入れられるようにするために、そこに存在する/もしくは今後生じてくるであろう、倫理的、法的、社会受容性の課題(Ethics, Legal, Social Issues: ELSI)[日経 2016, Kosinski 2018, など]をサービス提供者やサービス利用者の視点から抽出し、それを解決するためには技術開発としては何をすべきか、サービス提供としては何をすべきか、を明らかにする必要がある。

本研究では、ELSI 課題に対して AI 技術/AI 活用サービス提供側が取り組むべき方針を策定し、具体的プロセスや手法を開発するためのガイドライン項目を作成すること、を目標とする。今回は第一歩として、AI が埋め込まれたサービスをユースケースとして考案し、そこでの ELSI 課題を抽出して新たなガイドライン項目を導き出すことを試みた。具体的には、主に開発側の視点で書かれている総務省 AI ネットワーク社会推進会議が作成した「AI 開発ガイドライン」[総務省 2017]を対象とし、これを基準として新たな項目を検討することとした。ここで、検討する視点は、

- 開発側で考えるべきこと(AI 開発ガイドライン)
- サービス提供側で考えるべきこと

であり、特に、

- 社会(人)が AI と直接インタラクションするのか?
- 社会(人)が意識してインタラクションするのか?
- 社会(人)が意図せず AI からサービスを享受するのか?
- 社会(人)が AI を含んだ組織やサービスプロバイダーとインタラクションするのか?

といった利用者視点での課題を抽出することを目的とした。この概念図を図1に示す。最終的にはガイドラインが実際の開発の中で使えるようにプロセス化/手法化することを目指す。

連絡先:NEC 研究企画本部 福住 伸一
川崎市中原区下沼部 1753, s-fukuzumi@aj.jp.nec.com

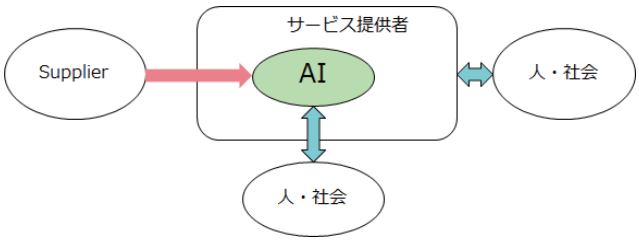


図 1 社会(人)と AI とのインタラクションの概念図

2. 予備調査

AI に関する ELSI 課題を抽出するにあたり、AI 技術に対してどのような課題を感じているのかについてヒアリングを実施した。その結果をまとめてサービス開発の観点からガイドライン項目化してみると、

- AI の判断に基づいた指示/示唆に対しての責任の明確化
- サービスとしての透明性
- AI が使われていることの明示
- 判断/意思決定者の明示
- 利用者へのメリット/デメリットの明示
- 「安心」基準の明示

とすることができる。

次章以降でサービス開発の視点、利用者視点でのガイドライン項目の抽出を試みるが、上記を参照にしつつ、実施する。

3. 対象領域と想定サービス

ここでは、対象領域をヘルスケアに絞り、あまり健康に対して意識をしていない人を対象とするサービスをユースケースとして検討した。

3.1 想定サービス作成 -AI による自動診断

今回のサービ対象は、「病院に行かない人」とした。このような人たちに対して自覚を促し、病院に行くようにするためのサービスを検討したところ、図2に示すようなユースケースが挙げられた。



図2　簡易サービスブループリント（社員の健康管理 AI サービス）

ここでは、体調が悪い社員が働き続けることの事業へのマイナス要因や早急な体制変更が可能となるといったビジネスインパクトがはっきりするため、会社として投資対象になりうるとの結論であった。このサービスについて、ELSI 課題を抽出するために、このサービスを利用しそうな方を対象にインタビューを実施した。

- インタビュー対象者
  - 病院に行きたがらない会社員（男性4名女性 1 名）
  - 職種：技術職4名（うち管理職1名）、事務職1名
  - 秘匿したい病歴は特にない（全員）

4. 既存の AI ガイドラインとの対応付け

インタビューの結果、当初の想定通り、総務省 AI 開発ガイドラインに相当する項目だけでなく、サービス開発・提供の視点から、新たな項目を抽出することができた。図3に今回抽出したガイドライン項目と AI 開発ガイドラインとの関係を示す。これより、新たに抽出されたサービス開発に関する項目は、まったく新しい項目と従来のガイドラインから視点を変えた項目の2種類があることがわかる。前者は、人がどのように AI が埋め込まれた社会と共存していくのか、といった内容である。後者は、言葉は従来のガイドラインと似ているが、技術の視点ではなく利用者側の視点で表現されている。さらに、予備調査から得られた、技術とは異なる視点での項目も挙がっている。このことから、AI 開発の、より包括的なガイドラインを整備するためには、サービス提供やユーザー側の視点を積極的に取り入れる必要があることが示唆される。

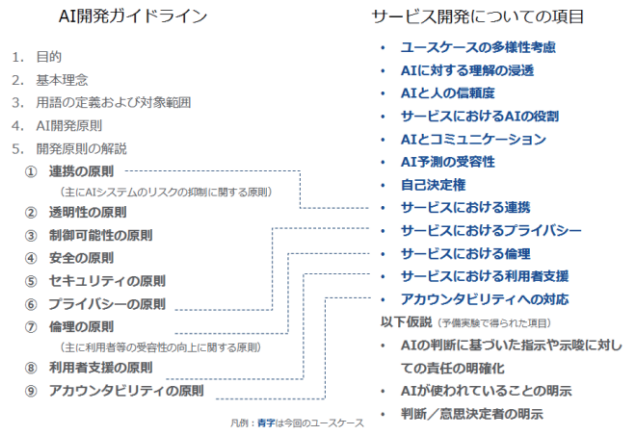


図3　既存の AI ガイドラインと新たな項目との対応付け

5. まとめ

今回、ヘルスケア領域を対象として新たなサービスをユースケースとし、それを実際に使うと想定したときの ELSI に関する課題をヒアリングし、その結果から、特にサービス開発に関する新たなガイドライン項目を抽出することができた。しかし、この結果は限定的であり、また、ヒアリング対象者も少数であるため、妥当性は十分には担保できていない。

今後は、幅広い対象者にヒアリングするとともに、新たなユースケースを想定して同様のプロセスを繰り返すことで、項目の妥当性を示していく予定である。

参考文献

[上野、2016]　上野裕子：海外から見た日本のロボット産業・技術、Global Angle、No. 124、2016.7

[日経 2016]　日本経済新聞：米マイクロソフトの人工知能、ツイッターで差別発言連発、https://www.nikkei.com/article/DGXLASGM25H5K_V20C16A3000000/, 2016.3.25

[Kosinski 2018]　Kosinski, Michal and Wang, Yilun: Deep Neural Networks Are More Accurate Than Humans at Detecting Sexual Orientation From Facial Images, Journal of Personality and Social Psychology. February 2018, Vol. 114, Issue 2, Pages 246-257.

[総務省 2017] AI ネットワーク社会推進会議　報告書、http://www.soumu.go.jp/main_content/000499625.pdf 総務省、2017.

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

IEEE「倫理的に調和した設計」を用いた議論の場とコミュニティの設計

Design dialogue and community to discuss IEEE *"Ethically Aligned Design"*

江間有沙[*1] Arisa Ema　長倉克枝[*2] Katsue Nagakura　工藤郁子[*3] Fumiko Kudo

[*1] 東京大学 The University of Tokyo　[*2] 科学ライター Science Writer　[*3] マカイラ株式会社 Makaira KK

This document reports the methodology and process of inter-disciplinary workshops involving various stakeholders to discuss IEEE *Ethically Aligned Design (EAD)* report. *EAD* report aims to move beyond the excessive fear and expectations associated with AI and increase innovation by creating ethically aligned designed AI. Authors organized the report items into 6 workshop series. The goal of our workshops is to understand the content of *EAD* and create a network among AI/IT researchers, social science and humanities researchers, industries, policy makers and other stakeholders.

1. はじめに

「今までは情報技術で倫理と言われていなかったのに，なぜ今，人工知能でこれほど倫理の議論がされているのか」

このような質問を受けることが多いが，情報技術倫理の研究は 1980 年代から存在する．それにもかかわらず「今更」と思われてしまうことからは，多くの方にとって情報技術の倫理や価値の議論が身近ではないこと，そして倫理の議論は技術開発の制約と見なされがちであることが再確認される．

技術の設計段階からその倫理的，法的，社会的な観点について考えていくためには，技術者にとっても倫理や価値の議論が自分事として考えられるような場や環境づくりが重要となる．そのため，技術に関する倫理や価値の「中身」の議論だけではなく，多様な人々を巻き込むという「プロセス」や，コミュニティ形成の方法についても実践と記録を残していくことが，重要である．

筆者らは，これまでも「人工知能と社会について考える場作り」として，様々な分野・業種の専門家を対象とした企画を行ってきた[江間 17a]．本稿では，IEEE が公開している報告書に関するワークショップを事例として，どのように異分野・異業種の専門家による企画を組織，運営しているかを紹介する．

2. IEEE「倫理的に調和した設計」とは

2016 年 12 月に The IEEE Global Initiative（The IEEE Global Initiative on Ethics of Autonomous and Intelligent Systems）が IEEE *Ethically Aligned Design*（「倫理的に調和した設計」）の第一版（以下 EADv1）を公開した．この報告書は知的な機械システム（Autonomous and Intelligent System）に対する恐怖や過度な期待を払拭すること，倫理的に調和や配慮された技術をつくることによってイノベーションを促進することが目的である．倫理そのものではなく，設計論や設計思想，それをどのように技術に落とし込めるかといった論点が整理されており，人工知能，法，倫理，哲学など他領域にわたる研究者，政策関係者，企業関係者の意見を集約して作成された．作成に関わった人は全世界で 250 人以上に上る．

続く 2017 年 12 月には第二版（EADv2）が公開され，以下の 13 項目から構成される[IEEE 17]．

1. 倫理的に調和したデザインをするための一般原則
2. 自律型知的システムに価値観を組み込む
3. 倫理的な研究や設計のための方法論やガイド
4. 汎用人工知能や人工超知能の安全性や便益
5. 個人データとアクセス制御
6. 自律型兵器システムの再構築
7. 経済 / 人道的課題
8. 法律
9. アフェクティブコンピューティング
10. 政策
11. 情報通信技術における伝統的倫理観
12. 複合現実
13. ウェルビーイング

EADv2 の公開と同時に，「自律的で知的なシステム」に関連する用語集（Glossary）委員会が組織された．分野も業種も違う人々が集まって作成している報告書だからこそ，定義を明確化する必要がある，というニーズから派生した委員会である．委員会では，アカウンタビリティ，データ，人権などの多義的なキーワードに対し，それぞれ(1)一般用語，(2)情報系，(3)工学系，(4)政策や社会科学系，(5) 倫理や哲学など，他領域での定義の整理が行われている．

今後，IEEE は約 1 年間のフィードバック期間を経て，2019 年に最終版となる第三版を公開する予定である．また，この EAD 報告書執筆陣を中心として，標準化を目指すプロジェクトが IEEE-SA（Standard Association：標準規格）に承認されている[江間 17b]．2018 年 3 月現在，IEEE-SA の P7000 シリーズとして 13 ワーキング・グループが標準化を目指しドラフトを作成中である．

3. ワークショップ概要

3.1 EADv1 ワークショップの概要

第 1 回のワークショップを筆者らは 2017 年の 4 月から 5 月にかけて名古屋と京都で 1 回ずつ，東京で 2 日間連続開催し，総勢 44 名の方にご参加いただいた．特設ウェブサイトを作成し(https://sites.google.com/view/ethically-aligned-design-ws/home)，案内を各種関連学会などのメーリングリストに流した．ウェブページでは報告書の日本語版概要と本文がダウンロードでき，参加者は報告書に目を通していただくことを条件とした．各回では毎回，報告書の概要や今後の方針についての概説があり，回によっては Skype で Executive Director の John C. Havens 氏や

Vice-Chair の Kay Firth-Butterfield 氏と繋いで直接，意見交換を行った．

ワークショップの目的は多様な意見をまとめてコンセンサスを得るのではなく，様々な視点を紹介することであった．そのため，ワークショップ報告書の執筆にあたっては，各項目に対して一文字ずつ追って精査していくというよりは，EADv1 全体やその背景に対する意見（総論）と，各項目に対する意見（各論）を整理し，提案を行った．ワークショップ参加者全員から修正や加筆をいただくプロセスを経た報告書は，現在ウェブ上に公開されている．

なお，各論点の発言者名を特定はしていないが，どのような属性の人の発言かは情報として重要であると考えたため，報告書では発言者コメントに属性を示した．属性の種類とワークショップ参加者の内訳は，アカデミアの情報系（11 名）アカデミアの人文・社会科学系 (12 名)，パブリックセクター(6 名)，インダストリー(5 名)，メディア(5 名)，その他(5 名)であった．報告書は 2017 年 6 月に米オースティンで開催された「自律システムの倫理に関するシンポジウム」（Symposium on Ethics of Autonomous Systems：以下 SEAS）に提出され，各項目の担当者へフィードバックされた．



図 1 EADv1 ワークショップの様子

3.2 EADv2 ワークショップの企画概要

EADv1 に対して全世界から寄せられたコメントを受けて，2017 年の 12 月に EAD の第二版が公開された．第一版から 5 項目新たに追加された 13 項目からなり，ページも第一版の 138 ページから約 2 倍の 266 ページとなった．

EADv1 ワークショップの反省として，(1) 少ない時間ですべての項目を扱うのが難しく表面的な議論になりがちであったこと，(2) 日本の具体的な事例などを埋め込むことができなかったこと，が挙げられた．そのため第 2 回ワークショップを開催するにあたっては，EADv2 の全 13 項目を読んだ上で，扱っているテーマが近い項目をオーガナイザ側で 6 つに再分類し（表 1），それぞれの項目について EADv2 を参照して話題提供をいただけるゲスト講師をお招きするという形式を採用した．

ゲスト講師は，各テーマに対し研究者やジャーナリスト，企業の方で，(1) 技術的なアプローチをされている方と，(2) 人文社会科学的なアプローチをされている方をそれぞれ招きした．また EADv2 を読み込んで解説を行っていただくのではなく，EADv2 を 1 つの指標（インデックス）と見なし，それに対して各話題提供者が知りえている情報や研究について具体的な事例を紹介していただくようお願いした．各回ともオーガナイザ側と話題提供者とで事前打ち合わせを行い，EADv2 に関する論点と日本の事例についてクローズドで議論も行った．

全 6 回の順番は，まずは自律型兵器や汎用人工知能（第 1 回），アフェクティブコンピューティングや複合現実（第 2 回）など技術的にイメージしやすい項目から開始し，そこから社会や倫理について議論するための方法論（第 3 回），法（第 4 回），基盤（第 5 回），最後に倫理・原則（第 6 回）といった抽象度の高いテーマへ進めていくこととした．

表 1 各回のテーマと項目

第 1 回 リスク	4. 汎用人工知能や人工超知能の安全性や便益 6. 自律型兵器システムの再構築
第 2 回 感情	9. アフェクティブコンピューティング 12. 複合現実
第 3 回 社会	3. 倫理的な研究や設計のための方法論やガイド 7. 経済 / 人道的課題 10. 政策
第 4 回 法	5. 個人データとアクセス制御 8. 法律
第 5 回 基盤	11. 情報通信技術における伝統的倫理観 13. ウェルビーィング
第 6 回 倫理・原則	1. 倫理的に調和したデザインをするための一般原則 2. 自律型知的システムに価値観を組み込む

また，本ワークショップは多様な観点を持つ人に参加してもらうべく，オーガナイザや話題提供者が所属している組織だけではなく，各種関連学会にもパートナーとして後援いただいているほか，それぞれのメーリングリストでも告知を行った．



図 2 EADv2 ワークショップの様子

4. おわりに

本稿を執筆している 2018 年 3 月上旬では第 3 回までが終了しており，今まで情報系と人文・社会科学系の研究者や企業関係者，政策関係者，学生などが参加している．また，各回の話題提供の内容とスライドはウェブに報告書が掲載されている．

全 6 回のワークショップ終了後には，全体を通しての報告書を日本語と英語で執筆する予定である．また，本ワークショップシリーズを通してどのようなコミュニティが形成され議論が継続されているのかについては，当日会場で議論を行いたい．

参考文献

[江間 17a] 江間有沙 他: 人工知能と社会について考える場づくりの実践，人工知能学会第 31 回全国大会予稿，pp. 4G2-OS-14b-3, 2017.

[江間 17b] 江間有沙：倫理的に調和した場の設計：責任ある研究・イノベーション実践例として，人工知能，Vol. 32, No. 5, pp. 694-700, 2017.

[IEEE 17] The IEEE Global Initiative for Ethical Considerations in Artificial Intelligence and Autonomous Systems: Ethically aligned design: a vision for prioritizing human wellbeing with artificial intelligence and autonomous systems, https://ethicsinaction.ieee.org/（2017）

Oral presentation | Organized Session | [Organized Session] OS-25

[3H2-OS-25b] [Organized Session] OS-25

Thu. Jun 7, 2018 3:50 PM - 5:10 PM Room H (10F Sky Hall)

[3H2-OS-25b-01] A Consideration on Anonymization of Personal Information to Establish Both Anonymity and Usability Based on Residuals

○Soichiro Morishita[1] （1. CyberAgent, Inc.）

3:50 PM - 4:10 PM

[3H2-OS-25b-02] A Study on the Ethical Aspects of Design Principles of Autonomous Robots from Sci-fi Movie

○Shigeyoshi IIZUKA[1], Chieko Takamori[2], Miwa Yamaura[3] （1. Kanagawa University, 2. AmidA Co., Ltd., 3. YAMAGATA INTECH Corporation）

4:10 PM - 4:30 PM

[3H2-OS-25b-03] Artificial intelligence and journalism ethics with a focus on "fake news"

○Fumiko Kudo[1] （1. Makaira KK）

4:30 PM - 4:50 PM

[3H2-OS-25b-04] “It’s Public, and also Private”: An Analysis of Flaming Fan Studies

○Hirotaka Osawa[1], Arisa Ema[2], Rena Saijo[3], Akinori Kubo[4], Nobutsugu Kanzaki[5], Minao Kukita[6], Ryutaro Ichise[7], Hiromitsu Hattori[8], Naonori Akiya[9], Takushi Otani[10] （1. University of Tsukuba, 2. The University of Tokyo, 3. Hokkaido University, 4. Hitotsubashi University, 5. Nanzan University, 6. Nagoya University, 7. National Institute of Informatics, 8. Ritsumeikan University, 9. Yamaguchi University, 10. Kibi International University）

4:50 PM - 5:10 PM

©The Japanese Society for Artificial Intelligence

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

残差に基づいて匿名性と有用性を両立させる匿名加工に関する考察

A Consideration on Anonymization of Personal Information to Establish Both Anonymity and Usability Based on Residuals

森下 壮一郎 *1
Soichiro Morishita

*1株式会社サイバーエージェント
CyberAgent, Inc.

In Japan, the revised Personal Information Protection Act is enacted in full force on May 30, 2016. It became possible to provide personal information to third parties under certain conditions such as anonymization without user agreements. However, in the case of no limitation on background knowledge of attackers, complete anonymization maintaining usability of data is impossible in principle. It is difficult to establish a rational anonymous processing standard. In this paper, an anonymization method based on residuals to establish both anonymity and usability is proposed. Moreover, it is shown that to apply anonymization with ambiguous purpose of use is meaningless.

1. はじめに

2016 年 5 月 30 日に全面施行された改正個人情報保護法（以下，法）において，匿名加工情報については一定の条件の下で本人の同意なしで第三者提供できるようになった．しかしながら個人情報保護委員会規則で定める基準は包括条項を含んでおり要件が不明瞭であることから，個人情報取扱事業者による匿名加工情報としての第三者提供および利用は進んでおらず，多くの場合で,「共同利用」や「業務委託」での利用になっている．これらも同意なしで利用可能な様態であるが，広くデータを利活用するという観点からは望ましくない．

一方で，攻撃者が持つ背景知識に限定がない場合，データの有用性を保ちながらの完全な匿名化は原理的に不可能であるので，合理的な匿名加工の基準を定めることは困難である．この難点を解消するには，背景知識を用いた個人の特定や情報の詳細化について法制などで制約を課すか，データの有用性について譲歩するかのいずれかの条件を満たす必要がある．前者のコントロールには限界があり，またリスク評価が困難である．一方後者は，実質的にデータの意味がなくなるという副作用は予想されるものの，データの利活用の目的を限定すれば，その条件下での最低限の効用は損なわない最大限の匿名化を施すことができる．以上の考えの下，本稿ではデータの有用性を保ちながらの個人情報の匿名加工の実施手順について検討する．

2. 匿名加工の基準および利用に関する指針

匿名加工の方法については「個人情報保護委員会規則」（以下，規則）で定める基準に従う必要がある〈法 36 条 1 項〉．しかしながらガイドラインでは例示があるのみで具体的な手法については確立されていない．法第 36 条第 1 項の個人情報保護委員会規則で定める基準（以下，基準）では，匿名加工で講ずるべき措置について 1 号から 5 号まで挙げている．国立情報学研究所の匿名加工情報に関する技術検討ワーキンググループは，基準の各号で示された措置について考察して「匿名加工情報の適正な加工の方法に関する報告書」としてまとめている [国立情報学研究所 17]．この報告書で，1 号から 4 号の措置については，曖昧性を排除して要件を定義した上で厳格な適用を求めている．5 号は包括条項であるので，この措置の要件については，匿名加工情報の有用性を損なわないことを重視して無限定の背景知識は仮定せず，特定対象項目（1 号の措置の対象で，特定の個人を識別することができる項目）の容易照合性について「通常の業務における一般的な方法で可能な状態」としている．そして，情報を結合する行為について特定対象項目の情報を増加や詳細化するようなものを識別行為禁止義務〈法 36 条 5 項〉違反と解釈している．

これは，前述の 2 つの条件のうちの「背景知識を用いた個人の特定や情報の詳細化について何らかの限定を施す」ことで合理的な匿名加工の基準を定めるときの難点を解消しようとするものである．これにより匿名加工の実施手順については明確になった．しかしながら識別行為禁止義務違反とならないような利用の形態については曖昧性が残っていた．

情報法制研究所のオンライン広告研究タスクフォースは,「オーディエンスターゲティング広告における匿名加工情報の利用に関する提言」（以下，提言）でオンライン広告における匿名加工情報の活用方法に関する指針を示した [情報法制研究所 17]．この提言では匿名加工の方法については議論していない．一方，報告書等で「識別行為禁止義務」違反とされている行為についての具体的な検討を行っており，適法となる形態（3.2.4 項）と違法となる形態（2.2.3 項）とをそれぞれ示している．

これらの報告書と提言，および他のプライバシー保護技術関連の教科書やガイドラインなどの匿名加工に関する文書では，プライバシーとデータの有用性とは常にトレードオフの関係にあると説明される．本稿ではこのトレードオフについて，報告書および提言の用語を用いながら検討する．

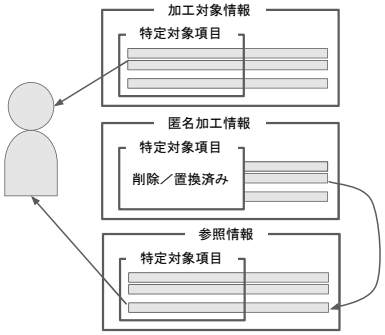
3. トレードオフについての検討

報告書では，匿名加工の対象となる個人情報を「加工対象情報」，基準の 1 号の措置の対象になる項目を「特定対象項目」，加工対象情報の外部にあって，それを参照することにより特定の個人が識別できる情報を「参照情報」と呼んでいる．これらの関係を図 1 に示した．

匿名加工情報には特定対象項目が含まれていないにも関わらず，参照情報に共通に含まれる項目によって，参照情報の特定対象項目と紐付けられて個人の特定に至っている．このような働きをする項目は，一般に準識別子と呼ばれる．無限定の背

連絡先: 森下 壮一郎，株式会社サイバーエージェント 秋葉原ラボ，morishita_soichiro@cyberagent.co.jp

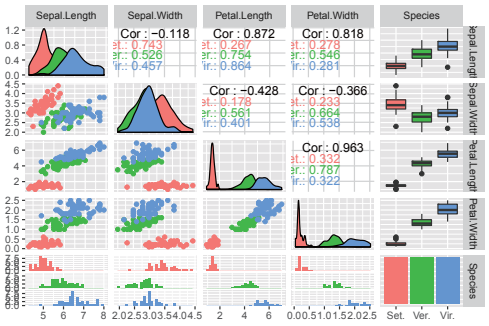
図 1: 参照情報による個人の識別



景知識（参照情報）を前提とするとき，当たり障りがないような項目からでも個人の特定に至る危険がある．

個人の特定に至らないまでも情報が詳細化される場合もある．わかりやすさのために，判別分析のテストデータとしてよく用いられる Iris データセット [Fisher 36] を仮想的に個人に関する情報と見なして詳細を述べる．図 2 にデータの分布を示す．作図には統計ソフトの R[R Core Team 17] を用いた．

図 2: Iris データセットにおけるデータの分布



これはアヤメの品種（species）と，がく（sepal）および花弁（petal）の長さと幅をそれぞれ計測したものである．品種ごと，すなわちクラスごとに各変量の平均が有意に異なり，また変量間にある程度の相関がある．個人に関する情報がこのように分布することは多い（例えば，出身学校と試験の各科目の成績など）．したがって，これを仮想的に個人に関する情報とみなすことに妥当性がある．なお，ここでは各品種における各変量の分布を攻撃者が背景知識の一部として持っているとする．

このデータセットから仮に品種の項目を削除したとしても，既知の分布から判別分析により品種を推定することは容易である．これは，背景知識に基づいて情報を詳細化することに対応する．統計情報として平均や分散が公知であることは多いので，この対応付けは妥当である．逆に，品種の項目を残して花弁の長さと幅の項目を削除したとしても，この 2 つの変量はクラス間分散に対してクラス内分散が小さいので，統計情報を基に一定の確かさで情報を詳細化できる．クラス間分散に対してクラス内分散が充分に大きくなる加工を施せば詳細化のリスクは小さくなるが，同時にクラスの違いが持つ情報量が小さくなる．これが匿名性と有用性のトレードオフの要因である．

4. 残差に基づく匿名加工

本稿では，以上で述べた状況下で有効な匿名加工の手続きとして，残差に基づく匿名加工を示す．例えば前述の Iris データにおいて，各クラスのクラス内分散共分散に基づいて正規化を行って，平均との差を残差として改めて特徴量とする．この操作によりすべての特徴量で平均が 0，分散が 1 になるので，詳細化のリスクはほとんどなくなる一方で，有用性は完全に失われるように見える．しかしながら実は目的によっては各クラスにおける残差が意味のある特徴量であることは多い．Iris データにおいては，品種ごとに平均が異なるところを補正したと考えることができる．すなわち，「この品種の中では大きい／小さい」という相対的な評価軸として変量を改めて定義したことになる（個人に関する情報でも，例えば各出身学校における相対的な成績の方にむしろ意味があるなどの場合がある）．なお削除対象の項目による分布の偏りを正規化できれば良いので，削除対象の項目が連続変数である場合には，例えば一般化線形モデルによる回帰分析における残差を用いることで同様の効果を得ることができる．

5. 議論

本項で述べた情報の詳細化の考え方に基づくと，元になる情報が法令上の個人情報でない（特定対象項目を含まない）場合でも，個人に関する情報であれば参照情報により個人が特定されたり情報が詳細化されたりするリスクがある．いずれにしても本稿で示した手順により，情報が詳細化されるリスクは軽減できるが，残差が有用な特徴量となりうるかは利用目的に応じて判断する必要がある．これはすなわち，「利用目的が曖昧なままに匿名加工を施すことにそもそもの意味がない」ことに他ならない．原則的には詳細化等のリスクについては識別行為禁止義務違反で処理すべきであるが，無目的なデータ提供における有用性を盾にした不充分な匿名化の妥当性は問われるべきであろう．なお例示の中に，統計量が参照情報となり情報が詳細化されるものがあった．そのような統計量を公知のものとしてよいのかという疑問も浮かぶが，本稿で示した手順に則ればその限りは問題ないことになる．これは，統計量への集計の入力は個人情報の利用としない現行法制と平仄が合っている．

6. おわりに

本稿では，攻撃者の背景知識を限定できない状況下での情報の詳細化のリスクと，それを充分に軽減しながらも有用性を保つ手法として残差に基づく匿名加工について述べた．今後は実施手順の詳細化を進める．

参考文献

[Fisher 36] Fisher, R. A.: The use of multiple measurements in taxonomic problems, *Annals of Eugenics*, Vol. 7, No. 2, pp. 179–188 (1936)

[R Core Team 17] R Core Team, : *R: A Language and Environment for Statistical Computing*, R Foundation for Statistical Computing, Vienna, Austria (2017)

[国立情報学研究所 17] 国立情報学研究所 匿名加工情報に関する技術検討ワーキンググループ:匿名加工情報の適正な加工の方法に関する報告書, `http://www.nii.ac.jp/research/reports/pd/report-kihon-20170221.pdf` (2017)

[情報法制研究所 17] 情報法制研究所 オンライン広告研究タスクフォース：オーディエンスターゲティング広告における匿名加工情報の利用に関する提言, `https://www.jilis.org/pub/pub_priv20171216.pdf` (2017)

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

SF映画からの自律型ロボットのデザイン原理導出における倫理的側面に関する一考察

A Study on the Ethical Aspects of Design Principles of Autonomous Robots from Sci-fi Movie

飯塚 重善 *1　高森 千恵子 *2　山浦 美輪 *3
Shigeyoshi Iizuka　Chieko Takamori　Miwa Yamaura

*1神奈川大学 Kanagawa University
*2株式会社 AmidA AmidA Co., Ltd.
*3YAMAGATA INTECH 株式会社 YAMAGATA INTECH Corporation

In the near future, it is thought that it is necessary to coexist a robot and a human being. In order for humans and robots to coexist within the same society, smooth communication and interaction between the two sides becomes essential. To that end, it is an important task to develop a user interface design, that is, an interface with weights placed on the user side. In order to derive the design requirement of the robot, we attempted to derive the robot design items from the science fiction movie as a material, considering the human psychology of the robot opposite the robot. As a result, in addition to existing design items for determining design and specification, arrangement of existing items for robot and new design items for robots were derived. In addition, 3 ethical design items that should be implemented in autonomous robot were derived.

1. はじめに

SF(Science Fiction) は，未来の世界を描いたエンターテインメントであるとはいえ，そこには，現実世界よりもはるかに進んだテクノロジーや未来的なインタフェースが登場する．現実世界の UI(User Interface) デザイナーからすれば，SF を現時点で何ができるかというインスピレーションやアイデアの対象として見ることができ，インタフェース，社会システム，人間関係等の多くの観点で考えさせられることが多い．「SF 物語に描かれた 21 世紀」と「現実の 21 世紀」の間にある隔たりは大きいという見方もあるが，現実に近い例として，Kinect が普及する前に公開された『マイノリティ・リポート』(*Minority Report*, 2002 年公開) におけるジェスチャー・インタフェースは，実際の UI デザインに大きな影響を与えたとされている．このように，SF からは，未来の人間生活，HCD(Human Centered Design) のあり方を考える上で多くのヒントが得られると期待できる．

そこで，SF 映画に描かれたインタラクションを，近未来のインタラクションや HCD 研究へ応用することは有効だと考え，HCD-Net(人間中心設計機構) では，SF 映画から未来に向けた HCD を検証することを目的とした研究グループ SF-SIG(Special Interest Group) を 2011 年に設置し，現在も活動中である．これまでの取り組みに関しては,『マイノリティ・リポート』と『アイアンマン 2』(*IronMan2*, 2010 年公開) を題材とした SF 映画の分析方法およびその結果について述べてきた [Iizuka 14, 飯尾 13]．さらに，それぞれの映画の中から特徴的なテーマをいくつか抽出し，そのテーマに沿って改めてその映画中のインタフェース，インタラクションについて検討し，そのあり方や今後の展開について議論をおこなってきた．また活動の一環として，やはり SF 映画を題材としてインタフェースをデザインにあたっての示唆を数多く挙げている『*Make It So*』[Shedroff 12] の翻訳をおこない，2014 年 7 月に『SF 映画で学ぶインタフェースデザイン ― アイデアと想像力を鍛え上げるための 141 のレッスン』[安藤 14] として出版している．

一方で，近い将来，ロボットと人間の共存が必要になると考えられ，21 世紀のキーワードの 1 つとして「人間とロボットの共生 (the symbiosis of humans and robots)」が掲げられている．今後ますます複雑化されていく人間社会において，セキュリティ，医療，介護，教育といったさまざまな場面でロボットとの協調・協業が必要になってくると考えられる．そして人間とロボットが同じ社会の中で共存していくためには，双方の円滑なコミュニケーション，インタラクションが肝要となってくる．そのような社会を実現するためには，人間がロボットに対して共感や親近感を持つことが不可欠であると考えられ，ロボットには，UI デザイン，すなわちユーザ側にウエイトを置いたインタフェースの開発が重要な課題となる [山岡 99]．しかしながら，開発する技術側からの提案は数多くあるものの，ユーザ視点とりわけ心理面に重点を置いた研究は少ない．パーソナルロボットの研究においても同様の傾向があり，工学系やコンピュータサイエンス系の立場からの研究が多くを占めているが，ロボットが家庭に受け入れられるには，ごく一般のユーザの視点に立ち，さらに心理面からも検証することが重要である．そこで筆者らは，将来的な人間とロボットの共存のため，双方の円滑なコミュニケーション，インタラクションを実現するためのロボットのデザイン要件を導出することを目的に，SF 映画を素材にして，ロボットと相対する人間の対ロボット心理を考察し，そこから，ロボットデザイン原則の導出を試みた．本稿では，筆者らのアプローチおよびその結果，特に自律型ロボットにインプリメントすべきものとして導出された倫理面でのデザイン項目について示す．

連絡先: 飯塚重善，神奈川大学，〒 259-1293 神奈川県平塚市土屋 2946，E-mail: iizuka@kanagawa-u.ac.jp

2. 分析アプローチ

2.1 ロボットのデザイン

人とロボットとの対話における心理 (人の，対ロボット心理) はさまざまな要因から影響を受ける．ロボットデザインに関する既往の研究として，日戸らは，日本・米国・ドイツの生活者を対象に，ロボットの導入に関するインターネット調査を実施し，受容性について考察している [日戸 16]．また，人型ロボットに対する不安や期待を日英間で比較した調査研究もある [Syrdal 13]．また，野村は文献 [佐藤 16] の中で，対ロボット行動がそうした要因とどのように関連しているかの仮説的フ

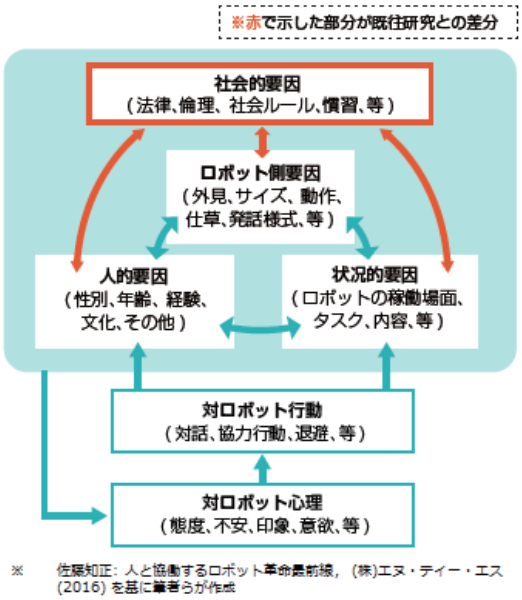


図 1: 対ロボット心理・行動に関する仮説的フロー

ローを提案している．この提案では，人側要因とロボット側要因，状況的要因が交互作用を起こしつつ，人の対ロボット心理に影響を与え，それが対ロボット行動に影響を与える流れを示しているのと同時に，これらの行動が結果として経験や文化等の人側要因およびロボットの応用場面等の状況的要因に影響を与えるという無限ループを想定している．そして，このループの構成要素がどのようなものであるか，さらなる研究が必要であると述べている．

これに対して，筆者らによる SF 映画鑑賞からは，この 3 つの要因に加えて，法律，倫理，社会ルール，慣習等もまた，人の対ロボット心理に影響を与えると考えられるシーンが見いだされたことから新たに「社会的要因」も必要となると考え，これを加えた交互作用を起こすとしたフローを提案するに至った（図 1）．

2.2 検討プロセス

筆者らは，SF 映画から，ロボットのデザイン原則を導出するにあたって，山岡が提唱している『70 デザイン項目』[山岡 14] をベースすることとした．『70 デザイン項目』とは，マーケティング・リサーチ，人間工学，認知科学，工業デザイン，ユーザビリティ工学，統計（多変量解析）などの観点を統合し，従来，直感に頼っていた製品開発のプロセスをできるだけ定量的な視点で見直して検討漏れがないようにするためのものであり．デザインや仕様を決めるために検討すべきスペックで，下記の項目がある．

- ユーザインタフェース関係 ：29 項目
- 感性デザイン関係 ：9 項目
- ユニバーサルデザイン関係 ：9 項目
- 安全性関係（PL）関係 ：6 項目
- ロバスト (頑強性) デザイン関係 ：5 項目
- メンテナンス（保守性）関係 ：2 項目
- エコロジーデザイン関係 ：5 項目
- その他・ヒューマン・マシン・インタフェース関係項目（5 デザイン項目）

以下に，筆者らによる今回の検討の手続きを示す．

1. 映画から，ロボットとのインタラクションシーンを抽出する
2. そのシーンにおける，登場人物の対ロボット行動を切りだし，その時の心理を洞察する
3. 「人側要因」,「ロボット側要因」,「状況的要因」，そして「社会的要因」を抽出する（当てはまるものがあるもののみ）
4. 解決すべき課題を導出する
5. 『70 デザイン項目』に対応付けする

3. 結果

図 2 に，実施結果イメージ（抜粋）を示す．なお，上記 2.2 節で示した手続きに際しては，予め図 2 中のフォームを用意し，本稿著者 3 名が各々で実施した．その後，3 者の結果を，議論しながら統合した．図 2 は，統合したものである．対象は，映画『アイ、ロボット』(*I, Robot*, 2004 年公開) とした．この作品は，アイザック・アシモフの短編集『われはロボット』[アシモフ 04] を原典にし，そのエピソードの一つのように映画化しようと練り直されたもので，人間と機械の関係にフォーカスしたテーマを内在している．

結果として，ロボットのデザインについて，課題解決のための要件として挙げられた多くの項目は,『70 デザイン項目』の中から当てはまる項目を見いだすことができた．また,『70 デザイン項目』の既存項目の応用（ロボット用のアレンジ）を提案するケースもある．例えば，強い感情表現を抑制し，人間に対して脅威・恐怖を与えないようにするために，既存の「4-1) 危険の除去」という項目を，そして，人間からロボットへの質問に対して，ロボットから質問で返さない（人間の間違い，驕りを指摘しない）よう，既存の「4-2) フール・プルーフ (fool proof) 設計をおこなう」という項目を，いずれも，コミュニケーション（対人インタラクション）に発展させた項目が必要になると考えた．

その一方で，対応する項目が見当たらないケースが生じてきており，これらに対しては，ロボットデザインに関する新規の項目を提案することとした．例えば,「人間への安全性，命令への服従，自己防衛」を目的とする 3 つの原則から成る『ロボット工学三原則』[アシモフ 04] というものが提唱され，その中に “第一条 ロボットは人間に危害を加えてはならない．また，その危険を看過することによって，人間に危害を及ぼしてはならない．” があるが，犯罪等から社会的秩序を保つため，全ての人間を対象にこの原則を適用できないケースが発生する．このようなケースに対しては，“警察（またはオーナー・法律等）が強制的に行動を制御できる権限を持つスイッチを持つようにする” といった項目が必要になると考えた．今回の試みでは特に，救助判断要件に子供・高齢者を優先する（優先度係数の実装を含む），ロボットが利他的行動に徹するための “倫理のインプリメント” が必要になると考えた．結果として，自律型ロボットにインプリメントすべき倫理的なデザイン項目として，以下に示す 3 つが挙げられた．

- 規則や法律の順守とプライオリティの判断
  - オーナーや，警察・司法・その他の第三者との状況に応じた判断をして対応を返す
- 救護・救助等の判断とプライオリティの判断
  - 複数の人命を救助する段階で状況に応じた対処や救護優先の判断をして対応を返す

No.	着目シーン	対ロボット行動 対話、協力行動、退避等	対ロボット心理 態度、不安、印象、意欲等	人的要因 性別、年齢、経験、文化、その他	ロボット側要因 外見、サイズ、動作、仕草、発話様式等	状況的要因 ロボットの稼働場面、タスク、内容等	社会的要因 法律、社会ルール、倫理、慣習等	課題解決のための要件	70デザイン項目への対応付け
1	FedExの配達専用ロボットが配達に来る	スプーナー：気配がないからか、驚く（呼び鈴を鳴らしていない？）	スプーナー：無視	スプーナー：ロボットを狭く思っていない	ボディに所属先特有の装飾を施し、所属先を明確にする。 頭部にはナンバーが記載されている。 長期間使用に耐えうる耐久性がある。 人物の同定が可能である。 停止状態は、まったくの静止状態ではなく、関節部分を全体的に揺らして、人間の動きを模した微妙な動きを再現もしくは直立姿勢のバランスを取っている。	呼び鈴を鳴らす直前の状態で、立ち止まっている。	ロボットは作業者として人間の生活に従事する	存在を予め知らせる (のが正しいわけでもない)	1-28）フィードバック 1-9）信頼感
2	ロボットとスプーナーが通りすぎまにぶつかった	スプーナー：何もしない	スプーナー：気にとめない	スプーナー：ロボットを狭く思っていない	人間かそうでないかを判別できる	人間のほうを向き、対話状態になる（人間が対話する・しないにかかわらず）	ロボットの対応を無視してもマナー違反にはならない	危険な指示でない限り、それに従う	2-5)エラーに対し寛容 ユーザがエラーを行った場合、バックアップするため何らかの対応が機械側からなされる
3	ロボットと人間が街中で会話している	スプーナー：何もしない 女性：会話している	女性：会話の相手として接している。ロボットのいる生活を受け入れている	公共の場所で人間とロボットが会話することが受け入れられている	相手のコミュニケーションしたい希望に沿える会話システムを搭載している。	対話相手をつとめる	ロボットは人間のコミュニケーション相手として機能する	なし	1-1）寛容性・柔軟性
4	ロボットがハンドバッグを持って走っているの	一般人：気に留めない スプーナー：追いかけて捕まえる	スプーナー：異常と感じる（泥棒かまたはロ	スプーナー：警察官で、ロボット不信	ロボットは、主人から指示（忘れものを持ってくる）を遂行する	ロボットが、手に荷物を持ち街の中を速度を出して移動		・ロボットが高速で移動する際、その目的を明示する	1-17）メンタルモデル 1-18）情報の多面的提供
5	「止まれ！」とスプーナーが叫ぶ	スプーナー：「止まれ！」とロボットに警告する	スプーナー：やはりロボットは時におかしなコ	スプーナー：ロボットに対する懐疑心を抱いて	動作（走る）を継続する 警官に制止を求められても応じない	警官の声を認識していない　または聞こえていない　または故意に無視が		人間（特に、警察官）の指示に対して反応する・回答	1-28）フィードバック オーナー＆警察＆司法
6	ロボットが緊急事態に対応するために走ったこと	スプーナー：とびかかって捕まえる	スプーナー：やはりロボットは時におかしなコトをする	スプーナー：ロボットに対する懐疑心を抱いている	無抵抗に倒れる。避ける動作はしない。 主人の所有物を保護しようと大切にする	バッグを手から離してしまったことに気づき、つかもうとする（＝重要なものであるという認識が	ロボットは主人の健康を守る（主人からの命令を必ず遂行する）	人間の危険な行動を察知し、怪我をさせないようにする	1-18）情報の多面的提供 1-26）メタファ （緊急性を示す）
7	「誤解させてすみません」と人間（スプーナー）に謝る	主人：誤ることはない、とロボットを諫める	主人：ウチのロボットは間違ったことはしていない（するはずがない）	主人：ロボットが盗難などするはずがない、そんなことを考える人間の方がバカである	人間の行動と思考を配慮しコミュニケーションが可能である。	「誤解させてすみません」と、人間に非がないことを伝え、謝る。	人間に不快な思いをさせないようにプログラムされている	ユーザーの思考の傾向や、習慣、文化を考慮する	1-29(ヘルプ 操作をサポートするため、最適なガイド、ヘルプ機能を提供する 1-1)寛容性・柔軟性とは異なる項目(もしかしてNEW) ロボットが人間のエラーを力バーし、また不快な思いをさ

図 2: ロボットデザイン項目抽出実施結果イメージ（抜粋）

- ユーザーの利益を損なうことをしない
  - ユーザーの判断とは異なる勝手な判断をしたり，虚偽の対応をしない

近年,「ロボット倫理学」と呼ばれる,「ロボットが備えるべき倫理」を考える新興の学問領域がある．これらは,「ロボット倫理学」における「ロボットの守るべき倫理」[久木田 09] に相当すると考えられる．

人間による倫理的判断ですら，必ずしも唯一無二 “絶対的な” の判断があるとは限らない．よって，“絶対的な” 倫理的判断を自律型ロボットにインプリメントすることは不可能かもしれないが，何らかの「倫理的な」基準をインプリメントする必要はあると考えられる．

その他，上記手法によって，さらに，UX(User Experience) の観点でのデザイン項目の必要性も挙げられた．

4. おわりに

将来の人間とロボットの共存のため，双方の円滑なコミュニケーション，インタラクションを実現するためのロボットのデザイン要件を導出することを目的に，SF 映画を素材にして，ロボットと相対する人間の対ロボット心理を考察し，そこから,『70 デザイン項目』をベースにしてロボットデザイン原則の導出を試みた．その結果,『70 デザイン項目』に当てはまる項目を多数見いだすと共に，既存項目のロボット向けアレンジ，そして新たにロボット向けに必要と考えられるデザイン原則を提案するに至った．自律型ロボットに関していえば，インプリメントすべきと考える倫理的なデザイン項目を導出することができた．今回は，1 作品のみを対象にしたアプローチではあったが，結果として，新たな項目の導出ができたことから，他の SF 作品についても同様のアプローチを試みることによって，さらなるデザイン原則の導出が可能になると考えられる．

なお本稿では，“自律型ロボット” を対象としてきたが，現段階の人工知能は，自律的に判断し行動しているように見えても，自ら「目的」を持って行動することはない，と言われているが [二木 17]，いずれは，人工知能を活用して自律的に活動することができるようになる可能性はゼロではない.「トロッコ問題」[Foot 67] と呼ばれる，有名な倫理学上の思考実験もあり,「人工知能学会 倫理指針」[人工知能学会 17] の第 9 条に,「人工知能への倫理遵守の要請」として「人工知能が社会の構成員またはそれに準じるものとなるためには、上に定めた人工知能学会員と同等に倫理指針を遵守できなければならない。」とあることからも，将来的には，ロボット（人工知能）自体が倫理を守る必要が生じてくる可能性が考えられる．

参考文献

[Foot 67] Foot, Philippa.: The problem of abortion and the doctrine of double effect, *Oxford Review*, vol.5 pp.5-15 (1967).

[Iizuka 14] Iizuka, S., Iio, J., Matsubara, H.: Reviewing the Role of the Science Fiction Special Interest Group via User Interfaces: the Case of Science Fiction Movies, *Industrial Applications of Affective Engineering*, pp. 233-240 (2014).

[Shedroff 12] Shedroff, N., Noessel, C.: Make It So: Interaction Design Lessons from Science Fiction, *Rosenfeld Media*, (2012).

[Syrdal 13] Syrdal, D. D., Nomura, T., Dautenhahn, K.: The Frankenstein Syndrome Questionnaire : Result from a Quantitative Cross-Cultural Survey, *Proc. 5th Int. Conf.Social Robotics*, pp.270-279 (2013).

[アシモフ 04] アイザック・アシモフ: われはロボット, 早川書房 (2004).

[安藤 14] 安藤幸央 (監訳): SF 映画で学ぶインタフェースデザイン ―アイデアと想像力を鍛え上げるための 141 のレッスン, 丸善出版 (2014).

[飯尾 13] 飯尾淳, 飯塚重善, 松原幸行: SF 映画に学ぶ近未来ユーザインタフェースのあり方, 人間中心設計, Vol.8(1)Vol.9(1) 合併号, pp.11-18 (2013).

[久木田 09] 久木田水生: ロボット倫理学の可能性, 京都大学文学部哲学研究室紀要:Prospectus, 11 (2009).

[佐藤 16] 佐藤知正: 人と協働するロボット革命最前線, (株) エヌ・ティー・エス (2016).

[人工知能学会 17] 人工知能学会: 人工知能学会 倫理指針, http://ai-elsi.org/wp-content/uploads/2017/02/人工知能学会倫理指針.pdf

[日戸 16] 日戸浩之, 谷山大介, 稲垣仁美: ロボット・AI 技術の導入をめぐる生活者の受容性と課題 日米独 3 カ国調査からの示唆, 知的資産創造, 24(5), pp.108-125 (2016).

[二木 17] 二木康晴, 塩野誠: いちばんやさしい人工知能ビジネスの教本, インプレス (2017).

[山岡 14] 山岡俊樹: デザイン人間工学 ―魅力ある製品・UX・サービス構築のために―, 共立出版 (2014).

[山岡 99] 山岡俊樹, 岡田明: 応用人間工学の視点に基づくユーザインタフェースデザインの実践, 海文堂 (1999).

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

人工知能と報道倫理:「フェイクニュース」を中心として

Artificial intelligence and journalism ethics with a focus on "fake news"

工藤郁子*

* マカイラ株式会社
Makaira KK

This document addresses the issue of "fake news" and artificial intelligence in terms of democratic values. Although some engineers are developing tools or measures against “fake news”, ethical indicators of the algorithms and desirable governance have not been clarified. So, the document tries to provide a suggestion for AI and journalism ethics.

1. はじめに

本報告は、人工知能(AI)と報道倫理について検討することを目的とする。今般、いわゆる「フェイクニュース」が投票結果などに重大な影響を及ぼしたとされ、社会問題化している。そのため、現在は「フェイクニュース」対策となるような技術と仕組みの開発・実証が模索されている。しかし、その評価軸となる倫理的指標(ethical indicators)や望ましいガバナンスの在り方は、必ずしも明らかにされていない。

そこで、まずは「フェイクニュース」現象とその対策について概観する。次に、「フェイクニュース」対策の難しさがどこにあるかを指摘した上で、報道の民主主義的価値について触れながら課題を再設定する。その上で、参照点としてのマスメディアの報道倫理を振り返りつつ、「フェイクニュース」対策に求められる倫理的指標やガバナンスについて示唆を導きたい。

2. 「フェイクニュース」と対策

2.1 「フェイクニュース」現象

本稿における「フェイクニュース」とは、主にインターネットに端を発する「虚偽」情報がソーシャルメディア等で拡散されて投票結果などに影響を及ぼすほど流通する現象をいう。「フェイクニュース」が社会問題となった契機は、2016 年の米国大統領選挙における一連のねつ造記事の拡散現象である。ロシア政府による情報工作、世論誘導、及び、トランプ陣営との癒着疑惑である「ロシアゲート」との関連で話題となっている[湯淺 2017]。

検察エンジンサービスの提供事業者やソーシャルメディアの運営事業者に対しては、ロシア政府のプロパガンダを担当したとされる企業「Internet Research Agency(IRA)」の広告出稿を防げず、「フェイクニュース」の拡散を助長したとの批判がある。例えば、Twitter 社の調査報告によると、IRA が設けたとみられる偽アカウントが 3814 件あり、関連する bot(機械による自動投稿プログラム)4 万 9000 件から約 140 万件のツイートが投稿されたとされている[Twitter 2017]。また、選挙期間中だけで 274,000 ドル(約 3000 万円)の広告費が利用された可能性がある。

2017 年 10 月、Facebook、Google、Twitter の 3 社は米連邦政府上院司法委員会の公聴会に招集され、対策を求められた。

2.2 「フェイクニュース」対策

こうした事態を受けて、「フェイクニュース」対策が技術的対応と社会的対応を組み合わせる形で進んでいる。

例えば、Twitter 社は以下のような対策を取っている [Twitter 2017] [Twitter 2018]。まず、IRA の偽アカウントをフォローしたり、コメントしたりしたユーザー67 万 7775 人に対して、偽アカウントをフォローしていた旨をメールで通知した。次に、偽アカウントが投稿していたツイートのサンプルを画像で紹介し、すでに削除した投稿がどのような内容だったかを示した。さらに、機械学習による偽アカウント検出技術の強化を進めるとの方針を示した。加えて、API ポリシーの変更も行い、同じ内容のツイートを大量のアカウントでツイートすることなどを禁止し、遵守しないアプリやアカウントの一時凍結するとした。

他方、Facebook 社は、当初、ユーザーから「フェイクニュース」であるとの通報を受け付け、提携メディアが真偽を検証するファクトチェックを実施し、「フェイクニュース」と認定された記事の横に「Disputed(問題あり)」という赤い警告アイコンを表示することで拡散を抑制しようとしていた [Facebook 2016]。ところが、警告表示によって、逆に「フェイクニュース」が正しいとの確信を強化してしまうことが確認されたため、2017 年 12 月、警告表示を廃止し、代わりに、真偽が問われている記事の横に関連記事(ファクトチェック済みの記事)を表示させる方針に切り替えた[Facebook 2017]。なお、2018 年 1 月には、ニュースフィードに表示する投稿の優先度を判断するアルゴリズムを変更し、友達や家族からの投稿を、企業やブランドの Facebook ページからの投稿よりも優先するとも発表している [Facebook 2018]。

3. 「フェイクニュース」と価値

3.1 「フェイクニュース」対策の難しさ

前述の通り、「フェイクニュース」対策として、削除対応、透明性報告書(transparency report)の公表、第三者機関による事実確認・検証記事の掲載、レイティング、関連記事の表示、AI を使った偽情報検出システムの利用などが検討・導入されており、試行錯誤を経ながら、より良い対策が模索されている。

しかし、「フェイクニュース」の受け手にこれらの対策は有効なのだろうか。仮に、正確性を重視しておらず、興奮や価値観の共有・強化、自分らしさの表明として「フェイクニュース」を消費しているとすれば、「正しい」情報を提示するというアプローチの意味は薄い。

また、報道ではなくエンターテイメントとしての「フェイクニュース」が求められているならば、それは「内心の自由」(憲法 19 条)、自己決定権(同法 13 条)、愚行権などとして取り扱うべきなのではないか。

さらに、「フェイクニュース」対策では、そもそも何が「フェイク」で何が「真実(truth)」かがわからないのではないか、という疑問もつきまとう(そのため本稿では「フェイクニュース」を鉤括弧付きで表現してきた)。ジャーナリスト教育においてしばしば訓示されるように、その時点において得られる最善の証拠(evidence)に基づいて一番確実な説明を目指すことしかできない。「真実」を判定することが(神ならざる存在には)できないとすれば、立場や見解の違いにすぎないこともあるだろう。そうすると、こうした「フェイクニュース」対策は、意思決定への「介入」という側面を意識しなければならない、ということになる。良かれと思ってしたことでも、それは後見主義的な介入であり、人が意識しないうちに操作されていることにもつながるからである。

3.2 課題の再設定

もっとも、「フェイクニュース」を消費する自由を認めるとしても、民主主義との関係で課題が生じることは否めない。民主主義の前提には、自由競争により低質な言論は淘汰されていくという「思想の自由市場」が機能するという発想がある。ところが、「フェイクニュース」が量産されれば、真偽を検証する「ファクトチェック」が今以上に追いつかなくなり、人間の認知限界を越える結果、「思想の自由市場」がゆがめられ、機能不全に陥ってしまうおそれがある。

もう一点の課題として、「フィルターバブル」と呼ばれる現象があげられる [Pariser 2011]。利用者の行動履歴などから AI やアルゴリズムが個人の嗜好を推定し、情報を選択的に提示することが進みすぎると、自分の好みの情報だけに泡のように取り囲まれるのではないかと懸念されている。自分と異なる見解に触れる機会が減り、他者とのコミュニケーションが困難になり、民主主義を支える基盤が弱くなると指摘されている。

上記も踏まえると、「フェイクニュース」そのものの真偽を問題とするのではなく、情報流通の方法など全体構造として問題を捉えた方が、より妥当と考えられる。

そして振り返れば、「フェイクニュース」に限らず、捏造記事、プロパガンダ、偏向報道、情報操作のような類似概念は従来から存在してきた。そこで、マスメディアが「フェイク」や「真実」とどう向き合ってきたかを参照してみたい。

4. 日本のマスメディアはどう対応してきたか?

4.1 報道倫理

従来、マスメディアは、「編集と経営の分離」によって、編集の独立を確保しつつ、報道倫理を遵守し、スクリーニングによる情報水準保障を行う機能が期待されてきた。すなわち、広告収入と購読料という経済力を背景にしながら、しかし、広告主とは距離をおきつつ、報道倫理に則って「事実」を編集・分析・解釈して国民に提供する機能を(一定程度)果たせていたとされる。なお、司法も、博多駅テレビフィルム提出命令事件などで、一定の役割・利益(「報道の自由」)を是認してきた。「報道機関の報道は、民主主義社会において、国民が国政に関与するにつき、重要な判断の資料を提供し、国民の『知る権利』に奉仕するものである。」(最大決昭和 44 年 11 月 26 日 刑集第 23 巻 11 号 1490 頁)との判示部分が、それを端的に示している。

そして報道倫理とは、ジャーナリズムの組織・活動に関わる自律的な社会規範(自主規制)であり、規律の対象となるジャーナリストが中心となって規範を定立するものをいい、他律的なマスメディア法(例えば放送法)とは区別される。日本新聞協会の旧「新聞倫理綱領」(1946 年)、「編集権声明」(1948 年)などが戦後日本では嚆矢とされ、「日本民間放送連盟放送基準」、「出版倫理綱領」、「雑誌編集倫理綱領」等の業界倫理規範が策定されている。また、1997 年に放送界共同の苦情対応機関として、学識経験者などで構成される第三者委員会「放送と人権等権利に関する委員会機構(現・放送倫理・番組向上機構(BPO))」が発足するなど、報道倫理規範の成文化とガバナンスの構築に努めてきた。

このように、いわばゲートキーパーを業として担ってきたマスメディアだが、技術の進展によって、情報流通を寡占し調整することが困難になってきている。情報の送り手と受け手の垣根は低くなり、報道倫理に拘束されない者たちも情報流通を担うようになったからだ。しかし、事業者としてまとまりのない「個人」に報道倫理を共有していくことは困難であるように思われる。おそらくそのために、新たなるゲートキーパーとして、検察エンジンサービスの提供事業者やソーシャルメディアの運営事業者が見出されつつある。よって、「フェイクニュース」対策として各種の自主規制が強化される点につき、間接規制や一種の検閲として機能するという側面にも注意を向けなければならない。

5. おわりに

本稿では、「フェイクニュース」対策について、個々の真偽というよりは、情報流通の全体構造として問題を捉えた方がより良いという前提のもと、マスメディアの報道倫理を参照し、いくつかの論点・示唆を指摘した。今後も、「フェイクニュース」対策に求められる倫理的指標やガバナンスについて網羅的な分析に向けて議論していきたい。

参考文献

- [Facebook 2016] Facebook. “News Feed FYI: Addressing Hoaxes and Fake News” https://newsroom.fb.com/news/2016/12/news-feed-fyi-addressing-hoaxes-and-fake-news/
- [Facebook 2017] Facebook. “News Feed FYI: Replacing Disputed Flags with Related Articles” https://newsroom.fb.com/news/2017/12/news-feed-fyi-updates-in-our-fight-against-misinformation/
- [Facebook 2018] Facebook. “News Feed FYI: Bringing People Closer Together” https://newsroom.fb.com/news/2018/01/news-feed-fyi-bringing-people-closer-together/
- [Pariser 2011] Pariser, Eli. *The filter bubble: What the Internet is hiding from you.* Penguin UK, 2011.
- [Twitter 2017] Twitter. “Update on Twitter’s Review of the 2016 U.S. Election.” https://blog.twitter.com/official/en_us/topics/company/2018/2016-election-update.html
- [Twitter 2018] Twitter. “Automation and the use of multiple accounts.” https://blog.twitter.com/developer/en_us/topics/tips/2018/automation-and-the-use-of-multiple-accounts.html
- [湯淺 2017] 湯淺墾道. “米大統領選におけるソーシャルメディア干渉疑惑.” 情報処理 58.12 (2017): 1066-1067.

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

公的であり私的：ファン研究炎上の分析

"It's Public, and also Private": An Analysis of Flaming Fan Studies

大澤 博隆[1], 江間 有沙[2], 西條 玲奈[3], 久保 明教[4], 神崎 宣次[5], 久木田 水生[6],
市瀬 龍太郎[7], 服部 宏充[8], 秋谷 直矩[9], 大谷 卓史[10], 駒谷 和範[11]

Hirotaka Osawa[1], Arisa Ema[2], Rena Saijo[3], Akinori Kubo[4], Nobutsugu Kanzaki[5], Minao Kukita[6],
Ryutaro Ichise[7], Hiromitsu Hattori[8], Naonori Akiya[9], Takushi Otani[10], Kazunori Komatani[11]

[1]筑波大学, [2]東京大学, [3]北海道大学, [4]一橋大学, [5]南山大学, [6]名古屋大学,
[7]国立情報学研究所, [8]立命館大学, [9]山口大学, [10]吉備国際大学, [11]大阪大学

[1]University of Tsukuba, [2]The University of Tokyo, [3]Hokkaido University, [4]Hitotsubashi University, [5]Nanzan University, [6]Nagoya University, [7]National Institute of Informatics, [8]Ritsumeikan University, [9]Yamaguchi University, [10]Kibi International University, [11]Osaka University,

Abstract: Online services make users' communication activities and content public. This online information has contributed to accelerating the creation cycle of user-generated content. Moreover, these services also allow researchers to utilize these online texts as a public source for easily analyzing human activities, also referred to as social sensing studies. However, we need to realize that there exists a controversial problem of privacy especially in the sensitive areas of creation, even though the content is public. This study tries to create new guidelines for online study using the case of the flaming of a study of female fan-fiction, which attempted to extract and filter sexual expressions using online fan-fiction novels as source. Researchers from the fields of both engineering and humanities, including law and ethics, discussed the violations in this case, and extracted ethical, legal, and social issues according to their specific areas of expertise.

1. Introduction

Internet technologies allow human communication to become much more tractable and observable. SNS and other networking services attract users to upload their activities online, eliciting social rewards. Maker Movements like Fablab, and the user generated content (UGC) movement also appreciate this form of shared information for enhancing the creation cycle of users supported by upload and feedback [1]. These online content platforms are a good research source, or hidden treasure, for evaluating and analyzing society's activities. Several researchers define online records of human activity as "social sensors" and have proposed utilizing them [2][3], while HCI studies have also started to use these online activities as data [4][5][6].

However, we also need to be careful that these public texts are not just open information for the research. The boundaries of public and private information are ambiguous, because users are not always aware of or have agreed to the fact that their content is to be openly used. Several researchers have voiced the criticism that the binarized notion of public and private is not appropriate in today's Internet environment [7][8]. In 2008, a group of researchers released profile data collected from Facebook accounts of US university students, leading to controversial discussion [9]. This mismatch between user and researcher requires new ethical guidelines for online studies [10]. Regarding the handling of information on the Internet, the Association of Internet Research Ethics Working Committee provides guidelines on human online activities [11].

Our viewpoint on the study by the abovementioned researchers is that not only user attribution, but also user content causes this kind of discussion on the border between public and private. These situations become critical in studies on UGC. Usually, every piece of published fiction is required to be separately accepted and criticized from the author's private attribution in a literature context. The author's privacy is protected by their name is anonymized by a pen name. However, these published contents may be regarded as private content, especially in sensitive fiction by minorities. Guidelines are starting to be created in the area of fan studies [12]. How

to design an online space where private and public spaces are mixed is an important issue in HCI, especially in the field of UGC where users request feedback by publishing content, and that feedback contributes to creation of further content. In such a scenario, it is a particularly difficult challenge to design a system that ensures privacy. In this study, we analyzed a case of flaming that occurred in response to a research study that analyzed fan fiction, which was posted at domestic congress of Japanese computer science society (in this paper, we called this society as society X for anonymization). We applied hybrid approach using both sociological method and online analysis. We created a team composed of researchers involved in computer science and literature, law, ethics, anthropology, etc.

2. Background

2.1. Sequence of the incident

The incident starts as follows. Researchers at University Y, including students, presented their fan study during Society X's annual conference, which is related to computer science. We refer to this day as day 1. The theme of the research is techniques used to filter obscene expressions from text. The core idea is as follows: Generally, words in text have multiple meanings including suggestions and implications, and some kinds of fiction use words generally reserved for obscene purposes for several other purposes. Thus, the word-based filtering approach commonly used as filtering technology is ineffective. In the abstract, the authors described that their controversial purpose of detecting obscene expressions was to eliminate information that might be harmful to young people. The authors used samples of secondary creation fan fiction, which were posted on Site Z, as a source text. They collected 10 samples from the site's ranked list, and manually analyzed expressions appearing in the text. Eight of ten fictions described homosexual relationships of male characters in famous Manga and Anime series (called Yaoi in Japan and slash fiction in U.S.[13]). The paper, in which the authors referred to the story title, author's account name, and link to the manuscript, was uploaded onto Society X's annual report page. At Society X's annual conference, organizers only perform brief checks on the title and abstract before uploading the entire paper online. In this case too, the same procedure was followed.

After the presentation, several participants at the annual conference posted short comments on Twitter. Next, online news media reported this incident based on the above tweets (day 2). Several tweets reported that eight of the authors deleted their novels from Site Z according to the effect of this flaming. Based on the above reactions and flaming, Society X organized an emergency meeting and decided to ban the paper. On the evening of day 2, Site Z commented on the fact that their site's intellectual property had been reprinted on the site and they contacted Univ. Y to confirm the fact. Based on the above facts, multiple media channels and more than one thousand users discussed this incident.

2.2. The Fan-fiction Environment in Japan

The ecosystem of subcultures including Manga, animation, and young novels in Japan are supported by fan actions including fan-fiction's so-called second creations [14]. In the fan-fiction movement, fans write and draw their original stories reusing characters and scenarios from the original works. They exchange their own works with other fans, mainly in the form of booklets called doujinshi. These doujinshi are shared mainly at large fairs called comic markets that have existed for more than 40 years [15].

The legal position of these fan-fictions is ambiguous. Unlike the copyright law in other countries like the United States, Japanese copyright law does not have a notion of fair use [16]. Thus, these fan creators' positions are not determined, and sometimes regarded as rip-off. On the other hand, copyright violation is defined by original creators in Japan, not by policies. If there are copyright violations, original creators need to sue them at first. In addition, these fan fictions sometimes include sexual content, and representing obscene expressions in public is considered illegal in Japan. For these three reasons, original creators simply ignore the doujinshi market. They do not want to sue fans, but they also do not permit fans' private works.

The people that participate in these doujinshi activities now number hundreds of thousands, and the boundary between public and private is transforming [17]. Many authors use doujinshi and comic markets as a target of drama in their story plots. Some publishers utilize these doujinshi markets as a place to find new creators of content, even for use in official anthologies. For example, vocal synthesizer creator Crypton permits users to create content using their characters except for sexual purposes [18]. Several original doujin-game (indies game)

communities also allow such kind of second creation [19]. Local trade in doujinshi has gone online, and some of those supporting this trade have started businesses. These situations make the boundary between official and fan fictions, and also between public and private works ambiguous.

3. Analysis by Discussion

This incident has many aspects to be discussed. To start the research, we organized an interdisciplinary team of humanities researchers (representation, ethics, philosophy, sociology, anthropology, science and technology society (STS)) and science and engineering researchers (artificial intelligence, natural language processing, multi-agent system (MAS) and human-agent interaction (HAI)). The researchers selected the five themes to be considered as key factors after 10 days of online discussion after day 1.

3.1. Ethical Issues

Online discussion of this case was confused on early days, with a mixture of legal, ethical, and other issues. Ethical issues cover a wider area than legal issues, and issues are different from the research field. We therefore had to separate the ethical and legal problems.

First, we confirmed that the ethical and moral standards and policies of research are different for each discipline, and that the obligation to present the source of the data and the protection of the information provider differ depending on the field to maintain the fairness of the research. The engineer emphasized the fact that the information regarding the source data, including the source, needs to be traced in order to guarantee the authenticity of data and the reproducibility of the research. In particular, it was pointed out that it is more important for stakeholders involved in the management of academic societies to seek clearly the quotation source of the data from an educational point of view when teaching students how to do research. An engineer involved in the operation of Society X pointed out that it is important to seek explicit reference from the data as the academic society is also a place of education that can teach students how to conduct research. However, Site Z needs to be registered with Site Z beforehand when browsing the contents. On Site Z, content intended for adults is zoned to prevent access by minors, so it is considered that the author does not want to disclose their work to many people. Therefore, the engineers said that it is important to anonymize the content as highly confidential data.

Even in the field of humanities research, the balance of both research ethics was diverse. However, in all areas, the case where research ethics needs to be revised to place more emphasis on protecting the interests of users is indicated. A literary researcher pointed out that even a published work is UGC, and it can be regarded as a right to criticize it. However, the researcher said that it is also important to consider the circumstances in which the research outcome affects the study subjects and becomes a mental hazard. On the other hand, from the anthropologist, the learning was that the policy is to minimize the influence of intervention in anthropology. In anthropology, as a rule, the name of the author and title of the work are generally pseudonyms. Anthropological research is carried out according to the rule that it does not describe the service name in some cases. From the standpoint of sociological researchers, there has been a case wherein information on Facebook leaked out under the name of sociological studies [9], and current sociological academic societies try to create a standard for dealing with such online studies.

3.2. Legal Issues

From the viewpoint of copyright law, it was discussed whether this research was cited or reprinted. Reprinting is not permitted in the terms of Site Z (Site Z expressed on Twitter that it views this paper as a reprint). However, Japanese legislation permits quotations that show the original, and if you do not show the original, there is a danger of being considered plagiarism. From the legal point of view, there is no legal problem with the authors presenting the original text. As a precedent, however, if there is a possibility of infringing the privacy of the other party, it is permitted to perform an appropriate anonymization in quotations.

3.3. Fan Studies Issues

The subject of research on this flaming is fan-fiction, a vulnerable community with a weak legal position. Anthropologists pointed out that if this case was an analysis of sexual fiction for men, there is a possibility that the flames would not have occurred. As a related factor, the problem of “representation of culture” in anthropology was cited. In the past anthropology, the problem arose that anthropologists deliberately distributed the values of cultures instead of local culture themselves. This is based on the imbalance in social power between academic researchers and local people. In the anthropology studies

from the 1980s to the 1990s, researchers were criticized for this problem, and as a result research in these fields has become impossible. Authors who make secondary creations are in a similar weak position. A similar problem seems to be the widely considered problem in UGC where the producer is an amateur. However, this paper is not created for the purpose of prescribing a specific culture. Suspicions were perhaps not appropriate in this case.

4. Conclusion

This study analyzes the case of the flaming of a study of female fan-fiction, which attempted to extract and filter sexual expressions using online fan-fiction novels as source. Researchers from the fields of both engineering and humanities, including law and ethics, discussed the violations in this case, and extracted ethical, legal, and social issues according to their specific areas of expertise. Based on the analyses, we hypothesize the structure of online discussion with three layers and propose new guidelines for user sensitivity to both private and public information.

5. Acknowledgement

This work was supported by JST RISTEX HITE.

REFERENCES

[1] K. Kuksenok, M. Brooks, and J. Mankoff, "Accessible online content creation by end users," in *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems - CHI '13*, 2013, pp. 59–68.

[2] D. T. Nguyen and J. E. Jung, "Privacy-preserving discovery of topic-based events from social sensor signals: An experimental study on twitter," *Sci. World J.*, 2014.

[3] V. Vasudevan, J. Wickramasuriya, S. Zhao, and L. Zhong, "Is Twitter a good enough social sensor for sports TV?," in *2013 IEEE International Conference on Pervasive Computing and Communications Workshops, PerCom Workshops 2013*, 2013.

[4] M. A. DeVito, D. Gergle, and J. Birnholtz, "'Algorithms ruin everything': #RIPTwitter, Folk Theories, and Resistance to Algorithmic Change in Social Media," in *Proceedings of the 2017 CHI Conference on Human Factors in Computing Systems - CHI '17*, 2017, pp. 3163–3174.

[5] A. Chauhan and A. L. Hughes, "Providing Online Crisis Information: An Analysis of Official Sources during the 2014 Carlton Complex Wildfire," in *Conference on Human Factors in Computing Systems*, 2017, pp. 3151–3162.

[6] M. Del Vicario, A. Bessi, F. Zollo, F. Petroni, A. Scala, G. Caldarelli, H. E. Stanley, and W. Quattrociocchi, "The spreading of misinformation online.," *Proc. Natl. Acad. Sci. U. S. A.*, vol. 113, no. 3, pp. 554–9, Jan. 2016.

[7] D. J. Solove, "Speech, privacy, and reputation on the Internet.," *The offensive Internet: Speech, privacy, and reputation.* 2010.

[8] R. Gross, A. Acquisti, and H. J. Heinz, "Information revelation and privacy in online social networks," in *Proceedings of the 2005 ACM workshop on Privacy in the electronic society - WPES '05*, 2005, p. 71.

[9] M. Zimmer, "'But the data is already public': On the ethics of research in Facebook," *Ethics Inf. Technol.*, vol. 12, no. 4, pp. 313–325, 2010.

[10] D. Elgesem, "What is special about the ethical issues in online research?," *Ethics Inf. Technol.*, vol. 4, no. 3, pp. 195–203, 2002.

[11] C. Ess and Associates, "Ethical Decision-Making and Internet Research," *Assoc. Internet Res. Ethics Work. Comm.*, 2002.

[12] TWC, "Transformative Works and Cultures: submissions," 2017. [Online]. Available: http://journal.transformativeworks.org/index.php/twc/about/submissions.

[13] M. McLelland, "The World of Yaoi: The Internet, Censorship and the Global 'Boys' Love' Fandom," *Aust. Fem. Law J.*, vol. 23, no. 1, pp. 61–77, Dec. 2005.

[14] T. Matsui, "The Diffusion of Foreign Cultural Products: The Case Analysis of Japanese Comics (Manga) Market in the US," *Society*, no. January, pp. 1–29, 2009.

[15] *Manga's Cultural Crossroads*. Routledge, 2013.

[16] T. G. Newby, "What's Fair Here Is Not Fair Everywhere: Does the American Fair Use Doctrine Violate International Copyright Law?," *Stanford Law Rev.*, vol. 51, no. 6, p. 1633, Jul. 1999.

[17] N. Lamerichs, "The cultural dynamic of doujinshi and cosplay: Local anime fandom in Japan, USA and Europe," *Particip. J. Audience Recept. Stud.*, vol. 10, issue, no. 1, pp. 154–176, 2013.

[18] M. Hamasaki and H. Takeda, "Social networks of an emergent massively collaborative creation community: Case study of hatune miku movie on Nico Nico Douga," in *CEUR Workshop Proceedings*, 2009.

[19] N. Hichibe and E. Tanaka, "Content Production Fields and Doujin Game Developers in Japan: Non-economic Rewards as Drivers of Variety in Games," in *Transnational Contexts of Culture, Gender, Class, and Colonialism in Play*, Cham: Springer International Publishing, 2016, pp. 43–80.

[3J1] [General Session] 7. Agent

座長:福田 直樹（静岡大学）

Thu. Jun 7, 2018 1:50 PM - 3:30 PM Room J (2F Royal Garden B)

[3J1-01] k-partition problem with uncertainty of agents' participation

Kazuki Nomoto[1], ○Yuko Sakurai[2], Yoshio Okamoto[3,4], Makoto Yokoo[1,4] （1. Kyushu University, 2. National Institute of Advanced Industrial Science and Technology, 3. The university of Electro-Communications, 4. RIKEN, Center for Advanced Intelligence Project AIP）

1:50 PM - 2:10 PM

[3J1-02] Proposal of traffic signal control system by multi agent using Deep Q-Network

○Yohei Kanzaki[1], Kikue Sato[1], Eichi Takaya[1], Ryo Pgawa[2], Yuta Ashihara[1,3], Satoshi Kurihara[1] （1. Keio University, 2. The University of Electro-Communications, 3. XCompass Ltd.）

2:10 PM - 2:30 PM

[3J1-03] Iterative Greedy Combinatorial Auction for Self Interested Multi-Agent Path nding

○Manao Machida[1] （1. NEC Corporation）

2:30 PM - 2:50 PM

[3J1-04] Estimation of people flow considering time delay

○Hiroshi Kiyotake[1], Masahiro Kohjima[1], Tatsushi Matsubayashi[1], Hiroyuki Toda[1] （1. NTT Service Evolution Laboratory）

2:50 PM - 3:10 PM

[3J1-05] Modeling Agents from the Perspective of Human Umwelt towards AI Safety

○Yosuke Fukuchi[1], Masahiko Osawa[1,2], Hiroshi Yamakawa[3,4], Michita Imai[1] （1. Graduate School of Science and Technology, Keio University, 2. Research Fellow of Japan Society for the Promotion of Science (DC1), 3. DWANGO Co., ltd Dwango Artificial Intelligence Laboratory, 4. The Whole Brain Architecture Initiative）

3:10 PM - 3:30 PM

©The Japanese Society for Artificial Intelligence

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

エージェントの参加が不確実な場合の k 分割問題

k-partition problem with uncertainty of agents' participation

野本 一貴 *1 Kazuki Nomoto　櫻井 祐子 *2 Yuko Sakurai　岡本 吉央 *3*4 Yoshio Okamoto　横尾 真 *1*4 Makoto Yokoo

*1九州大学 Kyushu University　*2産業技術総合研究所 National Institute of Advanced Industrial Science and Technology

*3電気通信大学 The university of Electro-Communications　*4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 consider a k-partition problem with uncertainty of agents' participation. In a traditional k-partition problem, all agent are guaranteed to join the assigned partitions. However, some agents cannot join them in more real-world problem settings. In such a case, some remaining agents have to move from the current partition to another partition to guarantee k-partitions. However, it requires some costs and loses efficiency. Therefore, we need to determine a k partitions by taking into account the uncertainty of agent's participation. In our problem setting, we assume that at most one agent is not going to participate. If one agent cannot participate, we allow one agent among the remaining agents to move from her current partition to another partition. We formalize our problem as an integer programing and show the results of computational experiment.

1. はじめに

効率的な提携を形成することは，人工知能やマルチエージェントシステムの研究領域において，重要な研究分野となっている．エージェントらは提携することで，個人では成し得ないことが可能になったり，より効率的に物事を行うことが可能となる．提携構造形成問題はエージェントの集合と任意のエージェントの部分集合 (提携) に対して提携値が与えられているとき，提携値の和が最大する，エージェントの分割 (提携構造) を決定する問題である [Sandholm 97]．最適な提携構造を見つけるためには計算量の課題があるため，マルチエージェントシステムの研究分野で盛んに研究が行われている [Rahwan 15]．

k 分割問題は提携構造形成問題の一形式であり，提携構造形成問題では任意の分割にエージェントを分割可能である一方，k 分割問題では提携数が k 個と固定された下で，提携値の和を最大化する分割を求める問題である．従来のほとんどの提携構造形成問題では，提携を組むエージェントの存在を保証している．数少ない例外として，文献 [Okimoto 17] で，エージェントの参加に対する不確実性を考慮した提携構造形成問題について議論されているが，k 分割問題を対象にしたものではない．

本研究では，エージェントの参加に対する不確実性を考慮した k 分割問題を検討する．エージェントらが実施すべきタスク数を事前に定められている状況は実世界でも数多く存在するため，このような状況でエージェントが不参加になることを検討する意義は大きい．本論文では，高々1 人のエージェントが提携に参加できない可能性が存在する場合の k 分割問題を整数計画問題として定式化し，商用ソルバーを用いた評価実験を示す．

連絡先: 野本一貴，九州大学大学院システム情報科学府，812-0395 福岡県福岡市西区元岡 744 番地，(092)802-3576，nomoto@agent.inf.kyushu-u.ac.jp

2. 問題設定

一般的な提携構造形成問題では，提携を入力として提携値を出力する特性関数と呼ばれる，ブラックボックスの関数 (オラクル) により与えられることを仮定する．特性関数を表記するためには，エージェント数を n とすると $O(2^n)$ の表記量が必要になる．そのため，特性関数を用いずに，問題を表現する簡潔記述法の提案も提携構造形成問題では重要な研究課題の一つである [Ieong 05, Conitzer 06]．本論文では，エージェント間の関係性をグラフで表現する簡略な記述法の下で，問題を表現する．

問題を重み付き無向グラフ $G = (V, E)$ で表現する．ノード集合 V はエージェント集合であり，各ノードはエージェントを示す．単独提携の提携値はノードの重みとして表現する．枝集合 E に含まれる枝は正の値の重みを持つ重み付き枝である．重みは，2 つのノードが示すエージェントらが同じ提携に入ることでシナジーが生じることを示す．本論文では，全てのシナジーは非負の値とする．シナジーがゼロの場合，そのエージェント間に枝は存在しない．

重み付き無向グラフが与えられたとき，枝の重みが最大化されるように，ノードを k 分割する．各分割には少なくとも 1 つのノードが含まれていなければならない．さらに，高々1 名のエージェントが参加しない可能性があり，実際に参加しないエージェントが出てきた場合，k 分割を維持する/提携値の和をより良くするために，1 エージェントを他の提携へ移動することができるとする．

例 1 4 人のエージェントが存在するとする．このとき，図 1 に示すように，任意の 2 エージェント間にシナジーが存在するとし，各エージェントの単独提携の提携値は 0 とする．例えば，エージェント 1 とエージェント 2 の 2 人提携の場合，その提携値は 4 である．

さて，タスク数を $k = 2$ としたとき，最適な提携構造は $\{1, 2, 3\}$ と $\{4\}$ に分割した場合であり，その値は 25 である．これが一時的な提携構造となる．

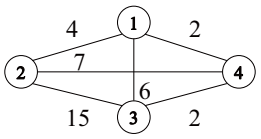


図 1: エージェント間の関係

例えば，エージェント 4 が不参加となった場合，提携数が 1 個のみとなり，残りの 3 エージェントで 2 個の提携を作る必要がある．この例では，エージェント 1 が今の提携から離れ，新たな単独提携を作ることとなる．よって，実際の提携構造は $\{1\}$ と $\{2,3\}$ となり，値は 15 である．一方，全員が参加した場合，先に求めた提携構造が実際の提携構造となる．

3. 整数計画問題としての定式化

本章では，整数計画問題として定式化を行う．この整数計画問題を解くことで，エージェントがいなくなる可能性を考慮しない場合の最適な提携構造を得ることができる．実際にいずれかのエージェントが参加しないと判明した場合，残ったエージェント集合のうち，1 名を移動させることができる．各エージェントが他の提携 (タスク) に移動したときの値を算出し，最も高い提携値の和が得られる提携構造が実際の提携構造となる．この操作は $k(n-1)$ 回の繰返しで実施されることになる．

まず，記法の定義を行う．$i = 1, \ldots, n$ $(n \geq 2)$ をエージェントとする．$j = 1, \ldots, k$ $(k \geq 2)$ をタスクとする．$w_{i,i'}$ をエージェント i と i' の間の枝の重みとする．$x_{i,j} \in \{0,1\}$ をタスク j をエージェント i に割り当てるかどうかを決める決定変数とする．$y_{i,i',j} \in \{0,1\}$ をエージェント i と i' が同じタスク j に割り当てるかどうかを示す決定変数とする．

この記法を用いて下記の通り，目的関数と制約条件を定める．

$$\max \quad \sum_{i=1}^{n} \sum_{i>i'} \sum_{j=1}^{k} w_{i,i'} y_{i,i',j}$$

$$s.t. \quad \sum_{j=1}^{k} x_{i,j} = 1 \quad \forall i \tag{1}$$

$$for\ each\ edge\ (i, i'(>i)),$$

$$y_{i,i',j} \leq x_{i,j} \quad \forall j \tag{2}$$

$$y_{i,i',j} \leq x_{i',j} \quad \forall j \tag{3}$$

$$x_{i,j} + x_{i',j} \leq y_{i,i',j} + 1 \quad \forall j \tag{4}$$

$$\sum_{i=1}^{n} x_{i,j} \geq 1 \quad \forall j \tag{5}$$

各制約条件について，式 (1) は各エージェントが 1 つのタスク (分割) に参加することを示す条件である．式 (2) から (4) はエージェント i と i' に同じタスクが割り当てられた場合，目的関数に $w_{i,i'}$ が足されることを操作する条件である．式 (6) は少なくとも 1 名のエージェントが各タスクに割り当てられることを示す条件である．

本論文では，エージェントの不参加を考慮せずに一時的な提携構造を求め，不参加が分かった後に，残りのエージェントを動かすという手法を紹介した．厳密な手法として，提携構造を求める際に，各エージェントが不参加になる確率を考慮し，1 名のエージェントが不参加になった場合に他のエージェントを移動させることも制約条件とした下で，提携値の和の期待値を最大化する提携構造を求めるという手法もある．紙面の都合上，本手法の説明は割愛する．

4. 評価実験

本章では，商用ソルバー Gobi 7.5.0 を用いた評価実験の結果を示す．利用した計算機について，OS は Ubuntu 16.04 LTS, CPU は Intel Xeon E5-2680v4 @2.40GHz プロセッサ × 2 基, メモリは 128GB である．

実験の問題設定は，エージェント数が 7，タスク数は 3，2 つのノード間に存在する枝の発生確率を 0.5，各枝の重みを $[1.0, 100.0]$ の範囲で一様分布に基づいて決定する．また，各エージェントが不参加になる確率を $[0.00, 0.01)$ の範囲で一様分布に基づいて与える．この問題設定の下で 100 インスタンスを実行した．

表 1: 実験結果

不参加のエージェント数	インスタンス数	平均実行時間 (ms)
0	98	24.9
1	2	37.0
		25.1

表 1 に不参加の参加数に応じた平均実行時間を示す．不参加のエージェントが存在する場合，残りのエージェントを移動させる操作が必要なため，計算時間が増加している．また，得られた解の品質であるが，どのエージェントが参加するかが決定された後に得られた最適な提携構造と比較して，本手法では，不参加のエージェントがいない場合は最適な提携構造が得られているのは自明である．また，不参加のエージェントがいる場合でも，本手法では最適な提携構造を得ることができた．

5. おわりに

本論文では，高々1 人のエージェントが提携に参加できない状況が存在する場合の k 分割問題を整数計画問題として定式化し，評価実験を行った．様々な問題設定での評価実験等が今後の課題として挙げられる．

参考文献

[Conitzer 06] Conitzer, V. and Sandholm, T.: Complexity of Constructing Solutions in the Core Based on Synergies Among Coalitions., *Artificial Intelligence (AI)*, Vol. 170, No. 6, pp. 607–619 (2006)

[Ieong 05] Ieong, S. and Shoham, Y.: Marginal contribution nets: a compact representation scheme for coalitional games, in *Proceedings of ACM EC*, pp. 193–202 (2005)

[Okimoto 17] 沖本 天太, Schwind, N., 平山 勝敏, 井上 克巳, Marquis, P.: 不確実性を考慮した提携構造形成問題に関する一検討, 第 31 回人工知能学会全国大会 (2017)

[Rahwan 15] Rahwan, T., Michalak, T. P., Wooldridge, M., and Jennings, N. R.: Coalition structure generation: A survey, *AI*, Vol. 229, pp. 139–174 (2015)

[Sandholm 97] Sandholm, T. and Lesser, V. R.: Coalitions Among Computationally Bounded Agents, *AI*, Vol. 94, No. 1-2, pp. 99–137 (1997)

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

Deep Q-Network を用いたマルチエージェントによる交通信号制御システムの提案

Proposal of traffic signal control system by multi agent using Deep Q-Network

神崎 陽平 *1 Yohei Kanzaki　佐藤 季久恵 *1 Kikue Sato　高屋 英知 *1 Eichi Takaya　小川 亮 *2 Ryo Pgawa　芦原 佑太 *1*3 Yuta Ashihara　栗原 聡 *1 Satoshi Kurihara

*1慶應義塾大学 大学院院理工学研究科 Keio University　*2電気通信大学 大学院情報理工学研究科 The University of Electro-Communications

*3株式会社クロスコンパス・インテリジェンス XCompass Ltd.

In urban areas, time and economic loss due to traffic congestion are getting worse. It has a great influence on our lives. As a cause of traffic congestion, on an ordinary road, an inappropriate signal switching may be cited. Parameter manipulation in the general general signal control is set by estimation based on experiences by human hands, etc., and it is never optimal. Therefore, controlling traffic lights and improving traffic behavior is one way to solve traffic congestion. In this research, we combine multi agent system with Sato et al 's Deep Q - Network method. In this urgent situation, we propose a signal control system aiming at appropriate parameter manipulation in a road environment with multiple intersections. manuscripts.

1. はじめに

近年，都市部では交通渋滞による時間的・経済的損失が深刻化しており，生活に多大な影響を及ぼしている [1]．所与の交通量のもとで交通渋滞を解消するには大きく 2 つのアプローチが考えられる．ひとつは適切なナビゲーションによって交通量の分散を図るアプローチであり，もうひとつは信号制御によりスムーズな交通流を生み出そうとするアプローチである．本研究では信号制御によるスムーズな交通流を生み出すアプローチに焦点をあてる．一般道路においては，交通渋滞が起こる原因のひとつが交差点である．交差点では，信号機により車の通行を制御することで安全を確保し，交通の流れを円滑にするが，信号機の適切でない切り替わりによって渋滞が発生する原因にもなる．信号の適切でない切り替わりとは，交差点を通過しようとする車の台数に見合う青信号の時間が確保されていない，また逆に信号の切り替わりが遅いために右折する車待ちで渋滞が発生するといったことである．現在の一般的な信号制御におけるパラメータ操作は，人の手による経験に基づく推定などで設定されたものであり，決して最適なものになってはいない．そのため，信号機のパラメータを適切に制御し，交通行動を効率化することは交通渋滞を解消する方法の一つになる．

本研究では，佐藤ら [2] の Deep Q-Network(以下 DQN と呼ぶ) を用いた手法にマルチエージェントシステムを組み合わせることで，複数の交差点をもつ道路環境において， 適切なパラメータ操作を行うことを目的とした信号制御システムを提案する．

2. 関連研究

信号制御に関する研究は様々な角度から行われている．高橋ら [3] は，各交差点に存在する信号機をエージェントとし，エージェント同士が協調することで自律的に信号制御を行う手法を提案した．西原ら [4] は，「青，黄，赤」と表示される信号機をマルチエレメント GA を用いて適切に変化させ，効率的に信号制御を行う手法を提案した．佐藤ら [2] は高い特徴抽出能力を持つ Deep Learning と，報酬に基づいた最適な行動を学習する強化学習のひとつである Q 学習を組み合わせた Deep Q-Learning を用いて，画像という高次元な情報からエージェント自身が信号制御に必要な特徴を抽出し，適切なパラメータ操作を出力することで信号機を動的に制御するシステムを提案した．しかし，佐藤らの研究では交差点を一つしか持たない小規模な道路環境での学習にとどまっている．これは，一つのエージェントが道路環境全ての信号機に対して操作を行うことから，交差点の数が増加するとそれだけ信号機の操作パターンも増加し，それらを網羅して適切なパラメータ制御を行うことが難しくなるためである．また，佐藤らの研究では一つのエージェントが道路環境全体の画像を読み込んで処理を行うため，複数の交差点を持つ規模の大きい道路環境に対しては計算量が膨大になってしまうためである．そこで本研究では，信号操作を行う交差点の数だけエージェントを用意し，エージェントごとに信号操作を行うことでエージェントにおける信号機の操作パターンを減らす．またエージェント同士を協調させることで，佐藤らの DQN を用いた手法よりも計算量を減らし，適切なパラメータ操作を行うことを目的とした DQN を用いた信号制御システムを提案する．

連絡先: 神崎陽平，慶應義塾大学 大学院理工学研究科，神奈川県横浜市港北区日吉３－１４－１

3. 提案手法

3.1 Deep Q-Network のアルゴリズム

DQN は，深層学習を用いた特徴抽出と強化学習における代表的な手法である Q 学習を組み合わせた技術である．Q 学習とは，状態 s(入力) を与えたときに Q 値 (行動の価値) が最大となる行動 a，すなわち，最も報酬 r が得られると期待される行動 (出力) をとるようにエージェントが学習する方法である．本研究では入力値として画像を用いるが，画像情報をもとに強化学習を行うためには，エージェントが過去の画像から得られる高次元な情報から特徴量を抽出し，活用しなければならない．そこで，DQN では画像からの特徴抽出に，深層学習の手法である Convolutional Neural Network(CNN) を用いてい

る．本研究ではエージェント間で協調を行うために “他のエージェントの行動” という情報をやり取りする．エージェント間で行動を共有出来るよう，全結合層における 512 個の入力値に，他のエージェントの行動の値を加え 513 個とする．これにより，出力される行動の価値は他のエージェントの行動も考慮して更新される (図 1 参照)．

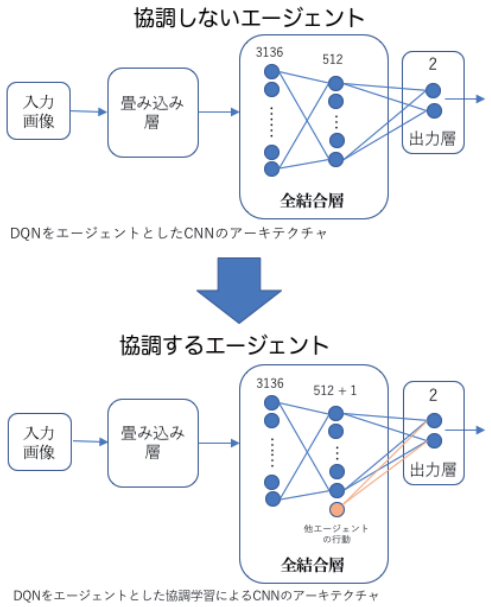


図 1: 非協調/協調学習における CNN

4. 実験とその評価

提案手法の有用性を確かめるために，車の待ち台数を評価尺度として幾つかの手法と比較実験を行った．それによる提案手法の効果，およびその有用性について考察する．なお，車の待ち台数とは道路環境上における速度が 0 の車の台数とする．

4.1 環境設定

本研究では，ミクロ交通流シミュレータ SUMO を用いて実験を行う．SUMO はドイツ航空宇宙センターを中心に開発されているオープンソースのシミュレータである．車の速度，加速度，走行ルート, 信号機，道路の設置など，自由に設定することが可能である．

本実験で用いるシミュレーション環境は提案手法，比較手法ともに図 2 のように 2 つの交差点上の道路網とする．このシミュレーションでは，step 数 *1 をはかることが可能である．車は 3step に 1 台の頻度で出現するものとする．左端から右端 (順路 1，順路 2) までの距離を 900m，上端から下端 (順路 3，順路 4) までの距離をそれぞれ 300 m とし，車の通過率を縦:横=1:3 とした環境を設定する．尚，順路 1，順路 2，順路 3，順路 4 はいずれも直進のみ行うものとする (図 2 参照)．

*1 1step は 1 秒に等しい．

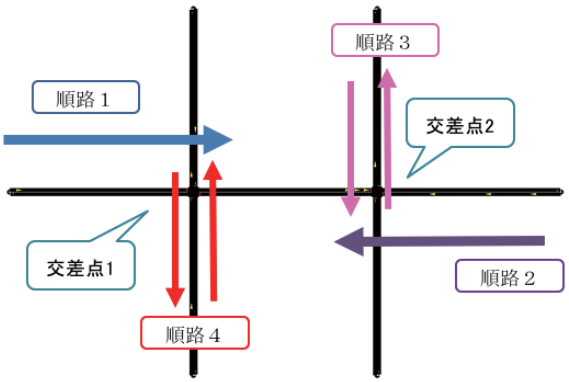


図 2: シミュレーション画像の全体像

4.2 比較手法 1 : 静的な信号制御

提案手法と比較するために，交通流に合わせた一定間隔で信号機が切り替わる静的な環境を用意する．本手法では常に決められた秒数で信号機を切り替える．また，車の通過率を縦:横=1:3 としているので，信号機のスプリット *2 は車の流量に合わせ縦を 25 %，横を 75 %とする．また，交差点間を車がスムーズに通過できるよう，信号機が青信号に切り替わるタイミングを交差点ごとにずらすものとする．このずらす秒数のことをオフセット数という．車の通行に最適なオフセット数を求めるために 0,10,15,20,25 秒の 5 種類のオフセット数を用意し，車の待ち台数を負の報酬として比較実験を行った．全ステップ数は 12,000step とし，3,000step ごとに平均値を取った．その結果，交差点間の信号を切り替える最適なオフセット数は最も車の待ち台数を少なくすることができた 15 秒であると考えられる (図 3 参照)．よって，本手法においてはオフセット数を 15 秒とする．

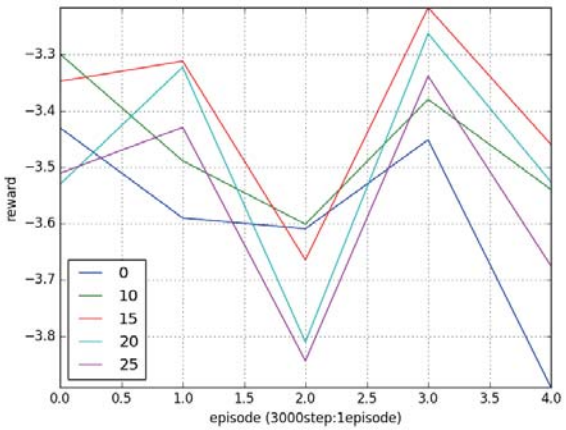


図 3: オフセット数をずらした際の静的信号制御の比較

*2 信号機が青，黄，赤を一巡する時間のうち，各道路に割り当てられる時間配分のこと．

4.3 比較手法 2：Deep Q-Network を用いた共調しないマルチエージェントによる信号制御

提案手法と比較させるために，DQN をエージェントとして，エージェント同士が情報の共有を行わないマルチエージェントによる環境を用意する．エージェントごとに交差点の画像を読み込ませるために，入力画像は図 4，図 5 のようになる．

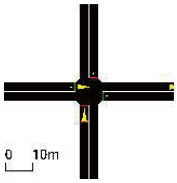


図 4: 交差点 1 の入力画像

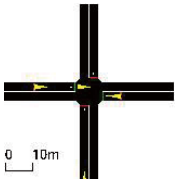


図 5: 交差点 2 の入力画像

4.4 比較手法 3：Deep Q-Network を用いたシングルエージェントによる信号制御

提案手法と比較するために，佐藤らによる手法として DQN をエージェントとし道路環境全体の画像を読み込みながら処理を行うシングルエージェントによる環境を用意する．一つのエージェントに道路環境全体の画像を読み込ませるために，入力画像は図 6 のようになる．



図 6: シングルエージェントにおける入力画像

4.5 実験結果と考察

提案手法, 比較手法ともに 500,000step 実験を行い, 6,000step ごとに車の待ち台数の平均を取ってシミュレーションを行った結果を図 7 に示す．横軸は 6,000step ごとの step 数，縦軸は車の待ち台数を負の報酬としたときの値である．グラフはそれぞれ，提案手法が “Cooperation_multi”，比較手法 1 が “static”，比較手法 2 が “multi”，比較手法 3 が “single” である．エピソード数が増えていくと佐藤らによる手法である比較手法 3 が他のどの手法よりも上回っており，佐藤らによる手法がもっとも渋滞を解消できる理想的な手法であるとわかる．ただし佐藤らの手法は提案手法に比べシミュレーションにおよそ 1.8 倍ほど時間がかかっている．また，提案手法は比較手法 1，比較手法 2 を上回り比較手法 3 に近づいている．よって提案手法は佐藤らによる手法に比べ計算量を削減しながらも，佐藤らによる手法により近い結果を出すことが出来た．つまり，DQN をエージェントとするとき，CNN の全結合層に別のエージェントの情報を加えることで，エージェント同士が協調し，高い学習能力を示すことがわかる．

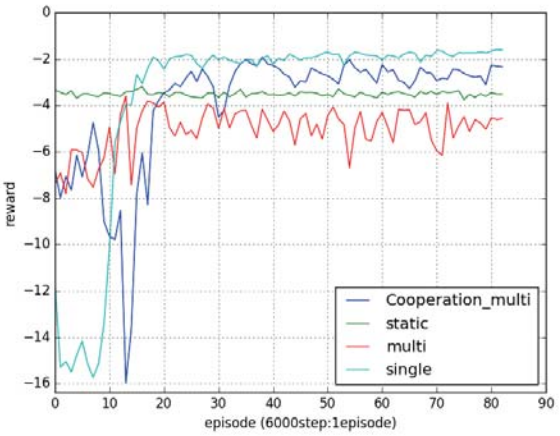


図 7: 提案手法および比較手法の比較実験結果

5. 終わりに

本研究では，高い特徴抽出能力を持つ Deep Learning と，報酬に基づいた最適な行動を学習する強化学習を組み合わせた Deep Q-Network による信号制御手法にマルチエージェントシステムを組み合わせた手法の評価を行った．提案手法は理想的な手法よりも計算量を削減し，理想的な手法に近い状態で渋滞をさせずに制御できていた．このように，入力された画像からエージェント自身が信号制御に必要な特徴を抽出しパラメータ制御を行う DQN を用いた信号制御に加え, エージェント同士が情報をやり取りし協調することで，複数の交差点を持つ道路環境において適切なパラメータ操作ができることが示された．

今後の課題としては, 歩行者の追加, 右折左折を取り入れた 2 車線以上の道路など, 現実に即した複雑な道路環境での実験を行う. また，現実の道路環境においては, すべての交差点において交通量計測センサが設置されてはいないため, 計測センサーが設置されている主要な交差点のみで協調することで Deep Q-Network を用いた交通信号制御が可能であるか, といった課題についての実験と考察も試みる．

6. 参考文献

[1] 国土交通省「都市圏の交通渋滞対策」“https://www.mlit.go.jp/common/000043136.pdf”

[2] 佐藤季久恵，高屋英知，小川亮，芦原佑太，栗原聡 ,“Deep Q-Network を用いた交通信号制御システムの提案”，2017 年度人工知能学会全国大会，名古屋

[3] 高橋光紀，篠田孝祐，諏訪博彦，栗原聡，“マルチエージェントモデルによる信号制御シミュレーションの検討 ”，研究報告知能システム (ICS)，09196072，情報処理学会, 2014，Vol.7，pp1-6.

[4] 高玉圭樹 ,“マルチエージェント学習 -相互作用の謎に迫る- ”，コロナ社，2013

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

繰り返し貪欲組合せオークションを用いた利己的マルチエージェント経路計画

Iterative Greedy Combinatorial Auction for Self Interested Multi-Agent Pathfinding

町田　真直
Manao Machida

日本電気株式会社
NEC Corporation

This paper proposes an iterative greedy combinatorial auction (CA) mechanism for multi-agent pathfinding (MAPF). MAPF algorithms assign agents non-conflicting paths that minimize a global cost (e.g. the sum of travel costs). CA mechanisms allocate agents items that maximize social welfare. Recent works proposed two mechanisms that coordinate self-interested agents in MAPF: one is called iterative taxation framework (ITF), which is similar to the simultaneous ascending auction, and the other is an iterative CA mechanism, which guarantees to minimize the global cost. However, both methods have drawbacks: the former has no approximation guarantee, and the latter suffers from the fact that winner determination in the CA is computationally infeasible (NP-hard). In this paper, the author propose two iterative greedy CA (IGCA) mechanisms for MAPF that are computationally efficient. The first mechanism provides square of the number of agents approximation. Second mechanism was shown, by numerical simulations, to give a lower cost than ITF.

1. はじめに

マルチエージェント経路計画問題（MAPF）はグラフとエージェントからなる．各エージェントは，それぞれのスタートノードからゴールノードまで，他のエージェントと衝突することなく，グラフ上を移動する必要がある．MAPF の目的は，エージェント間で衝突がなく，コスト（例えば，各エージェントの移動コストの合計）が最小である各エージェントの経路を解として得ることである．MAPF は，交通管制，ビデオゲーム，配車ルートの決定等，様々な応用分野を持つ [Silver 2005, Standley 2010, Ryan 2010, Dresner 2008, Kiesel 2012]．

組合せオークションでは，各エージェントは複数の商品の組合せに対して入札を行う．組合せオークションの目的は，社会余剰を最大化する，エージェントへの商品の割当を行なうことである．この社会余剰を最大化する商品の割当の決定は勝者決定問題と呼ばれ，NP 困難な問題であることが知られている．このような計算困難性に対して，貪欲的な価格付けと勝者決定を行なう，貪欲オークションというメカニズムが提案されている [Ito 2005, Yokoo 2003]．複数の商品の割当決定メカニズムとしては，他にも，商品 1 つずつのみに入札を行う，同時競り上げオークションなどが存在する [Milgrom 1997]．

従来の MAPF では，各エージェントは協力的であり，解として与えられた解の経路にしたがって移動することが仮定されている．近年，この協力型の MAPF に対して，利己的なエージェント間での MAPF の研究も行なわれている [Bnaya 2013, Amir 2015]．利己的なエージェント間の MAPF では，各エージェントが自身のコストだけを考えて経路を決定する状況で，いかにグローバルコストを最小化するかが問題となる．

[Bnaya 2013] は，ITF という，メディエーターが各エージェントのパスを予測し，コンフリクトが予想されるノードとエッジに税を掛けるメカニズムを提案している．さらに，ITF により得られる MAPF の解をメカニズムを導入しない場合の解と比較し，エージェントが税を払うコストを含めたとしても，全体のコストを小さく抑えることができることを示している．しかしながら，ITF では解の近似保証はなされていない．

ITF における，メディエーターが各エージェントのパスを予測し，衝突の発生するノードとエッジに税を掛ける操作は，ノードとエッジを商品，税を商品の価格だと考えれば，需要に対して供給が上回る商品の価格を競り上げることに等しい．この意味で，ITF は同時競り上げオークションと非常に似たメカニズムである．

[Amir 2015] は，競り上げ式組み合わせオークションを利己的エージェントの MAPF に適用するもので，各ラウンドで各エージェントは支払額を考慮した自身の最適パスに対して入札を行い，オークショナーが勝者決定（パスの割当）とパスの価格の競り上げを行うことで，MAPF の最適解（各エージェントの経路コストの総和が最小の解）が得られるとしている．ただし，各ラウンドでの勝者決定問題は NP 困難である．

本稿では，各エージェントが利己的な状況において，繰り返し貪欲組合せオークション（IGCA）を用いて MAPF を解く手法を提案する．提案手法においては，貪欲組合せオークションを用いることにより，各ラウンドでの計算困難性を回避している．また，貪欲組合せオークションとして，２種類の価格付け方法を用いる．本稿ではさらに，１つ目の価格付け方法を用いた IGCA が，各エージェントが他のエージェントのスタートノードとゴールノードを使用しないという問題設定において，エージェント数の二乗の近似保証をもつことを示す．また，２つ目の価格付け方法を用いた IGCA が，数値実験において，ITF よりコストを小さく抑えることができることを示す．

2. 問題設定

MAPF は，グラフ $G = (V, E)$ とエージェントの集合 $K = \{1, \ldots, k\}$ からなる．そのため，MAPF の問題 M を，$M = (G, K)$ で定義する．エージェント $i \in K$ はスタートノード $s_i \in V$ とゴールノード $g_i \in V$ を持つ．各エージェントは，１つのタイムステップに，現在のノードに留まるか，隣接するノードに移動することができる．エージェント i のパス P_i を

連絡先: 町田 真直，日本電気株式会社，〒 211–8666，神奈川県川崎市中原区下沼部 1753，044-435-5678，manao-machida@ap.jp.nec.com

以下で定義する．

定義 1 パス P_i は，エージェント i が通る，ノードとそのタイムステップの組と，エッジと 2 つのタイムステップの組の集合である．

つまり，エージェント i がタイムステップ n にノード $v \in V$ に存在し，エッジ $e \in E$ を通ってタイムステップ $n+1$ にノード v' に到着するとき，パス P_i は，$(v,n),(e,(n,n+1)),(v',n+1)$ を要素としてもつ．また，一般的な MAPF では，エージェントはゴールに到着後にもそのノードに留まる．そのため，タイムステップ n にゴールに到着するパス P_i は，任意のタイムステップ $n' \geq n$ について，(g_i,n') を要素としてもつ無限集合である．定義より，エージェント i,j がそれぞれパス P_i,P_j にしたがって移動して衝突するとき，$P_i \cap P_j \neq \emptyset$ である．MAPF の解を，パスの集合 $\mathcal{P} = \{P_1,\ldots,P_k\}$ で表す．

本稿で扱う問題設定では，エージェントが利己的かつ，異なるタイムステップコストを持つとする．エージェント i のタイムステップコストを w_i とする．ここで，タイムステップコスト w_i は，単位時間当たりの遅れに対するコスト増加を表している．例えば，このコストを燃料費だとみれば，トラックが単位時間当たりに消費する燃料 w_{truck} が，バイクが単位時間当たりに消費する燃料 $w_{motorcycle}$ の 2 倍であるならば，$w_{truck} = 2 \cdot w_{motorcycle}$ と設定すればよい [Amir 2015]．

パス P_i にしたがって移動したときのエージェントの移動コストは，ゴールに到着するまでのタイムステップ数を $n(P_i)$ として，$w_i n(P_i)$ で与えられる．また，形式的には，

$$n(P_i) = \min\left\{n : \forall n' \geq n, (g_i,n') \in P_i\right\}$$

である．

さらに，本稿ではエージェントのコストは準線形であると仮定する．つまり，パス P_i にしたがって移動するために，金銭支払い t が必要であるとき，パス P_i にしたがうエージェント i のコストは，

$$w_i n(P_i) + t$$

で与えられる．利己的なエージェントは，自身のコストを最小化することを目的として行動する．

3. 提案メカニズム

本節では，ICGA メカニズムを用いて MAPF を解く手法を提案する．

3.1 貪欲組合せオークション

貪欲組合せオークションでは，商品の組合せの価格を，局所的な情報で決定する．[Yokoo 2003] では，次の価格付け方法が提案されている．エージェント i が商品の組合せ B を購入しようとしたときの価格 $t_i(B)$ を，

$$t_i(B) = \max_{B_j \cap B \neq \emptyset, j \neq i} v_j(B_j) \tag{1}$$

で与える．ただし，$v_j(B_j)$ は，エージェント j にとっての商品の組合せ B_j の価値を表す．

提案メカニズムの 1 つ目では，商品の組合せをパスと見なして，(1) を修正した，以下の貪欲的な価格付け方を用いる．

定義 2 (競合最大価格) すべての $j \in K$ についてエージェント j がパス P_j を価格 $t_j(P_j)$ で入札しているとする．このとき，エージェント $i \in K$ がパス P を得るための価格 $t_i(P)$ を，以下で与える．

$$t_i(P) = \max\left\{\max_{P \cap P_j \neq \emptyset, j \neq i} t_j(P_j) + \epsilon, t_i(P_i)\right\} \tag{2}$$

ただし，$\epsilon > 0$ である．

競合最大価格では，欲するパスと衝突を起こすパスの価格の中で，最大のものより ϵ だけ高い値が欲するパスの価格となる．ϵ は競り上げオークションにおける，最小の競り上げ幅に対応する．ただし，既に入札しているパスがある際には，自らパスを変更したとしても，その価格は既に入札しているパスの価格以下にはならない．また，競合最大価格を用いる IGCA メカニズムを，本稿では M-IGCA メカニズムと呼ぶ．

さらに，提案メカニズムの 2 つ目では，以下の貪欲的な価格付け方を用いる．

定義 3 (競合合計価格) すべての $j \in K$ についてエージェント j がパス P_j を価格 $t_j(P_j)$ で入札しているとする．このとき，エージェント $i \in K$ がパス P を得るための価格 $t_i(P)$ を，以下で与える．

$$t_i(P) = \sum_{P \cap P_j \neq \emptyset, j \neq i} (t_j(P_j) + \epsilon) + t_i(P_i) \tag{3}$$

ただし，$\epsilon > 0$ である．

競合合計価格では，欲するパスと衝突を起こすパスの価格に ϵ を足したものの合計に，自身の既に入札しているパスの価格を足したものが欲するパスの価格となる．また，競合合計価格を用いる IGCA メカニズムを，本稿では S-IGCA メカニズムと呼ぶ．

3.2 M-IGCA メカニズム

M-IGCA メカニズムのプロトコルを以下に示す．

1. ラウンド $r \leftarrow 0$，価格集合 $t \leftarrow \{0,\ldots,0\}$, パス集合 $\mathcal{P} \leftarrow \{\emptyset,\ldots,\emptyset\}$，$S \leftarrow K$ とする．
2. $r \leftarrow r+1$，$i \in \arg\max_{i \in S} t_i$ である 1 人のエージェント i を選び，$S \leftarrow S \setminus \{i\}$ とする．
3. エージェント i は，$w_i n(P) + t_i(P)$ が最小であるパス P を申告する．すなわち，$P_i \leftarrow P$，$t_i \leftarrow t_i(P)$.
4. すべての $j \neq i$ について，$P_j \cap P_i \neq \emptyset$ ならば $P_j \leftarrow \emptyset$, $t_j \leftarrow 0$.
5. すべての $j \neq i$ について，$t_j < t_i$ ならば $S \leftarrow S \cup \{j\}$.
6. $S \neq \emptyset$ であれば 2. へ，そうでなければ，すべてのエージェント $i \in K$ が価格 t_i を支払いパス P_i を得て終了．

M-IGCA メカニズムでは，各ラウンドで 1 人のエージェントのみ入札を行う．特に ϵ が十分に大きいとき，各エージェントは自身より先に入札されたパスに競合するパスを申告すると，非常に高い価格を払う必要があるため，事前に申告されたパスと競合しないパスを申告する．このような，順にパスを作り，後にパスを作るエージェントは先に作られたパスを競合しないパスを作る手法は，CA* と呼ばれる [Silver 2005]．一方，ϵ が小さいとき，各エージェントは，他のエージェントが申告する価格より ϵ だけ高い価格を申告することで，そのエージェ

ントのパスを無視してパスを作ることができる．また，その際，無視された競合パスを申告していたエージェントは，申告が拒絶され，パスが割り当てられていない状況になる．

M-IGCA メカニズムの動作の概略を説明する．ラウンド $r, r+1$ におけるパス，価格を $\mathcal{P}^r, t^r, \mathcal{P}^{r+1}, t^{r+1}$ で表すとして，ラウンド r においてエージェント $1,2,3$ がパス $P_1^r, P_2^r, P_3^r \neq \emptyset$ を持つとき，ラウンド $r+1$ でエージェントがパス P_1^{r+1} を申告するとする．このとき，$P_1^{r+1} \cap P_2^r \neq \emptyset$，$P_1^{r+1} \cap P_3^r = \emptyset$ であるならば，ラウンド $r+1$ での割り当てられるパスは，エージェント 1 は申告した P_1^{r+1}，エージェント 2 は申告を拒絶され $P_2^{r+1} = \emptyset$，エージェント 3 は変わらず $P_3^{r+1} = P_3^r$，価格は $t_1^{r+1}(P_1^{r+1}) = \max\{t^r(P_2^r) + \epsilon, t^r(P_1^r)\}$，$t_2^{r+1}(P_2^{r+1}) = 0$，$t_3^{r+1}(P_3^{r+1}) = t^r(P_3^r)$ となる．$t_1^{r+1}(P_1^{r+1}) > t_3^{r+1}(P_3^{r+1})$ ならば，エージェント 3 は既にパスを割り当てられていたとしても，再度パスを申告する機会を得る．これは，エージェント 1 の申告により，パスの申告に必要な価格が変更されたことにより，エージェント 3 はパスを変更することでコストを減少させることができる可能性があるためである．

M-IGCA メカニズムが有限回のラウンドで終了する十分条件は以下で与えられる．

定理 1 問題 M において，任意のパス作成順の *CA** が解を得ることができるならば，*M-IGCA* メカニズムは有限回のラウンドで終了する．

[Čáp 2015] では，CA* において，各エージェントは他のエージェントのスタートノードとゴールノードを通らないという条件下において，解が得られるどうか判断する手法を示している．他のエージェントのスタートノードとゴールノードを通らないという条件は，利己的なエージェント間では自然な仮定である．例えば，エージェントが車であれば，スタートノードは自身の駐車場等であり，通常他のエージェントの移動には使用されない．また，エージェントがドローンやヘリの場合，スタートとゴールは地表にあり，移動中はエージェントは上空に位置するため，スタートノードとゴールノードは他のエージェントの移動には使用されない．

M-IGCA メカニズムの解を，パスの集合 $\mathcal{P}$ と価格の集合 t の組で表す．M-IGCA メカニズムは以下の近似保証をもつ．

定理 2 各エージェント $i \in K$ がすべての $j \neq i$ について s_j, g_j を通過できない問題 M において，$\epsilon > 0$ が十分に小さいとき，*M-IGCA* メカニズムの解 $(\mathcal{P}, t)$ は，最小コストパス $\mathcal{P}^*$ に対して，

$$\sum_{P_i \in \mathcal{P}} \{w_i n(P_i) + t_i(P_i)\} \leq k^2 \sum_{P_i^* \in \mathcal{P}^*} w_i n(P_i^*) \qquad (4)$$

を満たす．

この定理は，M-IGCA メカニズムの解における支払い価格を含めたエージェントのコストが，MAPF の解である最小の移動コストに対して，エージェント数の 2 乗の近似保証をもつことを示している．

3.3 S-IGCA メカニズム

S-IGCA メカニズムのプロトコルを以下に示す．

1. ラウンド $r \leftarrow 0$，価格集合 $t \leftarrow \{0, \ldots, 0\}$, パス集合 $\mathcal{P} \leftarrow \{\emptyset, \ldots, \emptyset\}$，$S \leftarrow K$ とする．
2. $r \leftarrow r+1$，S から 1 人のエージェント i を選び，$S \leftarrow S \setminus \{i\}$ とする．
3. エージェント i は，$w_i n(P) + t_i(P)$ が最小であるパス P を申告する．すなわち，$P_i \leftarrow P$，$t_i \leftarrow t_i(P)$.
4. $j \neq i$ が存在して，$P_j \cap P_i \neq \emptyset$ ならば，$S \leftarrow K$
5. すべての $j \neq i$ について，$P_j \cap P_i \neq \emptyset$ ならば $P_j \leftarrow \emptyset$，$t_j \leftarrow 0$.
6. $S \neq \emptyset$ であれば 2. へ，そうでなければ，すべてのエージェント $i \in K$ が価格 t_i を支払いパス P_i を得て終了．

S-IGCA メカニズムは，M-IGCA メカニズムと異なり，パスの申告順は価格によらない．また，申告を拒絶されるエージェントが存在した場合には，今後のラウンドにおいて，すべてのエージェントに再度パスの申告を行なう機会が与えられる．

4. 数値実験

本節では，提案メカニズムを数値シミュレーションにおいて評価する．また，CA*，[Bnaya 2013] で提案されている ITF との比較を行なう．特に ITF については，各エージェントの挙動が同じ状況で比較を行なうために，（メディエーターの想定する）各エージェントが A* アルゴリズムにより得られた最短パスを一本だけ申告する，EITF(1) との比較を行なう．

MAPF の問題設定として，20×20 グリッドのグラフ G を考える．グラフ G は，各グリッドをノードとして，上下左右の 4 近傍のノードと隣接している．また，IGCA メカニズムは，すべてのシミュレーションで $\epsilon = 0.1$ とした．

図 1 は，タイムステップコストが各エージェントで同一な場合 $(w_1 = \cdots = w_k = 1)$ について，エージェント数が，10,20,30,40 のときの結果を示している．ただし，グラフの見易さのため，エージェント数 40 のときの M-IGCA メカニズムは省略した．

この結果は，任意の $i \in K, j \neq i$ について，$s_i \neq s_j, g_i \neq g_j$ であるよう，スタートノードとゴールノードはランダム生成した，1000 セットの問題のコストの平均である．ただし，CA* で解が得られない場合，また，IGCA と ITF において 1 分以内で解が得られなかった場合は除いている．解が得られないケースは，それぞれ，エージェント数 30 のときに M-IGCA で 1 回，エージェント数 40 のときに，CA* で 2 回，ITF において 2 回，M-IGCA で 4 回だった．

図 1 より，提案メカニズム S-IGCA では，CA*，ITF と比較して，コストを小さく抑えられていることがわかる．特に，ITF と比較すると，移動コストには大きな違いはないが，金銭の支払いを小さく抑えられていることがわかる．一方で，提案メカニズム M-IGCA は，金銭の支払いコストが高く，コストを小さく抑えることはできていない．

図 2 は，各エージェントに 1 から 10 までのタイムステップコストをランダムに設定する場合について，エージェント数が，10,20,30,40 のときの結果を示している．図 1 の同様に，20×20 グリッドのグラフ G において，任意の $i \in K, j \neq i$ について，$s_i \neq s_j, g_i \neq g_j$ であるよう，スタートノードとゴールノードはランダム生成した，1000 セットの問題の平均である．各エージェントのタイムステップコストも，各問題ごとにランダム生成している．また，ITF はエージェントごとのコストの違いに対応していないメカニズムであるため，本設定においてシミュレーションは行なっていない．解が得られなかった問題数は，CA* について，エージェント数 30 のときに 2 回，エージェント数 40 のときに 3 回だった．

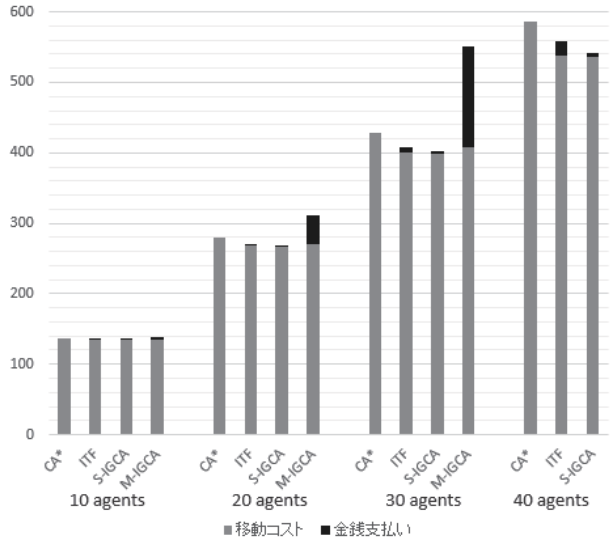


図 1: 20×20 グリッド，$w_1 = \cdots = w_k = 1$ の場合

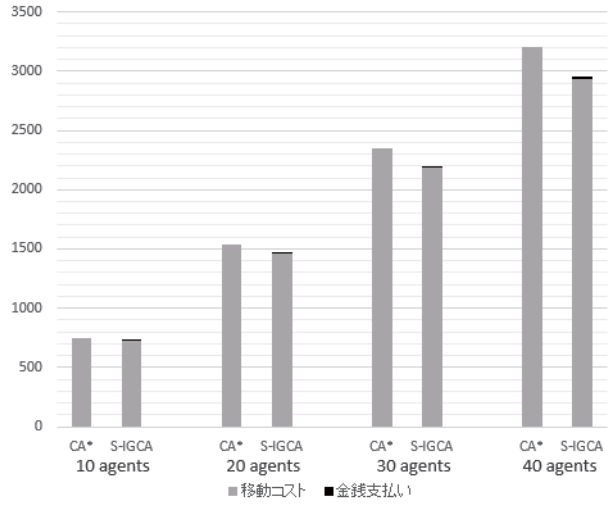


図 2: 20×20 グリッド，$w \in [1, 10]^k$ の場合

図 2 より，各エージェントのタイムステップコストが異なる場合において，S-IGCA メカニズムでは，CA* よりコストを小さく抑えられていることがわかる．また，図 1，図 2 における S-IGCA メカニズムの，CA* と比較したコストの減少率は，それぞれ，エージェント数 10 のとき約 2 %，20 のとき約 3 %，30 のとき約 6 %，40 のとき約 8 %で，大きな違いはみられなかった．

5. まとめ

本稿では，各エージェントが利己的な状況において，繰り返し貪欲組合せオークションを用いて MAPF を解く手法を提案した．競合するパスの最大価格に基づいて価格付けを行なう M-IGCA メカニズムが，各エージェントが他のエージェントのスタートノードとゴールノードを通過しないという問題設定において，エージェント数の 2 乗の近似保証をもつことを示した．また，競合するパスの価格の合計値に基づいて価格付けを行なう S-IGCA メカニズムが，数値シミュレーションにおいて，ITF（EITF(1)）よりコストを小さく抑えることができることを示した．今後の研究としては，S-IGCA メカニズムの近似保証を行なうことが挙げられる．

謝辞

本研究は独立行政法人新エネルギー・産業技術総合発機構（NEDO 技術開発機構）が推進するロボット・ドローンが活躍する省エネルギー社会の実現プロジェクトによる援助を受けて行われた．

参考文献

[Amir 2015] Amir, O., Sharon, G. and Stern, R.: Multi-agent pathfinding as a combinatorial auction, in *AAAI* (2015)

[Bnaya 2013] Bnaya, Z., Stern, R., Felner, A., Zivan, R., and Okamoto, S.: Multi agent path finding for self interested agents, in *Sixth Annual Symposium on Combinatorial Search* (2013).

[Čáp 2015] Čáp, M., Novák, P., Kleiner, A. and Selecký, M.: Prioritized planning algorithms for trajectory coordination of multiple mobile robots, in *IEEE Transactions on Automation Science and Engineering*, Volume: 12, Issue: 3 (2015)

[Silver 2005] Silver, D.: Cooperative pathfinding, in *AIIDE*, pp. 117-122 (2015).

[Standley 2010] Standley, T.: Finding optimal solutions to cooperative pathfinding problems, in *AAAI*, pp. 173-178 (2010)

[Ryan 2010] Ryan, M.: Constraint-based multi-robot path planning, in *ICRA*, pp. 922-928 (2010)

[Dresner 2008] Dresner, K. and Stone, P.: A multiagent approach to autonomous intersection management, *J. Artif. Intell. Res. (JAIR)*, volume 31, issume 1, pp.591–656 (2008)

[Kiesel 2012] Kiesel, S., Burns, E., Wilt, C. M., and Ruml, W.: Integrating vehicle routing and motion planning, in *ICAPS* (2012)

[Ito 2005] Ito, T., Yokoo, M., Matsubara, S. and Iwasaki, A.: A New Strategyproof Greedy-Allocation Combinatorial Auction Protocol and its Extension to Open Ascending Auction Protocol, in *Proc. of the 20th National Conf. on Artificial Intelligence (AAAI2005)*, pp. 261–266 (2005)

[Yokoo 2003] Yokoo, M.: The characterization of strategy/false-name proof combinatorial auction protocols: Price-oriented, rationing-free protocol, In *IJCAI*, pp. 733-739 (2003)

[Milgrom 1997] Milgrom, P. R.: Putting Auction Theory to Work; The Simultaneous Ascending Auction, thechnical report 98–0002, Department of Economics, Stanford University (1997)

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

時間遅れを考慮した経路別通行人数の推定

Estimation of people flow considering time delay

清武　寛　Hiroshi Kiyotake
幸島　匡宏　Masahiro Kohjima
松林　達史　Tatsushi Matsubayashi
戸田　浩之　Hiroyuki Toda

NTT サービスエボリューション研究所
NTT Service Evolution Laboratories

It is important to make a security plan in advance for safe operation. Recently, to make a detailed security plan and to reproduce the flow of the real world crowd, Multi Agent Simulator (MAS) is widely used. In order to reproduce the crowd flow on MAS, the route (start time, start, and goal) of each agent is necessary to estimate. In this paper, we propose a estimation method based on the Bayesian Optimization. Using two real world observed data, we show the data assimilation results. By considering a multi time window to the optimization, the error of estimation caused by the time delay of observation is decreased.

1. はじめに

人気アーティストのライブや，スポーツイベントなど，入退場に多数の人の移動が伴うイベントにおいて，安全な運営を実現するためには事前の警備計画の策定が重要である．通常，警備計画は，来場する群衆の移動を想定し策定される．例えば，2020 年に開催予定であるオリンピック・パラリンピックでは，新国立競技場（オリンピックスタジアム）の設立とともに，周辺複数の駅からの歩行者移動経路を想定して，安全なアクセス環境の計画立案を進めている [14]．また，群衆行動の想定には過去の知見のみならず，類似イベントによる調査も重要視されており，新国立競技場では移動経路上における群衆行動のリハーサルも計画されている [4]．

近年，このような事前計画の策定に，Multi-Agent Simulation(以下 MAS と略す) が用いられている．MAS は，各エージェントがいつ，どこから，どこに向かうかという時間帯ごとの移動経路別の通行人数を入力することで，エージェント間の相互作用を考慮しながら群衆行動の様子を再現する．MAS を用いて，様々なシチュエーションでの群衆行動の分析を実施することで，誘導計画や歩行者路の道幅確保などの警備計画の策定に役立てられている [3, 9, 10, 12]．しかしながら，計画策定を正しく行うには，MAS 上での群衆行動の再現が現実に即したものである必要である．そのため現実の群衆行動を観測し MAS に反映するアプローチが検討されている [1, 11, 13]．

現実の群衆行動の計測には，GPS 等の測位機能を持ったデバイスを人々が持つ方法の他，カメラやレーザセンサなど環境に設置されたデバイスによる計測方法がある．しかしながら，GPS 等の利用による移動経路計測では，イベント参加者全員の軌跡を取ることは困難であり，カメラの人物特定による軌跡追随はプライバシー保護の観点から活用は難しい．また，レーザセンサの重畳計測による移動経路追跡手法 [5] もあるが，屋外での広域計測は困難である．それゆえ，現実的には，道路等に定点に設置されたカメラで計測できる局所的な通過人数を活用することになる．しかし，この手段で計測できる情報では，MAS の入力に必要な時間帯ごとの移動経路別の通行人数とは乖離がある．

本稿では，大規模イベントにおいて会場と周辺駅との間を群衆が移動する状況等を対象に，定点で局所的に観測された通過人数から，観測値との誤差が小さくなるような時間帯ごとの移動経路別の通行人数を推定する．これにより，現実に即した形で群衆行動を MAS 上に再現する事が可能となる．

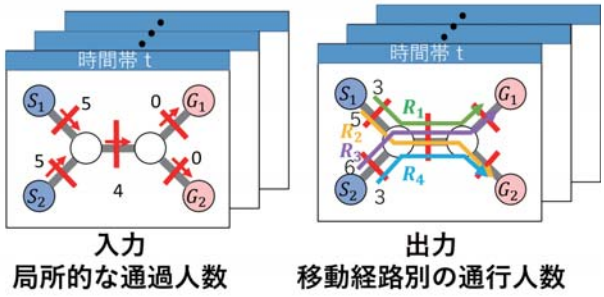


図 1: タスクの入出力例

各時間帯の通過人数の誤差を小さくするように推定するためには，複数の時間帯でユーザが観測されること (時間遅れ) を考慮しなければならない．そのためには，混雑時の速度低下等の他のユーザからの影響による移動時間を考慮する必要がある．ユーザ間の相互作用による移動時間を考慮するため，本稿では MAS を用いた推定方法のフレームワークを提案する．提案フレームワークでは，MAS の実行と通過人数の誤差が減少する可能性がある経路別通行人数の探索を交互に行うことで，時間帯ごとの経路別通行人数を更新しながら逐次的に推定を行う．また移動に時間がかかる混雑時の推定も正しく行うため，一つの時間帯の経路別通行人数の推定の際に複数時間帯の通過人数の誤差を目的関数として用いる．

手法の有効性の確認のため，本稿では実際に行われた二つのイベントデータを用いて，実際に観測された値と推定結果をもとに MAS を実行した際の MAS 上での観測結果との誤差を評価する．実験結果をもとに，既存手法に比べ平常時・混雑時ともに精度良く推定できることを示す．また，時間遅れを考慮したことの効果についても併せて述べる．

本稿では，第 2 章で同様のタスクを扱った関連研究について述べ，本研究の貢献を明確にする．第 3 章で本稿の提案である MAS を用いた推定手法のフレームワークについて詳しく述べる．第 4 章で提案手法の有効性を実験的に検証し，第 5 章でまとめを行う．

連絡先: kiyotake.hiroshi@lab.ntt.co.jp

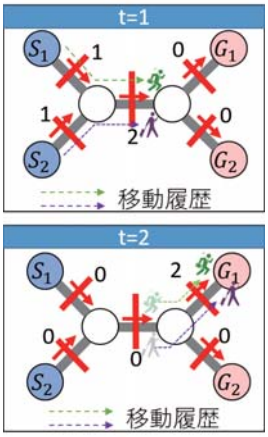


図 2: 既存手法で正しく推定できない例

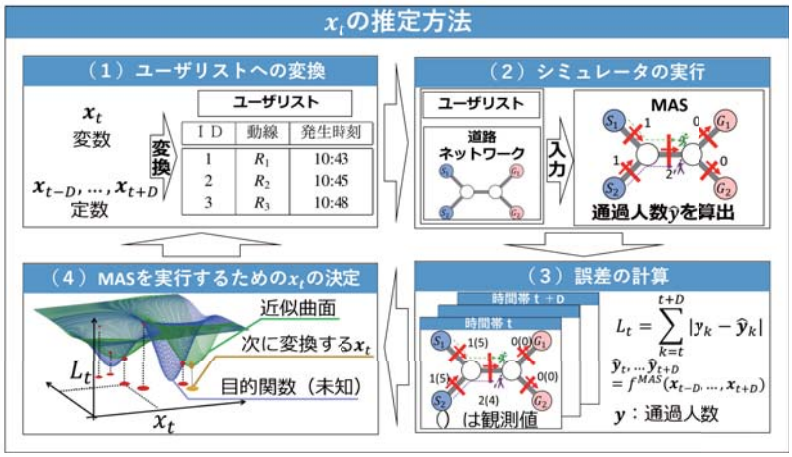


図 3: 推定方法全体図

2. 関連研究

近年，現実に観測されたデータを用いて，現実に即した MAS のパラメータを推定するデータ同化の研究が行われている [11, 13]．推定するパラメータは，各エージェントの歩行速度や出発時刻など，目的に応じてさまざまである．警備計画策定に MAS を用いる場合，各エージェントが移動する経路を変更した場合の効果検証という目的が想定される．本稿では，道路上にある複数の観測地点 j において，各時間帯 t に局所的に観測された通過人数 $\mathbf{y}_t = (y_{tj})_{j=1}^{J}$ のデータを用いて，各時間帯 t に各移動経路 R_i 上を通行開始する人数 $\mathbf{x}_t = (x_{ti})_{i=1}^{I}$ を推定するというタスクに取り組む．このタスクの入出力例を図 1 に示す．

ナイーブな解法として，各時間帯 t における目的関数を以下のように定義し，最適化することが考えられる．

$$L_t = |\mathbf{y}_t - \hat{\mathbf{y}}_t|$$

$\mathbf{y}_t$: 観測された通過人数

$\hat{\mathbf{y}}_t$: 移動経路別の通行開始人数 $\mathbf{x}_t$をもとに算出される通過人数

清水ら [11] は，通信の分野において Zhang らが提案した通信トラヒック推定モデル [8] を参考にした統計モデルを考案し，移動経路別の通行人数 $\hat{\mathbf{y}}_t$ を算出している．具体的には，各観測地点におけるにおける通過人数は，その観測地点を通過する各移動経路の通行人数の和となるため，移動経路とが各観測地点の関係を記述した行列

$$A_{ij} = \begin{cases} 1 & \text{移動経路 } R_i\text{が観測地点 } j \text{ を通過する場合} \\ 0 & \text{その他} \end{cases}$$

を用いて，各時間帯の各観測地点の通過人数 $\hat{\mathbf{y}}_t$ を

$$\hat{\mathbf{y}}_t = A\mathbf{x}_t, \qquad t = 1, 2, \ldots, T$$

として算出する．統計モデルを用いた手法では，モデルが MAS を正しく表現できていない場合，推定結果をもとに MAS を実行したとしても誤差が大きくなってしまう．エージェントが経路を通行する際，出発から到着まで移動時間がかかるが，清水らの手法では移動時間を考慮せず，出発時間帯内で到着することを想定している．そのため移動が複数時間帯にまたがる場合に推定誤差が大きくなってしまう．例えば図 2 のように，S1 から G1 への移動経路を通るエージェント，S2 から G1 への移動経路を通るエージェントの二人が存在し，両者とも $t = 1$ では目的地に到着せず，$t = 2$ において目的地である G1 へ到着している場合を考える．既存手法では時間帯 $t = 1$ 内で到着することを仮定するため，正しい移動経路を推定した場合と，一方が S1 から G2，他方が S2 から G2 という誤った経路を推定した場合の誤差が同じになるため，誤った推定を行う可能性がある．

一般的に MAS は，エージェント間の相互作用による速度低下なども考慮して開発されるため，パケットのように瞬時に移動することを前提とした統計モデルを用いて表現することは難しい．そのため，本稿ではエージェントの移動時間を考慮しながら経路別の移動人数を推定する手法を提案する．

3. 提案手法

第 2 章で述べた通り，統計モデルを用いた手法では，エージェントの移動時間や相互作用などを考慮することが困難である．そこで我々は，エージェントの移動時間を考慮することを目的とし，MAS を活用して，局所的な地点での通過人数から，経路別の移動人数を推定する手法を提案する．

本章では，まず MAS を用いて経路別移動人数を推定するフレームワークを提案する．そして，複数時間帯で観測される時間遅れを考慮した推定のための目的関数を提案する．

3.1 推定方法

本提案手法では，以下の 4 つのステップを繰り返すことにより，各時間帯 t における移動経路別の通行人数を推定する．推定方法の全体図を図 3 に示す．

(1) ユーザリストへの変換：シミュレータを実行するためにエージェントがいつ，どこからどこへ向かうのかを記述したユーザリストを作成する．変数である時間帯 t における経路別の移動人数である $\mathbf{x}_t$ と定数である $\mathbf{x}_{t-D}, \cdots, \mathbf{x}_{t-1}, \mathbf{x}_{t+1}, \cdots, \mathbf{x}_{t+D}$ をもとに出発時刻，移動経路の組み合わせを生成する．

(2) シミュレータの実行：(1) で作成したユーザリストをもとに，シミュレーションを実行する．この際，現実との観測地点と同じ場所においてエージェントが通過した人数を出力する．

(3) 誤差の計算：(2) で出力された各観測地点におけるエージェントの通過人数をもとに，実際に観測した通過人数との誤差 L_t を計算する．この誤差の式を目的関数とする．詳細は 3.2 節で述べる．



図 4: 早稲田大学周辺マップ



図 5: 新宿駅付近マップ

(4) 次に実行する $\mathbf{x}_t$ の決定：次に実行するユーザリストを作成するための $\mathbf{x}_t$ の決定には，メタヒューリスティックス最適化手法の一つである，ベイズ最適化 [7] を用いる．ベイズ最適化は，これまで得られた移動経路別の通行人数 $\mathbf{x}_t$ と誤差 L_t の組 $S = \{(\mathbf{x}_t, L_t)|n = 1, 2, \ldots, N\}$ をもとに $\mathbf{x}_t$ と L_t の関係式をガウス過程 [6] によって近似し，誤差が小さくなる可能性が高い移動経路別の通行開始人数 $\mathbf{x}_t$ を探索し，出力する．この $\mathbf{x}_t$ を (1) ユーザリストの作成の際に用いる．

上の (1) から (4) までを繰り返すことにより，一つの時間帯 t に出発する移動経路別の通行開始人数 $\mathbf{x}_t$ を推定する．$\mathbf{x}_t$ の推定には前後の時間帯 $t - D \sim t + D$ に出発するエージェントも影響を与えるため，$\mathbf{x}_1, \mathbf{x}_2, \cdots$ と推定を終了したのち，さらに複数周回同様の推定を繰り返し，推定精度を向上させる．

3.2 目的関数

次に，推定方法 (3) で用いる，エージェントが複数時間帯で観測されることを考慮した目的関数を提案する．図 2 の例の場合では，時間帯 $t = 1$ に出発するすべてのエージェントが到着する，$t = 2$ までの観測値を用いれば，実際に MAS を実行した際に誤差が 0 となる経路別の通行人数を推定することができる．提案手法では時間帯 t における経路別の通行開始人数 $\mathbf{x}_t$ を推定するために，時間帯 t に発出発したエージェントが到着までにかかる時間帯の最大個数（時間遅れ定数）D を導入し，以下の目的関数を最適化する．

$$L_t = \sum_{k=t}^{t+D} |\mathbf{y}_k - \hat{\mathbf{y}}_k|$$

また，MAS 上における各時間帯の各観測地点の通過人数 $\hat{\mathbf{y}}_t$ は以下のように算出する．

$$\hat{\mathbf{y}}_t, \cdots, \hat{\mathbf{y}}_{t+D} = f^{MAS}(\mathbf{x}_{t-D}, \cdots, , \mathbf{x}_t, \cdots, \mathbf{x}_{t+D}), \qquad t = 1, 2, \ldots, T$$

$\mathbf{x}_t$: 変数

$\mathbf{x}_{t-D}, \cdots, \mathbf{x}_{t-1}, \mathbf{x}_{t+1}, \cdots, \mathbf{x}_{t+D}$: 定数

ここで，$\hat{\mathbf{y}}_t, , \cdots, \hat{\mathbf{y}}_{t+D}$ には時間帯 t に出発するエージェントだけではなく，時間帯 $t - D, \ldots, t - 1, t + 1, \ldots, t + D$ に出発するエージェントも影響を与えるため，$\mathbf{x}_{t-D}, \cdots, \mathbf{x}_{t-1}, \mathbf{x}_{t+1}, \cdots, \mathbf{x}_{t+D}$ は定数として入力する．

4. 評価実験

本章では，複数のイベントにおいて観測したデータに提案手法を適応することで手法の有効性を検証する．まず初めに実験に用いたシミュレータ，観測したイベントデータ，評価指標値などの実験設定について述べる．その後，提案手法に用いる時間遅れ定数 D を決定するための事前分析を行う．最後に，本手法の性能を評価するための実験を行い，考察を述べる．

4.1 実験設定

MAS：本稿では，我々が独自で開発している MAS[2] を用いる．この MAS はエージェントの出発時刻，移動する移動経路を記述したユーザリストとエージェントが動く道路ネットワークを入力することで動作する．各時間帯 t における移動経路別の通行人数 $\mathbf{x}_t$ をもとに各エージェントの発生時刻，通行する経路を決定し，ユーザリストに記述する．また，道路ネットワークは，ノードと幅を持ったエッジから構成される．各エージェントはユーザリストに記述された経路上を出発地から目的地まで最短距離の経路で行動する．MAS はシミュレーション終了後に，エージェントが観測地点のノードを通過した時間を出力する．その値をもとにシミュレーション上の時間帯ごとの通過人数 $\hat{\mathbf{y}}_t$ を出力する．

イベントデータ：実験用のデータには，早稲田祭 2016[*1] と YOYOGI CANDLE 2020[*2] という二つのイベント時に複数の観測地点において目視で観測された通過人数のデータを用いる．どちらのイベントも大規模な移動が伴うイベントであるため，本手法の有効性の確認に適していると考えられる．会場周辺地図と観測場所のマップを図 4，図 5 に示す．マップ上にあるアルファベットが書かれている場所が観測地点であり，そこから伸びる赤線を矢印方向に通過した人数が観測値となる．早稲田大学周辺においては駅と大学を結ぶ主要な道を移動経路としている．また，YOYOGI CANDLE 2020 は観覧場所にてプロジェクションマッピングを観覧するイベントであったため，観覧場所を目的地と考え，移動経路は駅やデパートと観覧場所を結ぶ道としている．それぞれのイベントの観測条件を表 1 に示す．

評価指標値：推定精度の検証のため，推定した各時間帯 t の移動経路の通行人数 $\mathbf{x}_t$ をもとに MAS を実行し，実際の観測値との比較を行う．評価指標値には，各時間帯 t に集計した観測値 $\mathbf{y}_t$ とシミュレーション上で同様に集計した観測値 $\hat{\mathbf{y}}_t$ との

*1 http://www.wasedasai.net/2016/
*2 http://www.ntt.co.jp/topics/pdf/topics_20171130.pdf

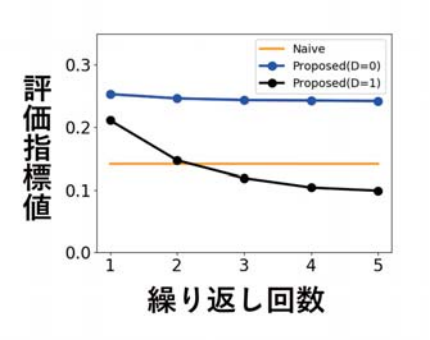


図 6: 全時間帯における精度評価

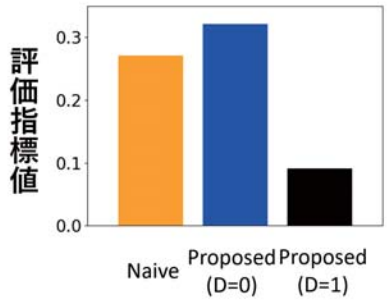


図 7: 混雑した時間帯における精度評価

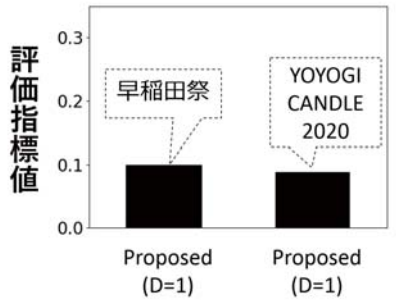


図 8: 複数データセットにおける精度評価

イベント名	早稲田祭	YOYOGI CANDLE 2020
移動経路数	24 本	26 本
観測場所数	15 箇所	28 箇所
観測時間間隔	10 分	5 分

表 1: 観測条件

標準化絶対誤差 (normalized absolute error：NAE)

$$\mathrm{NAE} = \sum_t \frac{|\mathbf{y}_t - \hat{\mathbf{y}}_t|}{|\mathbf{y}_t|}$$

を用いる．

比較手法：比較には，関連研究で述べた，統計モデルを用いた移動時間を考慮しない手法 (niave) を用いる．

4.2 時間遅れの決定

早稲田祭においては観測時間間隔が 10 分であり，移動経路の通行時間が長く見積もっても 20 分以内であると考えられるため，今回は時間遅れ定数 $D = 1$ とした．また，YOYOGI CANDLE 2020 についても同様のことが考えられるため，同じく $D = 1$ とした．

4.3 実験結果

図 6 にそれぞれの手法により推定した導線の通行人数をもとに MAS を実行した際の評価指標値を示す．実験は早稲田祭のデータを用いて実施した．横軸は推定を行った繰り返し回数である．提案手法は推定する $\mathbf{x}$ の探索問題となるため，繰り返し回数数に応じて推定精度をプロットしている．統計モデルを用いた手法は推定一度しか行わないため，繰り返し回数にかかわらず一定の値としている．図 6 からわかるように，提案手法 ($D = 1$) が最も良い推定精度となっている．既存手法と提案手法 ($D = 1$) の結果から分かるように，MAS を用いた移動時間の考慮が効果的に作用していることがわかる．また，提案手法 ($D = 0$) との比較から分かるように，移動時間を考慮したとしても例 2 で説明した問題は発生しうるため，時間遅れを考慮した目的関数を設定することが重要であることがわかる．

また，図 7 に観測時に混雑が発生した時間帯における誤差を示す．提案手法 ($D = 1$) は混雑時も精度を維持したまま推定することができている．この時間帯は早稲田祭のパレードが行われていた時間帯であり，観客の移動時間が長くなり，時間遅れの効果が顕著に表れたためだと考えられる．

図 8 に提案手法を複数データセットに用いた評価を示す．図 8 からも分かるようにイベントの実施場所や観測時間間隔によらずに，高精度な推定を行うことができている．

5. まとめ

本稿では，大人数の移動が伴う大規模イベントにおける MAS による警備計画策定のため，複数地点において観測された通過人数から，移動経路別の通行人数を推定した．推定にあたり，ユーザの移動時間を考慮する方法として，MAS を用いた推定フレームワークを提案した．また，ユーザが複数時間帯にまたがり観測される可能性があるため，時間遅れを考慮した目的関数に変更することにより高精度な推定を実現した．今後は実用化に向け，本技術を用いた実験を重ね，利用者からフィードバックをもらうことでさらなる技術改善に取り組みたい．

参考文献

[1] NEC、数万人規模の混雑度と人の流れをリアルタイムかつ高精度に予測する技術を開発～群衆行動解析技術を強化～. http://jpn.nec.com/press/201610/20161024_05.html.

[2] 時空間多次元集合データ解析技術による集団最適誘導. http://www.ntt.co.jp/journal/1707/files/JN20170724.pdf.

[3] 人の流れの計測とシミュレーションによる避難誘導方法の伝承. 人工知能学会研究会資料 SIG-KST-026-06(2015-11-13).

[4] 東京 2020 大会開催基本計画. https://tokyo2020.org/jp/games/plan/data/GFP-JP.pdf.

[5] 動線計測ソリューション. http://www.hitachi-ite.co.jp/products/o-tracking/.

[6] Carl Edward Rasmussen and Christopher KI Williams. *Gaussian process for machine learning*. MIT press, 2006.

[7] Jasper Snoek, Hugo Larochelle, and Ryan P Adams. Practical bayesian optimization of machine learning algorithms. In *Advances in neural information processing systems*, pp. 2951–2959, 2012.

[8] Yin Zhang, Matthew Roughan, Nick Duffield, and Albert Greenberg. Fast accurate computation of large-scale ip traffic matrices from link loads. In *ACM SIGMETRICS Performance Evaluation Review*, Vol. 31, pp. 206–217. ACM, 2003.

[9] 犬飼洋平, 小国健二, 堀宗朗. 計測に基づく避難行動マルチエージェントシミュレータの開発. 応用力学論文集, Vol. 8, pp. 629–636, 2005.

[10] 山下倫央, 野田五十樹. 屋外大規模イベントにおける群集規制モデルの構築, 人工知能学会全国大会 2014 (jsai2014) 予稿集. 2014.

[11] 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推定. 第２０回情報的学習理論ワークショップ（IBIS2017）, 2017.

[12] 清武寛, 幸島匡宏, 松林達史, 戸田浩之. 最適制御策の効率的探索技術に関する研究. 第 31 回 人工知能学会全国大会論文集, 3N1-2in2, 2017.

[13] 川口英俊, 野田五十樹. 人流シミュレーションにおける複数の評価基準を考慮した時間別 od 表の推定. 人工知能学会全国大会論文集, Vol. 29, pp. 1–4, 2015.

[14] 東京都オリンピックパラリンピック準備局. 東京 2020 オリンピック・パラリンピック競技大会フォローアップ計画書（新国立競技場（オリンピックスタジアム））. https://www.2020games.metro.tokyo.jp/followupkeikaku_olympicstadium_all.pdf.

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

人間の環世界から見たエージェントモデル –AI Safetyの実現に向けて

Modeling Agents from the Perspective of Human Umwelt towards AI Safety

福地庸介 *1 Yosuke Fukuchi　大澤正彦 *1*2 Masahiko Osawa　山川宏 *3*4 Hiroshi Yamakawa　今井倫太 *1 Michita Imai

*1慶應義塾大学理工学研究科 Graduate School of Science and Technology, Keio University

*2日本学術振興会 特別研究員 (DC1) Research Fellow of Japan Society for the Promotion of Science (DC1)

*3株式会社ドワンゴ ドワンゴ人工知能研究所 DWANGO Co., ltd Dwango Artificial Intelligence Laboratory

*4全脳アーキテクチャ・イニシアティブ The Whole Brain Architecture Initiative

Transparency in machine learning (ML) agents' decision making is crucial for achieving AI Safety. However, it is difficult to comprehend agents' behavior because gaps of perception, mobility, desire, and time scale between humans and ML agents obstruct people to mentalize the agents. In this paper, we propose a model of human's inference of ML agents' mental states so as to explain the agents' behavior from the perspective of humans.

1. はじめに

深層強化学習をはじめとする機械学習技術の進展により，ビッグデータと呼ばれる複雑で大量の情報をもとに行動を決定するエージェントが実現されている．またエージェントは，より複雑な行動を扱えるようになっている．

しかし，エージェントが複雑な情報処理を扱うようになるにつれて，エージェントの振舞いを理解することは難しくなっていく．エージェントの振舞いが理解不能となることは，人間と同じ環境を共にするエージェントにおいて特に深刻な問題である．人間の意図/予期しない振舞いが致命的な事故に繋がるためである．AI Safety[Amodei 16] を実現する上で，エージェントの振舞いに対する透明性を向上させ，人間がエージェントを理解できるようにすることが重要といえる．

機械学習によって獲得された振舞いの透明性を向上し，人間にエージェントを理解させる手法として，エージェントの行動の履歴から振舞いを確率的にモデル化して得られたモデルを自然言語で説明する方法が提案されている [Hayes 17]．また画像処理の分野では，大量のパラメータで表現されていて人間には理解が難しい深層学習器の分析が盛んに行われている [Le 13]．

いずれの手法も，行動決定を行う機械学習モデルが扱う情報空間の範疇で振舞いを説明している．しかしエージェントと人間は，同じ環境にあってもそれぞれ異なる観測空間の中で環境を知覚し，それぞれの時間・報酬・行動空間を持っている．本稿では，人間・エージェントそれぞれが固有に持っている情報空間を環世界と呼ぶ．人間とエージェント間の環世界の違いはエージェントの理解を難しくする．また人間が「盲導犬は信号の色を見て行動決定している」と誤解してしまうように，環世界の違いがエージェントを理解する際のバイアスとなり，エージェントの振舞いに対する致命的な誤解を生じさせる原因にもなる．

そこで本稿では，人間からはエージェントの振舞いはどのように理解されるのか，をモデル化した “人間の環世界から見たエージェントモデル” を提案する．人間の環世界から見たエージェントモデルの構築は，人間の情報空間の中でエージェントの振舞いを説明することや，人間がエージェントに対して抱く誤解を検知することにつながると考えられる．

連絡先: 慶應義塾大学理工学部情報工学科今井研究室
〒 223–0061 神奈川県横浜市港北区日吉 3–14–1
E-mail: fukuchi@ailab.ics.keio.ac.jp

2. 他者理解と環世界

2.1 人とエージェントの環世界

ユクスキュルは，生物が認識している世界が，生物種それぞれが持つ知覚と作用の上で構築される主観的な世界 (環世界) であると考えた [ユクスキュル 05]．環世界は，行動主体が持っている知覚器官からの情報で構成される知覚世界と，主体が働きかけられる対象から構成される作用世界の統一体とされる．

機械学習によって行動を獲得するエージェントもまた，行動によって環境に働きかけ，観測と報酬によって環境を知覚する，という一つの環世界を構築していると考えられる．

そこで本稿では，エージェント α の環世界 E^α を，エージェントが扱う状態空間 $\boldsymbol{S}^\alpha$，観測空間 $\boldsymbol{\Omega}^\alpha$，知覚時間 t^α と報酬関数 R^α からなる知覚世界，行動空間 $\boldsymbol{A}^\alpha$ からなる作用世界として，$E^\alpha = (\boldsymbol{S}^\alpha, \boldsymbol{\Omega}^\alpha, R^\alpha, \boldsymbol{A}^\alpha, t^\alpha, T^\alpha, O^\alpha)$ と考える．T^α, O^α はそれぞれ，エージェントが状態 $s^\alpha \in \boldsymbol{S}^\alpha$ のもとで行動 $a^\alpha \in \boldsymbol{A}^\alpha$ をとった際の状態遷移確率と観測確率である．同様に人間の環世界を $E^h = (\boldsymbol{S}^h, \boldsymbol{\Omega}^h, R^h, \boldsymbol{A}^h, t^h, T^h, O^h)$ とモデル化して考えることにする．

2.2 他者理解の壁となる環世界の違い

2.2.1 観測空間

人間の観測空間は，視覚や聴覚といった五感からの情報で構成される．一方磁力センサによって環境を認識するエージェントのように，人間が持っている観測空間と対応関係がない場合人間にはエージェントが環境の何を知覚できているのかを判断することが難しくなる．また，環境の状態の中でエージェントが知覚できていている範囲を推定することも難しい．

エージェントが環境の何をどのように観測しているかは，エージェントの振舞いを予測する際や，エージェントが環境に対して持つ信念を推定する際に重要な情報である．

2.2.2 行動空間

エージェントが関節角やモータの制御値のような低レイヤの行動を扱う場合や，蛇型エージェントのように人間の行動空間と離れた行動を扱うエージェントの場合，エージェントが扱う行動空間の値をそのまま人間が理解するのは難しい．

人間がエージェントの振舞いを理解し予測する際は，エージェントが実際に扱う低レイヤの行動空間ではなく，「右に行く」「手を伸ばす」といった，より抽象的な行動空間の中でエージェントの振舞いを捉えていると考えられる．

2.2.3 知覚時間

強化学習によって行動を獲得したエージェントの場合，エージェントの扱う時間ステップのたびに行動決定が行われる．しかしエージェントが行動を選択する際の時間間隔は，人間がエージェントを理解するには短すぎる場合が存在する．

例えば，深層強化学習を用いてゲーム内のエージェントを制御する [Mnih 15] では，エージェントが 4 フレームに一度行動を選択している．行動選択の時間間隔は 67 (msec) である．一方人間は，単一の刺激に対して単一の反応を行うだけでも 150 (msec) 以上の時間がかかるとされる [大山 85]．人間にはエージェントの知覚時間の単位の情報は扱いきれず，人間はより大きな時間粒度でエージェントの振舞いを捉えていると考えられる．

2.3 環世界の違いを超えた他者理解

人間とエージェントの環世界には大きなギャップが存在する．しかし機械学習によって行動獲得するエージェントの透明性の向上に関する従来研究では，エージェントの環世界の範疇でのみ振舞いが説明されてきた．環世界の乖離はエージェントの扱うタスクや行動が複雑になるにつれて大きくなると予想される．そのため人間が一方的にエージェントの環世界に合わせるのではなく，エージェントもまた人間の環世界を考慮して人間とインタラクションを行うべきだと考えられる．

マルチエージェントシステムの分野では，環世界の異なるエージェントがどのような信念や欲求を持っているかをエージェントの観測を元に推定する研究がある [Rabinowitz 18]．しかし Human-Agent Interaction の枠組の中で，機械学習によって獲得された振舞いが人間固有の環世界から見てどのように理解・解釈されるか，ということは考えられてこなかった．

そこで本稿では，人間が観測し理解できる情報だけの範疇でエージェントの振舞いを解釈し説明する「人間の環世界からみたエージェントモデル」を提案する．提案モデルでは，エージェントの観測空間と無関係に，人間の観測空間で得られる情報からエージェントの振舞いを扱う．またエージェントが選択する低レイヤーの行動ではなく，より抽象度の高いレベルでエージェントの行動を捉える．さらにエージェントが扱う時間粒度ではなく，より長期的な時間粒度でエージェントの振舞いをモデル化する．

環世界の違いから，提案するモデルはエージェントの真の行動決定と整合性の取れない場合が予想される．例えばエージェントが人間と異なる観測空間を扱う場合，人間の環世界からはエージェントの振舞いを説明しきれないと考えられる．提案モデルの目的は，エージェントの行動決定を正確に説明するモデルを構築することよりも，エージェントを観測する人間がエージェントに対して想定してしまう振舞いのモデル再現することにある．

2.4 扱う環境

本稿では，シミュレーション環境 [Catto] で機械学習による行動獲得を行なったエージェントを対象として，人間の環世界から見たエージェントモデルを考える．エージェントはロケット型でジェット噴射を操作することで特定の位置に移動する行動を獲得している．

エージェントの観測空間 $\mathbf{\Omega}^\alpha$ は，環境に関する 8 次元のパラメータ群で構成される．エージェントは固有の報酬関数 R^α を持ち，観測 ($\omega^\alpha \in \mathbf{\Omega}^\alpha$) と信念 ($b^\alpha \in \boldsymbol{B}^\alpha$) を元に行動 ($a^\alpha \in A^\alpha$) を選択する．

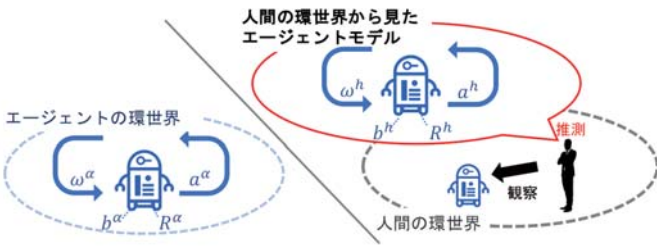


図 1: エージェント固有の環世界の中で行動決定するエージェント (左) と，人間の環世界から見たエージェントモデル (右)

3. 人間の環世界から見たエージェントモデル

3.1 モデル概要

人間の環世界から見たエージェントモデルは，エージェントの環世界 E^α と独立して，人間の環世界 E^h からエージェントを観察した際のエージェントの振舞いをモデル化したものである (図 1)．提案モデルは，[Baker 17] をもとに，エージェントの行動決定を E^h における部分観測マルコフ過程 [Kaelbling 98] として扱う．また提案モデルはエージェントが持つ報酬空間 R^α の情報は持たず，人間が想定するエージェントの信念状態と報酬関数の仮説の集合 $\boldsymbol{B}^h$，$\boldsymbol{R}^h$ を持ち，人間から見たエージェントの報酬関数 $R^h \in \boldsymbol{R}^h$ と信念 $b^h \in \boldsymbol{B}^h$ を確率分布として推定する．

3.2 実際のエージェントへの適用

本稿では，2.4 節で紹介したエージェントを対象に，人間の環世界から見たエージェントモデルを構築する．人間はエージェントを視覚により観察していると仮定して，$\mathbf{\Omega}^h$ はエージェントの位置情報と速度のみで構成されるとする．また人間が持つ時間粒度の大きさを考慮して，人間が扱う時間 t^h はエージェントが扱う時間ステップ t^α に対して $t^h = k \cdot t^\alpha$ とする．人間がエージェントに対して想定する行動空間 $\boldsymbol{A}^h$ を扱うため，つもり抽出 [丹羽 12] を参考にした事前実験を行う．事前実験では，人間がエージェントの動きを観察し、エージェントになったつもりになってゲームコントローラを操作させることで，人間がエージェントに対して想定する行動と，その際の状態遷移確率を抽出する．

4. おわりに

本稿では，AI Safety の実現に向けてた取り組みとして，人間からはエージェントの振舞いはどのように理解されるのか，をモデル化した “人間の環世界から見たエージェントモデル” を提案した．提案モデルは，人間の環世界の中でエージェントの振舞いを説明することや，人間がエージェントに対して抱く誤解を扱う際に重要なモデルであると考えられる．

今後は構築されるモデルを，実際に人間が考えるエージェントモデルと比較することで検証する．さらに，構築されるモデルにもとづいて，エージェントの振舞いを人間に理解させるためのインタラクションを検討していく．

参考文献

[Amodei 16] Amodei, D., et al. : Concrete problems in AI safety. arXiv preprint arXiv:1606.06565 (2016)

[Le 13] Le, Q. V. : Building high-level features using large scale unsupervised learning. IEEE International Conference on Acoustics, Speech and Signal Processing, pp. 85958598. (2013)

[ユクスキュル 05] ユクスキュル, クリサート (日高敏隆, 羽田節子訳), 生物から見た世界, 岩波書店. (2005)

[Hayes 17] Hayes, B., Shah, J. A. : Improving Robot Controller Transparency Through Autonomous Policy Explanation. Proceedings of the 2017 ACM/IEEE International Conference on Human-Robot Interaction. ACM, pp. 303312. (2017)

[Mnih 15] Mnih, V., et al.: Human-level control through deep reinforcement learning. Nature 518, 7540 pp. 529533. (2015)

[大山 85] 大山正.: 反応時間研究の歴史と現状. 人間工学 21 (2) pp. 57-64. (1985)

[Kaelbling 98] Kaelbling, L. P., et al.: Planning and acting in partially observable stochastic domains. Artificial Intelligence 101, 99134 (1998).

[Catto] Catto, E. Box2d: A 2d physics engine for games. Accessed: 2017/5/26.

[丹羽 12] 丹羽真隆ら.: つもり制御: 人間の行動意図の検出と伝送によるロボット操縦 (<特集> テレイグジスタンスのためのロボティクス・グラフィクス・インタフェース). 日本バーチャルリアリティ学会論文誌 17.1. (2012)

[Rabinowitz 18] Rabinowitz, N. C., et al. : Machine Theory of Mind. arXiv preprint arXiv:1802:07740 (2018).

[Baker 17] Baker, C. L., et al..: Rational quantitative attribution of beliefs, desires and percepts in human mentalizing. Nature Human Behaviour, 1(4):0064. (2017)

[3J2] [General Session] 7. Agent

座長:金森 亮（名古屋大学）

Thu. Jun 7, 2018 3:50 PM - 5:30 PM Room J (2F Royal Garden B)

[3J2-01] A Study of Optimization Method Considering Bottlenecks in Asymmetric Constraint Optimization Problem

○Toshihiro Matsui[1] （1. Nagoya Institute of Technology）

3:50 PM - 4:10 PM

[3J2-02] Impact of Ego-Ships in Ship Collision Avoidance using Distributed Stochastic Search Algorithm

Hiroki Karato[1], ○Katsutoshi Hirayama[1], Tenda Okimoto[1], Donggyun Kim[2] （1. Kobe University, 2. Beijing Institute of Technology）

4:10 PM - 4:30 PM

[3J2-03] Modeling of Classroom SNSs and Classroom Network Based on the Socion Theory

○Kosuke Naito[1], Shohei Kato[1,2] （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）

4:30 PM - 4:50 PM

[3J2-04] Continuous conversation with two-robot coordination

○Hiroaki Sugiyama[1], Masahiro Mizukami[1], Hiromi Narimatsu[1] （1. NTT Communication Science Labs.）

4:50 PM - 5:10 PM

[3J2-05] A Preliminary Approach on a Coalition Formation Simulator with Inertia on Continuous Cooperative Games

○Masaaki Horie[1], Naoki Fukuta[1] （1. Shizuoka University）

5:10 PM - 5:30 PM

©The Japanese Society for Artificial Intelligence

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

非対称な制約最適化問題におけるボトルネック最適化手法の一検討

A Study of Optimization Method Considering Bottlenecks in Asymmetric Constraint Optimization Problem

松井 俊浩
Toshihiro Matsui

名古屋工業大学
Nagoya Institute of Technology

The representation of Constraint Optimization Problems for multiagent systems has been addressed in several studies including Distributed Constraint Optimization. We focus on the asymmetric problem where each objective function is defined as an evaluation of an individual agent. While this class of problems is studied as a multi-objective problem, there are opportunities to investigate various types of solution methods. In this study we investigate the possibility of the framework based on the Lagrangian dual methods. We address a bottleneck problem that minimizes the worst case cost. As the initial study, we experimentally apply and evaluate a formalization of the problem.

1. はじめに

制約最適化問題によるマルチエージェントシステム上の問題の汎用的な表現は，非集中型の最適化手法を扱う分散制約最適化問題 [Farinelli 08, Modi 05, Petcu 05, Zivan 08] を含む研究において検討されている．この制約最適化問題は，エージェントの状態を表す変数と，変数間の関係を表す複数の目的関数から構成される．従来の問題の定式化では目的関数がエージェント間で共通である．これに対し，近年，目的関数が個々のエージェントについての評価として定義される非対称な問題が検討されている [Netzer 11, A. Netzer and A. Meisels 13, Netzer 13, Matsui 14, Matsui 15].

分散制約最適化問題の解法にはいくつかのアプローチがあるが，非対称な問題についての解法では厳密解法とその近似，および局所探索の検討が比較的多い．そこで，他のアプローチに基づく解法として，ラグランジュ双対問題に基づく解法の枠組み [波多野 12, Hatano 13] についての検討の余地があると考えられる．本研究では，マルチエージェントシステム上の多目的最適化問題のための非対称な制約最適化問題に，ラグランジュ双対問題に基づく解法の枠組みを適用する基礎検討として，エージェントの最適コストを最小化するボトルネック問題への適用を試みる．また，初期の評価として，このような解法の枠組みの挙動を実験的に評価する．

2. 準備

2.1 マルチエージェント最適化を模倣する制約最適化問題

マルチエージェント最適化を模倣する基本的な制約最適化問題を示す．問題は (A, X, D, F) により定義される．A はエージェントの集合，X は変数の集合，D は変数の値域の集合，F は目的関数の集合である．

変数は $x_i \in X$ はエージェント $i \in A$ の状態を表す．簡単のためにエージェントは一つの変数を持つとし，エージェントと変数の添え字を同一視する．変数 x_i は離散値の集合である値域 $D_i \in D$ に含まれる値をとる．

連絡先: 松井 俊浩，名古屋工業大学，〒 466-8555 愛知県名古屋市昭和区御器所町，matsui.t@nitech.ac.jp

目的関数 $f_{i,j}(x_i, x_j) \in F$ は変数 x_i と x_j の値の組み合わせのコスト値を定義する．目的関数はすべて二項関数 $f_{i,j} : D_i \times D_j \to \mathbb{N}_0$ として定義される．

大域的な目的関数を各エージェントの目的関数 $f_{i,j}$ の合計関数 $F = \sum_{f_{i,j} \in F} f_{i,j}$ とする．目的は，大域的な目的関数 F の値を最小化するような変数値の組み合わせを求めることである．

2.2 非対称な制約最適化問題のボトルネック最適化

非対称な制約最適化問題では，従来の制約最適化問題ではエージェント間で共通である目的関数が，各エージェントの固有の目的関数として，定義される．次のような非対称な制約最適化問題を用いる．非対称な制約最適化問題は (A, X, D, F) によりに定義される．A, X, D は基本的な制約最適化問題と同様である．F は非対称な目的関数の集合である．

目的関数 $f_{i,j}(x_i, x_j) \in F$ は変数 x_i と x_j の値の組み合わせのコスト値を定義する二項関数である．ここで，関数 $f_{i,j}(x_i, x_j)$ は片側のエージェント i の評価とする．すなわち，$f_{i,j}(x_i, x_j)$ と $f_{j,i}(x_j, x_i)$ をそれぞれ同一の変数のペアについての，エージェント i および j 固有の評価とする．エージェント間の関係を簡単に扱うために，$f_{i,j}$ と $f_{j,i}$ が同時に定義されるとする．

エージェント i の局所的なコストは，i の固有の評価関数の合計 $F_i = \sum_k f_{i,k}$ をとして定義される．すなわち，各エージェント i が自身の目的関数 F_i を持つ多目的最適化問題となる．

大域的な目的関数を各エージェントの目的関数 F_i を最大化関数により結合した関数 $F = \max_k(F_i)$ とする．目的は，大域的な目的関数 F の値を最小化するような変数値の組み合わせを求めることである．

2.3 関連手法

分散制約最適化問題の解法として，ラグランジュ双対問題を利用する手法が提案されている [波多野 12, Hatano 13][*1]．この手法では元の問題をラグランジュ緩和した問題の下界を最大化することにより，反復的に解の改善を試みる．本研究では初期の検討として，集中型の解法の枠組みを用いるが，基本的な形式化は従来手法に準じる．

*1 この手法ではエージェント内に局所的な問題があるような，より複雑な場合を対象とするが，これには上記の基本的な制約最適化問題と同様の場合も含まれる．以降では関連する部分のみを抜粋する．

問題は次のように表現される．

$$\text{minimize} \quad \sum_{f_{i,j} \in F} \alpha_i^{i,j\,T} f_{i,j} \alpha_j^{i,j} \tag{1}$$

$$\text{subject to} \quad x_i = \alpha_i^{i,j} \ \ \forall f_{i,j} \in F$$
$$x_j = \alpha_j^{i,j} \ \ \forall f_{i,j} \in F \tag{2}$$

ここで $x_k, \alpha_k^{i,j}$ は，変数の値域の大きさに等しい次元のベクトルであり，いずれか一つの要素のみが 1，他の要素は 0 とする．

この問題は，実数値をとる列ベクトルである，ラグランジュ乗数 $u_k^{i,j}$ を用いて次のように緩和される．

$$\text{minimize} \quad \sum_{f_{i,j} \in F} \alpha_i^{i,j\,T} f_{i,j} \alpha_j^{i,j} + \sum_{f_{i,j} \in F} u_i^{i,j}(x_i - \alpha_i^{i,j}) + \sum_{f_{i,j} \in F} u_j^{i,j}(x_j - \alpha_j^{i,j}) \tag{3}$$

この緩和問題は元の問題の下界を与える．この緩和問題を主問題として，ラグランジュ双対問題を用いる最適化を行う．詳細は文献を参照されたい．

3. 解法の枠組

従来手法のアプローチを，ボトルネックを最適化する，すなわちエージェントの最大コストを最小化する問題に適用することを意図し，次のように問題を表現する．ここで，β は目的関数かつ制約条件である．

$$\text{minimize} \quad \beta \tag{4}$$

$$\text{subject to} \quad (\sum_{f_{i,j} \in F_i} \alpha_i^{i,j\,T} f_{i,j} \alpha_j^{i,j}) \leq \beta \ \ \forall F_i \subseteq F$$
$$x_i = \alpha_i^{i,j} \ \ \forall f_{i,j} \in F$$
$$x_j = \alpha_j^{i,j} \ \ \forall f_{i,j} \in F$$

この問題を次のように緩和する．ここでは，β についての制約条件も緩和する．u^{F_i} はスカラ値となる．

$$\text{minimize} \quad \beta + \sum_{F_i \subseteq F} u^{F_i}((\sum_{f_{i,j} \in F_i} \alpha_i^{i,j\,T} f_{i,j} \alpha_j^{i,j}) - \beta) + \sum_{f_{i,j} \in F} u_i^{i,j}(x_i - \alpha_i^{i,j}) + \sum_{f_{i,j} \in F} u_j^{i,j}(x_j - \alpha_j^{i,j}) \tag{5}$$

ここで，複数エージェントに上式の要素を分散させることを意図し，各エージェント i ごとの部分問題を次のように定義した．ここで，$u_j^{i,j} = u_i^{j,i}$ とした．

$$u^{F_i}((\sum_{f_{i,j} \in F_i} \alpha_i^{i,j\,T} f_{i,j} \alpha_j^{i,j}) - \beta) + \sum_{f_{i,j} \in F_i} (u_i^{i,j}(x_i - \alpha_i^{i,j}) - u_j^{i,j} \alpha_j^{i,j}) + \sum_{f_{j,i} \in F_j} u_i^{j,i} x_i \tag{6}$$

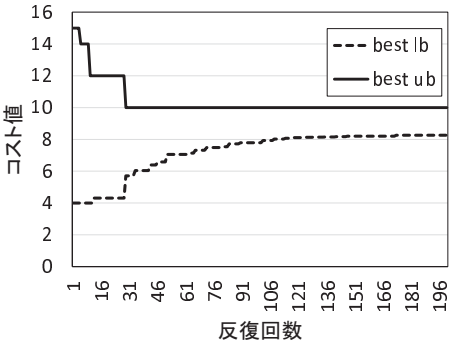


図 1: 上下界の anytime グラフの例

β はエージェント間で共有される情報であることから，同値制約などを導入する分解の方法を検討する必要があると考えられるが，ここでは初期の検討として，集中処理により各エージェントの部分問題の探索を結合して最小化した，共通の β の下での挙動を見ることとした．

解法の枠組みは従来手法と類似する次のような方法を用いた．

1. 各 $u^{F_i}, u_k^{i,j}$ の要素をゼロに初期化する．
2. 各エージェント i について，$u^{F_i}, u_k^{i,j}$ のもとで部分問題を最小化する x_i と各 $\alpha_k^{i,j}$ を探索する．集中処理により，共通の β に対する大域的な下界値を得る．最良の下界値を更新する．
3. 各エージェントの変数値を交換し，大域的な上界を得る．最良の上界値を更新する．また，各制約を緩和した項について，ギャップを求める．
4. 最良の上下界値の差分とギャップに基づき，各 $u^{F_i}, u_k^{i,j}$ を更新する．ここでは，従来手法で用いられている劣勾配法に類似する手法を用いた．共有される $u_k^{i,j}$ を交換する．
5. 終了条件を満たすまで，手順 2 からの処理を繰り返す．

ここでは主問題の最小化に厳密解法を用いる．その一方で，各 $u^{F_i}, u_k^{i,j}$ の更新は非厳密解法であり，問題の構造が従来手法と異なることから，局所解への誤収束の可能性が考えられる．初期の検討として，実験的に挙動を確認することとした．

4. 実験

上記の手法について，実験により挙動を調査した．5 エージェント 3 値変数の場合の上界と下界の挙動の例を図 1 に示す．この例では，摂動により上界は最適値に到達した．その一方で，下界の改善がある程度のところから進まない状況に陥った．小規模な問題で，最小コストが比較的場合には，上下界が一致する場合も見られたが，上記の結果のように，特に下界の収束性に課題が見られた．

5. おわりに

本研究では，マルチエージェントシステム上の多目的最適化問題のための非対称な制約最適化問題に，ラグランジュ双対問題に基づく解法の枠組みを適用する初期検討として，エージェントの最適コストを最小化するボトルネック問題への適用を試

みた．結果からは局所解への収束が比較的顕著であることが示され，定式化と解法の改善および，より網羅的な評価が今後の課題である．また，他の類似する指標への適用も実際面への展開のための課題である．

参考文献

[A. Netzer and A. Meisels 13] A. Netzer and A. Meisels, : Distributed Envy Minimization for Resource Allocation, in *5th International Conference on Agents and Artificial Intelligence*, Vol. 1, pp. 15–24 (2013)

[Farinelli 08] Farinelli, A., Rogers, A., Petcu, A., and Jennings, N. R.: Decentralised coordination of low-power embedded devices using the max-sum algorithm, in *7th International Joint Conference on Autonomous Agents and Multiagent Systems*, pp. 639–646 (2008)

[Hatano 13] Hatano, D. and Hirayama, K.: DeQED: An Efficient Divide-and-Coordinate Algorithm for DCOP, in *IJCAI 2013, Proceedings of the 23rd International Joint Conference on Artificial Intelligence, Beijing, China, August 3-9, 2013*, pp. 566–572 (2013)

[Matsui 14] Matsui, T., Silaghi, M., Hirayama, K., Yokoo, M., and Matsuo, H.: Leximin Multiple Objective Optimization for Preferences of Agents, in *17th International Conference on Principles and Practice of Multi-Agent Systems*, pp. 423–438 (2014)

[Matsui 15] Matsui, T., Silaghi, M., Okimoto, T., Hirayama, K., Yokoo, M., and Matsuo, H.: Leximin Asymmetric Multiple Objective DCOP on Factor Graph, in *18th International Conference on Principles and Practice of Multi-Agent Systems*, pp. 134–151 (2015)

[Modi 05] Modi, P. J., Shen, W., Tambe, M., and Yokoo, M.: Adopt: Asynchronous distributed constraint optimization with quality guarantees, *Artificial Intelligence*, Vol. 161, No. 1-2, pp. 149–180 (2005)

[Netzer 11] Netzer, A. and Meisels, A.: SOCIAL DCOP - Social Choice in Distributed Constraints Optimization, in *5th International Symposium on Intelligent Distributed Computing*, pp. 35–47 (2011)

[Netzer 13] Netzer, A. and Meisels, A.: Distributed Local Search for Minimizing Envy, in *2013 IEEE/WIC/ACM International Conference on Intelligent Agent Technology*, pp. 53–58 (2013)

[Petcu 05] Petcu, A. and Faltings, B.: A Scalable Method for Multiagent Constraint Optimization, in *19th International Joint Conference on Artificial Intelligence*, pp. 266–271 (2005)

[Zivan 08] Zivan, R.: Anytime Local Search for Distributed Constraint Optimization, in *Twenty-Third AAAI Conference on Artificial Intelligence*, pp. 393–398 (2008)

[波多野 12] 波多野 大督, 平山 勝敏：DeQED: 双対変数の値を交換する分散制約最適化アルゴリズム, 人工知能学会全国大会論文集, p. 1E3 (2012)

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

分散確率的探索アルゴリズムを用いた船舶衝突回避における非協力船舶の影響

Impact of Ego-Ships in Ship Collision Avoidance using Distributed Stochastic Search Algorithm

唐渡 裕基 *1 Hiroki Karato　平山 勝敏 *1 Katsutoshi Hirayama　沖本 天太 *1 Tenda Okimoto　金 東均 *2 Donggyun Kim

*1神戸大学 Kobe University　*2北京理工大学 Beijing Institute of Technology

DSSA_SCA is a state-of-the-art distributed algorithm for solving the Ship Collision Avoidance (SCA) problem. This work empirically investigates how the existence of "Ego-Ship", who cannot communicate her intention with neighboring ships, affects the performance of DSSA_SCA using some sample data from www.vesselfinder.com.

1. はじめに

国土交通省運輸安全委員会が公開している船舶事故の統計によれば，毎年 200 件を越える船舶同士の衝突事故が発生している．船舶衝突事故による人的，経済的，環境的被害は規模によっては甚大なものとなるため，それを避ける手段として，現状，法的あるいは技術的な対策が複数講じられている．

一つ目は船舶運用規則の制定である．1972 年に国際海上衝突予防規則（通称 COLREG 条約）が制定され，その後，部分改正を重ねながら船舶衝突を防止するための国際的な船舶運用規則が確立されている．ただし，その規則は，基本的には 1 隻の船舶が他の 1 隻の船舶と対面するいわゆる 1 対 1 状況における行動指針を定めたものであるため，例えば多くの船舶が輻輳する可能性のある港湾近くの狭いエリア（輻輳海域）においてはうまく機能しない．

二つ目は管制センターの設置である．東京湾，伊勢湾，瀬戸内海のような輻輳海域には，海上交通センター（VTS センターあるいはマーチス）という管制施設が沿岸地域に設置されており，専門の管制官による管制コントロールが実施されている．現在，海上交通センターは日本国内では 7 箇所（東京，名古屋，伊勢，大阪，備讃瀬戸，来島海峡，関門海峡）に設置されている．海上交通センターの設置はもちろん有効だが，設置および維持のためのコストがかかる．また，管制コントロールには，複雑な状況における瞬時の判断が求められるため，かなりの熟練を要すると考えられる．

三つ目は近隣船舶の情報を得るシステムの利用である．ARPA（Automatic Radar Plotting Aid）というシステムでは，レーダーを使って得た近隣船舶の位置をディスプレイ上にプロットし，操船者を側面から支援する．また，AIS（Automatic Identification System）というシステムでは，それを搭載した船舶同士が互いに様々な情報（識別子，船種，位置，針路，速度，目的地など）を無線でやり取りして操船者に知らせ，その判断を支援する．なお，一定の基準を満たす船舶に対しては，AIS の搭載が国際的に義務付けられている．

筆者らは，船舶の完全自動運航の実現を目指して，マルチエージェント探索の技術を応用した分散確率的探索アルゴリズム（DSSA_SCA: Distributed Stochastic Search Algorithm for Ship Collision Avoidance） [Kim 2017] を提案した．DSSA_SCA では，AIS のような通信機能をもった船舶同士が互いの意図を交換することにより，衝突を回避する針路を自動的に決定する．しかし，その一方で，現実の海上輸送においては，AIS 搭載義務のない漁船やプレジャーボートのような小型船が大きく船舶衝突事故に関係している．本研究では，すべての船舶が通信機能をもつ「協力的な船舶 (Co-Ship)」と仮定する DSSA_SCA において，通信機能をもたない「非協力的な船舶 (Ego-Ship)」の存在が性能にどう影響するかをシミュレーション実験により調べる．

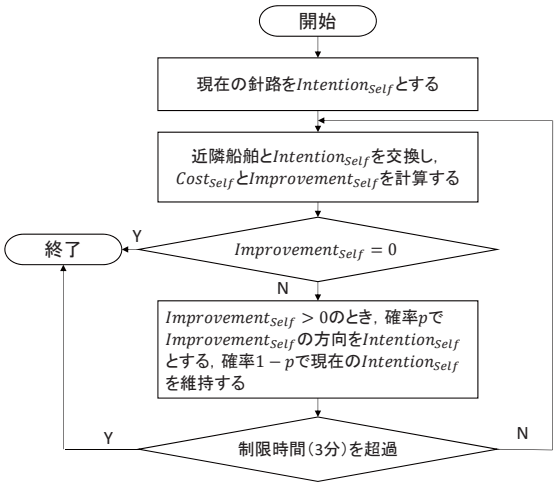


図 1: Co-Ship の手続き

2. 協力的な船舶（Co-Ship）

本研究では，DSSA_SCA に従って針路を決定する船舶を「協力的な船舶 (Co-Ship)」とよぶ．Co-Ship は，図 1 の手続きに従って 3 分毎にそれぞれの針路を更新する．

$Intention_{Self}$ とは，DSSA_SCA の実行中に暫定的に設定した仮の針路（意図）であり，検知範囲に存在する近隣船舶の意図に応じて実行中に何度も変更される可能性がある．なお，実際に Co-Ship が採用する針路は，手続きが終了した時点での最新の意図とする．

各船舶は，現在の針路を中心として，左舷方向に最大 45° (−45°)，右舷方向に最大 45° (+45°) の間を 5° 刻みで方向を

連絡先: 平山 勝敏，神戸大学大学院海事科学研究科，〒 658-0022 神戸市東灘区深江南町 5-1-1，hirayama@maritime.kobe-u.ac.jp

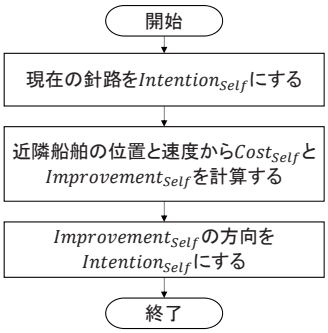


図 2: Ego-Ship の手続き

選択し，針路を変更できるものとする．各船舶は，各方向について以下に示す式でコストを計算し，コストが最小となる方向を仮の針路（意図）としてその都度確率的に選択する．

$$Cost_{Self}(crs) \equiv \alpha \sum_{j \in Neighbors} CR_{Self}(crs, j) + EF_{Self}(crs) \tag{1}$$

ここで，

$$CR_{Self}(crs, j) \equiv \begin{cases} \frac{15}{TCPA_{Self}(crs,j)} & \text{if } Self \text{ will collide with } j \\ 0 & \text{otherwise} \end{cases}$$

は衝突危険性を表す指標であり，具体的には自船舶 $Self$ が方向 crs を選択した際の 15 分先までの状況を先読みし，船舶 j と衝突すると判断される場合は衝突までの残り時間 TCPA (Time to Closest Point of Approach) の逆数をコストとして返す．一方，船舶 j と衝突しないと判断される場合は 0 を返す．一方，

$$EF_{Self}(crs) \equiv \frac{|\theta_{dest} - \theta_{Self}(crs)|}{180}$$

は非効率性を表す指標であり，自船舶 $Self$ が選択する方向 crs と目標地点が存在する絶対方向 θ_{dest} の差の絶対値をコストとして返す．

なお，$Improvement_{Self}$ とは，現在選択している仮の針路 ($Intention_{Self}$) から方向を変更した場合のコストの減少幅の最大値である．$Improvement_{Self}$ の方向とは，コストの減少幅が最大となる方向を意味する．

3. 非協力的な船舶（Ego-Ship）

AIS 等の通信機能を持たず，近隣船舶に対してその意図を知らせることができない船舶を「非協力的な船舶 (Ego-Ship)」とよぶ．本研究では，Ego-Ship は ARPA を搭載し，レーダーを使って近隣船舶の位置や速度を測定することができると想定する．すなわち，近隣船舶の現在の針路 *1 をもとに，式 (1) を用いて自船舶における各方向のコストを計算することができる．Ego-Ship は，コストを計算した後，直ちにコストの減少幅が最大となる方向に次の針路を設定する．

図 2 に Ego-Ship の手続きを示す．なお，Ego-Ship は近隣船舶と意図の交換を行わないため，Co-Ship よりも頻繁に針路を更新できると考えるのが自然である．本研究では，Co-Ship の 3 分毎に対して，Ego-Ship は 1 分毎に針路を更新できるものとした．

*1 近隣船舶の意図ではなく，ARPA を通して観測できる針路のみに基づくことに注意．

4. シミュレーション実験

Co-Ship と Ego-Ship が混在する状況が結果にどう影響するかシミュレーション実験により調べる．本実験では，Co-Ship の数に対して Ego-Ship の割合を次第に増やしていき，衝突回数と遠回り率がどう変化するか測定した．遠回り率とは、(実際に航行した距離)/(最短航路の距離) で計算され，最短航路から外れるほど一般に大きな値となる．



図 3: 8 隻の船舶の位置情報

シミュレーション実験で使用するデータは，図 3 のように www.vesselfinder.com 上で瀬戸内海淡路島西方の海域から任意に抽出した 8 隻の船舶の位置情報をもとに作成した．各船舶の目標地点は，データ取得時における各船舶の針路の延長上にあるものとし，すべての船舶について船速を 12 ノット，検知範囲（近隣船舶との通信可能範囲）の半径を 12 海里，安全領域（衝突と判定される範囲）の半径を 0.5 海里とした．

表 1: 衝突回数と遠回り率

	#Ego-Ship		
	0	4	8
衝突回数	0	2	3
Co-Ship の遠回り率	1	1.00289	-
Ego-Ship の遠回り率	-	1.00013	1

Ego-Ship の数を 0 隻， 4 隻，8 隻と変化させたときの衝突回数と遠回り率の結果を表 1 に示す．EgoShip を増やすと衝突回数は明らかに増加する．なお，掲載していない他の問題例での実験も含め，衝突は常に Ego-Ship 間または Ego-Ship と Co-Ship 間で起こり，Co-Ship 同士が衝突することはなかった．また，Ego-Ship との衝突を避けるために Co-Ship が迂回するケースが多く，その結果，Co-Ship の遠回り率が増加することが分かった．

5. 今後の課題

より現実に近い設定でシミュレーション実験を網羅的に行うこと，針路変更だけでなく速度変更も可能とするよう DSSA_SCA を拡張すること等が今後の課題として挙げられる．

参考文献

[Kim 2017] Donggyun Kim, Katsutoshi Hirayama, Tenda Okimoto: Distributed Stochastic Search Algorithm for Multi-ship Encounter Situations, Journal of Navigation, Vol.70, Issue 4, pp.699–718 (2017).

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

ソシオン理論に基づいた学級集団ネットワークと学級内SNSのモデル化

Modeling of Classroom SNSs and Classroom Network Based on the Socion Theory

内藤昂佑 *1　加藤 昇平 *1 *2
Kosuke Naito　Shohei Kato

*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

In recent years, Social Networking Serveices (SNSs) have been popular among young people. According to the popularity of SNSs, the cyberbullying becomes a social problem. To find the mechanism of cyberbullying, there are several studies using multi-agent simulation which can analyze human relationships. Therefore, in this study, we model SNSs in classroom and analyze the influence of SNSs on classroom friendship. This model is based on the Socion theory. In the model, an agent can communicate other agents using two kinds of networks: a network of classroom and networks of SNSs via a network recognized by each individual. Agents communicate face to face (FTF) in the classroom and do SNS communication in SNSs. In this paper, we conduct simulation of friendship relations considering SNSs, and disccuss the influence of SNSs on classroom relationships from the simulaion results.

1. はじめに

近年，SNS が若者の間で流行しており，平成 28 年度の青少年のインターネット利用率は 80.2 %となっている [内閣府 17]. インターネットの利用内容として,「コミュニケーション」が上位となっており青少年の人間関係に多大な影響を与えていると考えられる．一方，マスメディアでは「いじめ問題」や「学級崩壊」など，教育現場での問題が多く取り上げられてきており，1000 人当たりのいじめの認知件数である認知率が年々増加し，平成 28 年度には 23.9 件となり 30 年間で最大となっている．このように社会全体がいじめに対して危機意識を持ち，1 つの社会問題となっている．その中で，SNS の流行に伴い新たに「ネットいじめ」という社会問題が生まれた [内閣府 08]. 「ネットいじめ」とは，ネットを通じて誹謗・中傷を行ういじめであり，何時でも容易に行えること，大人の目に届かないことから悪質ないじめとされている．本研究では，いじめの増加によっていじめ認知率が増加したと考え，いじめの増加と SNS 流行の関係について分析を試みる．

長期間観察が必要な社会現象を分析する手法の 1 つとしてマルチエージェントシミュレーションが挙げられる．これまでに，マルチエージェントシミュレーションを用いて学級集団をモデル化した研究が，多数報告されている [Okubo 15, Osumi 14]. これらの研究では，コミュニケーションにより人間関係が変化する学級集団のモデルを形成しているが，SNS の流行以前であったため，コミュニケーションの手段に SNS を考慮する必要がなかった．本研究では，マルチエージェントを用いた学級集団のシミュレーションに SNS でのコミュニケーションを導入 [内藤 17] し，SNS が人間関係に与える影響の分析を試みる．

2. 提案モデル

2.1 概要

本研究では，対面コミュニケーション (Face to Face，FTF) と SNS の 2 つのコミュニケーションと，それらのコミュニケーションによって形成される人間関係をモデル化する (図 1)．シミュレーションは，中学校の 1 学級を想定し，好感度が変動し人間関係が変化する．本モデルでは，FTF と SNS の 2 つのコミュニケーションにより好感度を更新する．また，SNS のグループは学級内のエージェントのみで構成されるものとする．

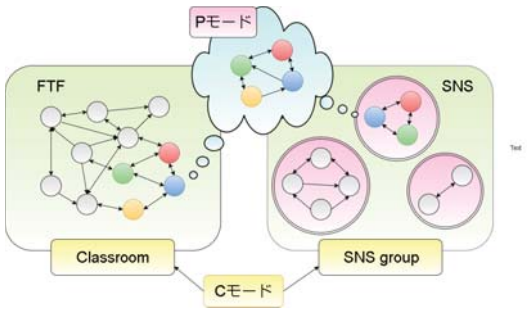


図 1: 提案モデルのネットワーク

SNS を行うシミュレーションにおいて，FTF のみを行う導入期，FTF と SNS を行う本期を用意し，導入期終了後に SNS アカウントを持つ各エージェントが SNS アカウントを持つ友人を誘う形で，SNS グループを作成する．SNS のモデルへの適用に関しては，2・7 節に後述する．本研究では，コミュニケーションモデルにハイダーのバランス理論 [Heider 58]，大隅らの同調方略 [Osumi 14] を使用，ネットワークモデルにソシオン理論 [藤澤 06]，エージェントモデルに大久保らのコミュニケーション能力 [Okubo 15] を使用する．

2.2 ネットワークモデル

本研究のモデルでは，人間関係をネットワークと考え，有向グラフで表現する．個々のエージェトをノードで表し，それらが互いに好感度 [-1,1] を持つ．好感度が友人閾値以上のとき友人リンク，排斥閾値以下のとき排斥リンクを生成する．学級内の活動を想定したネットワークは，FTF に 1 つ (学級集団)，SNS に複数 (グループ) 存在することが可能である．

2.2.1 ソシオン理論

ソシオン理論 [藤澤 06] は，人間関係をネットワークとして考える．自分が他者を思う気持ち (荷重 I)，他者が自分を思う気持ち (荷重 II)，自分が自分を思う気持ち (荷重 III) の 3 つの

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

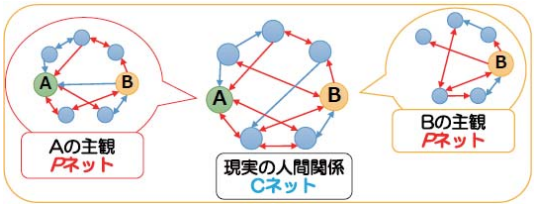


図 2: ソシオン理論における 2 つのモード

荷重で自己を定義する．荷重は，正と負の向き (荷重価) と大きさを持つ (荷重量)．荷重 Ⅲ は，各個人が自由に変更できるものでなく，荷重 Ⅱ の影響を強く受ける．他者から多く評価をもらえれば，自身の評価が大きくなるというものである．

ソシオン理論では，人々は心の中に社会と同じネットワークを持っているとされ，それを P モードのネットワーク (P ネット) と呼び，個人の内部に個別に存在する．一方現実の人間関係のネットワークを C モードのネットワーク (C ネット) と呼ぶ (図 2)．それらの 2 つのネットワークが，コミュニケーションを通して情報をやり取りすることで，一人ひとりの心と社会の相互作用のモデル化を可能となる．また，P モードと C モードの好感度は，必ずしも一致するものではなく，C モードに存在するノードが P モードに含まれない場合がある．本研究では，各エージェントが持つ P ネットは FTF と SNS で共通する (図 1)．

コミュニケーションでは，C モードを P モードに反映 (畳み込み)，P モード内での心の作用 (操作)，P モードを C モードに反映 (広げ返し)，C モード内での変化の 4 ステップにより情報交換を行う．本稿では，心の作用 (操作) として大隅らの同調方略 [Osumi 14] を使用する．

C モードにおけるエージェント a_i からエージェント a_j に対する好感度は W_{ij} と表される．

2.3 エージェントモデル

集団に属するエージェントを $a_i(i = 1, \cdots, n)$ と表す．本稿では，国内における平成 27 年度の 1 学級あたりの生徒数を考慮し，エージェント数を 30 名 (n=30) とする．エージェントは，P ネット，コミュニケーション能力，SNS アカウントを持つ．

2.3.1 好感度

本稿における P ネットは，好感度の集合となる．エージェント a_i の P ネットにおけるエージェント a_j からエージェント a_k への好感度を W^i_{jk} と表す．本稿では，エージェント a_i の荷重 Ⅲ(2.2.1 節参照) は，以下に定義する．

$$W^i_{ii} = \eta \sum_{j=1}^{n} W^i_{ji} (j \neq i) \tag{1}$$

また，C ネットにおける a_j から a_k への好感度は W_{jk} と表し，$W_{jk} = W^j_{jk}$ となる．すなわち，各エージェントから荷重 I を集めたものが C ネットとなる．

2.3.2 コミュニケーション能力

大久保ら [Okubo 15] は，内野ら [内野 09] が行った自己主張・他者受容の尺度の作成と，そのソーシャルスキルの特徴及び学校適応感との関連を検討した研究を基に，ソーシャルスキルを用いた好感度更新法をモデル化した．本研究では，エージェントのソーシャルスキルとして大久保らが作成したコミュニケーション能力とそれを用いた好感度更新法を使用する．コミュニケーション能力として以下の 2 つを定義する．

- a_i の自己主張係数 A_i
  大きいほど自分の意見を相手に影響させる．

表 1: エージェント群

	自己主張係数	他者受容係数
アサーティブ群	高	高
アグレッシブ群	高	低
ノンアサーティブ群	低	高
関係回避群	低	低

- a_i の他者受容係数 R_i
  大きいほど相手の意見に影響される．

また，各ソーシャルスキルの高低により，エージェントを表 1 の 4 群に分ける．また，内野らが行ったアンケート結果の構成比に基づき各群の人数を決定する．アサーティブ群，アグレッシブ群，ノンアサーティブ群，関係回避群の構成比はおよそ 2:1:1:2 であった．よって本研究では，学級内にアサーティブ群及び関係回避群をそれぞれ 10 名，アグレッシブ群及び関係回避群をそれぞれ 5 名とする．

2.3.3 SNS アカウント

エージェントは，SNS アカウントを利用できるかどうかの 2 値を持つ．SNS のネットワークには，SNS アカウントを持ち SNS を利用することができるもののみが所属することができるものとし，複数のグループに属することも可能とする．本稿では，平成 28 年度の中学生のインターネット利用率，及び利用目的に「コミュニケーション」を挙げている割合から人数を 18 名に設定する [内閣府 17]．

2.4 コミュニケーションモデル

2.4.1 ハイダーのバランス理論

ハイダーのバランス理論とはフリッツ・ハイダー (Fritz Heider) が提唱した態度理論であり，「認知的均衡理論」とも呼ばれる [Heider 58]．ハイダーのバランス理論では，認知の主体を「*P*」，*P* と関係のある他の人物を「O」，認知の対象を「X」とし，これら 3 つの心情関係のバランスが議論されている．*P* から O，*P* から X，O から X の心情の正負に注目する．それぞれの心情関係について，ポジティブな心情をプラスで表し，ネガティブな心情をマイナスで表すとすれば，3 つの心情の積が正ならば均衡状態，負であれば不均衡状態となる (図 3)．不均衡状態である場合，認知の主体である *P* は不均衡状態を回避し均衡状態に近づこうとするため，O または X に対する心情を変化させる．本研究では，この作用により好感度が変動し，人間関係が変化していく．

2.4.2 同調方略

本稿では，P ネットにおける操作 (2.2.1 節参照) において大隅らが提案した同調方略を使用する [Osumi 14]．同調方略とは，同調により地位の維持・向上を目的とした方略である．各個人は，自身の行動によって人間関係にどのような影響があるか，頭の中でシミュレートをし，嫌われ者にならないよう行

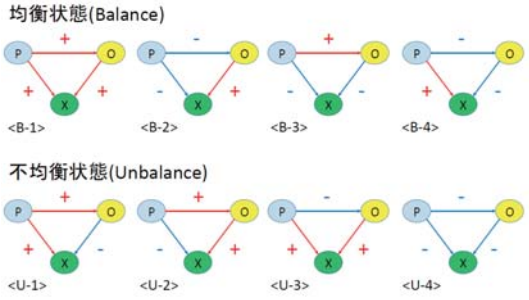


図 3: ハイダーのバランス理論

動する傾向があると考えられる．同様に，各エージェントは，P ネット内で自身の荷重 Ⅲ を維持，向上を目的としたシミュレーションを行う．あるエージェント a_i が他のエージェントに対する好感度を σ 上昇させた場合と σ 低下させた場合の 2 つの場合において，自身の荷重 Ⅲ の向上が最も大きかったエージェントを，好感度を上げる候補 a_u・下げる候補 a_d としそれぞれ 1 名選択する．大隅らは，それぞれ $W^i_{iu} < 0$，$W^i_{id} > 0$ の場合のみ好感度の更新を行っているが，本稿では，選択された場合条件なく好感度を更新する．

2.5 シミュレーションモデル

本研究では，ソーシャルスキルの差及び SNS による人間関係への影響を観察するため，大久保らのモデルにソシオン理論と SNS を導入する．

2.6 FTF

FTF では 1 対 1 の対話を想定する．各エージェントは，対話相手と話題対象を選択し対話を行うことで好感度を更新する．対話相手，話題対象の選択及び好感度更新法は，大久保らの手法を利用する [Okubo 15]．大久保らの好感度更新法は，自己主張による好感度更新法と他者受容による好感度更新法がある．FTF の 1 ターンの流れを以下に記す．

1. 対話相手の選択
2. 話題対象の選択
3. P ネットの更新
4. 対話による好感度更新
5. 同調方略
6. C ネット更新

2.6.1 対話相手の選択

友人リンク先のエージェントを 1 リンク先のエージェントとする．各エージェントは 2 リンク以内のエージェントからランダムに対話相手を選択する．

2.6.2 話題対象の選択

本モデルでは，話題対象をクラス内のエージェントに限定する．話題対象は，対話を行う 2 人以外からランダムに選択する．

2.6.3 ネットワークの更新

P ネットの更新において各エージェントは，対話相手と話題対象に関する好感度情報のみを更新する．エージェント a_i がエージェント a_j がエージェント a_k を話題対象として対話を行う時，以下の式に従い P ネットを更新する．

$$W^i_{ji} = W_{ji} + \alpha_1\delta \tag{2}$$

$$W^i_{jk} = W_{jk} + \alpha_2\delta \tag{3}$$

$$W^j_{ij} = W_{ij} + \alpha_1\delta \tag{4}$$

$$W^j_{ik} = W_{ik} + \alpha_2\delta \tag{5}$$

α_1 はコミュニケーション相手から自分への好感度，α_2 は自分以外への好感度を推定した際に起こる誤差を表現するためのゆらぎの大きさとなり，δ は [-1,1] の一様乱数により決定する．また，シミュレーションにより C ネットの更新は，前述通り $W_{jk} = W^j_{jk}$ とする．

2.6.4 自己主張による好感度更新

自己主張とは，自分の意見を強く主張することができるスキルと捉えられている．従って，自己主張係数が大きいほど，自身の持つ話題対象への好感度を強く相手に影響させると考えられる．エージェント a_i とエージェント a_j が対話を行う時，エージェント a_i は図 3 の <U-1>，エージェント a_j は <U-2> の状態であり，$A_i > A_j$ とする．このとき，エージェント a_i の自己主張により，エージェント a_j は話題対象エージェント a_x に対する好感度を正方向へ変化しやすいと考えられるので，<B-1> へ変化しやすくなる．この場合，エージェント a_j は，以下の式に従い好感度を更新する．

$$g = A_i - A_j \tag{6}$$

$$P_A = 100 \cdot \frac{g+1}{2} \tag{7}$$

$$\frac{\delta W^j_{jx}}{\delta t} = g \cdot A_i \cdot W^j_{ji} \cdot W^j_{ix}(P_A\%\text{で選択}) \tag{8}$$

$$\frac{\delta W^j_{ji}}{\delta t} = \omega \cdot W^j_{jx} \cdot W^j_{ix}((100 - P_A)\ \%\text{で選択}) \tag{9}$$

上記より，自己主張係数の差が大きいほど自己主張による更新を行いやすく，更新量も大きい．

2.6.5 他者受容による好感度更新

他者受容とは，相手の意見を受け入れ理解することができるスキルと捉えられている．従って，他者受容係数が大きいほど，相手の持つ話題対象に対する好感度に強く影響されると考えられる．エージェント a_i とエージェント a_j が対話を行う時，エージェント a_i が図 3 の <U-1> の状態であるとする．エージェント a_i がエージェント a_j に共感して好感度更新を行うならば，話題対象 a_x に対する好感度が負の方向へ変化しやすいと考えられるので，<B-3> へ変化しやすくなる．この場合，エージェント a_i は，以下の式に従い好感度を更新する．

$$d = |W^i_{jx} - W^i_{ix}| \tag{10}$$

$$P_R = 100 \cdot R_i \tag{11}$$

$$\frac{\delta W^i_{ix}}{\delta t} = (1 - \frac{d}{2}) \cdot R_i \cdot W^i_{ij} \cdot W^i_{jx}(P_R\%\text{で選択}) \tag{12}$$

$$\frac{\delta W^i_{ij}}{\delta t} = \omega \cdot W^i_{ix} \cdot W^i_{jx}((100 - P_R)\ \%\text{で選択}) \tag{13}$$

上記により，他者受容係数が大きいほど共感による更新を行いやすく，更新量も大きくなる．

2.7 SNS

FTF と SNS の差異をモデル化するため，SNS の特徴を以下の 3 つと仮定する．

1. 居場所，時間に関係なく対話することができる．
2. グループ以外の人間に情報を隠蔽できる．
3. 発言をグループに属する全員が共有できる．

上記 3 つの特徴を以下のようにモデルに適用する．

1. SNS を利用するエージェントは FTF のみに比べてコミュニケーション回数が増加する．
2. 各グループに固有の C ネットを用意する．
3. SNS では発言者と各グループ員で逐次好感度更新を行う．

SNS では，1 ターンに各グループ毎にコミュニケーションを行う．グループ員の中でランダムに 1 人発言者を選択し，話題対象をグループ員以外からランダムに選択する．

SNS アカウントを持つエージェントは，1 リンク先のエージェントを SNS グループのメンバーとして誘う．誘われたエージェントが SNS アカウントを持っている場合，グループに加入する．この動作を SNS アカウントを持つ全エージェントが行いグループを生成する．

3. 実験設定

本稿では，提案モデルを用いた中学校の 1 学級 30 人，6ヶ月を想定したシミュレーション実験を行う．シミュレーションとして，以下の 2 つのシミュレーションを行う．

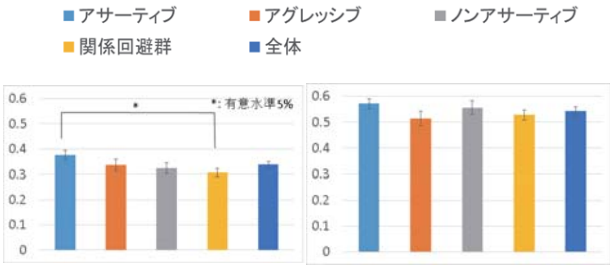
i). 大久保らのモデルにソシオン理論を導入したモデル

ii). i) のモデルに SNS を導入したモデル

これ以降 i) のシミュレーションを FTF のみのシミュレーションと呼び，ii) のシミュレーションを SNS 導入のシミュレーションと呼ぶ．実験設定として導入期 10 日，本期 148 日とし，FTF13 ターン/日，SNS1 ターン/日とする．また，前述した通り SNS を使用するエージェントは 18 名とする．

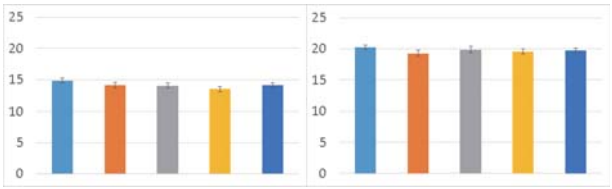
4. 実験結果

100 試行のシミュレーションにより得た結果を図 2 から図 4 に示す．



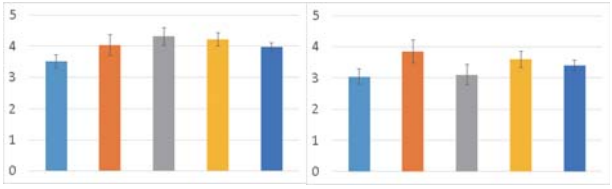
(a)FTF のみ　(b)SNS 導入

図 4:平均被好感度



(a)FTF のみ　(b)SNS 導入

図 5:平均被友人リンク数



(a)FTF のみ　(b)SNS 導入

図 6:平均被排斥リンク数

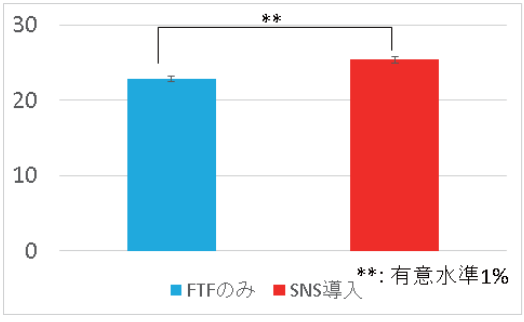


図 7: 最大被排斥リンク数平均

各グラフごとに Bonferroni 法を用いて多重比較検定を行った．その結果，FTF のみのシミュレーションの平均被好感度においてアサーティブ群と関係回避群の間に有意差が確認された (図 4)．これは，内野らの考察と一致しモデルの妥当性を示唆している．SNS 導入のグラフを見ると SNS を導入したことで，SNS 使用者のコミュニケーションターン数が単純に増加したため，全体的な平均被好感度，友人リンク数が上昇したと考えられる (図 4，図 5)．また，排斥リンク数はわずかに低下した (図 6)．一方で，クラス内で最も嫌われているエージェントの被排斥リンク数の平均は，FTF のみのシミュレーションと SNS を導入したシミュレーションで有意差が確認された (図 7)．SNS を導入したことで，コミュニケーションが増加し一定数のエージェントは友人が増加したが，一部のエージェントに排斥リンクが集中した．SNS のコミュニケーションによりグループ員同士がクラスメイトに対する好感度を共有する機会が生まれた．その結果，好かれている者，嫌われている者が顕在化し，同調方略に基づく心の作用において特定の者が集中して選択され，いじめのきっかけとなる排斥リンクの増加が発生したと考えられる．

5. おわりに

本稿では，SNS のコミュニケーションを考慮した学級集団のモデル化，及びシミュレーション実験を行い，対人コミュニケーションに SNS を導入した場合の効果の検証を行った．今後は，大隅らのモデルとの比較を行いモデルの妥当性を検証していく．また，SNS のコミュニケーションにおいてソーシャルスキルの差が与える影響を調査・検討し，モデルに導入していく．その後，いじめの増加と SNS 使用率増加の相関に関して，好感度，友人リンク，排斥リンクの観点から分析する．

参考文献

[内閣府 17] 内閣府，平成 28 年度 青少年のインターネット利用環境実態調査 調査結果 (2017)

[内閣府 08] 内閣府,「ネット上のいじめ」に関する対応マニュアル・事例集 (学校・教員向け) (2008)

[内藤 17] 内藤 昂佑，加藤 昇平，”SNS のコミュニケーションを考慮した学級集団ネットワーク形成モデル”，情報処理学会第 80 回全国大会 (2018)

[Okubo 15] Tatsuki Okubo, Shohei Kato, Atsuko Mutoh, ”A Friendship Network Model on Heider’s Balance Theory Considering Assertiveness and Empathy”, IEEE GCCE 2015, pp.117-119 (2015)

[Osumi 14] 大隅 俊宏，大澤 博隆，今井 倫太，”ソシオン理論に基づいたクラス内のいじめと同調方略のモデル化”，電気学会論文誌（電子・情報・システム部門誌）vol.134(2014), P560-570(2014)

[Heider 58] F.Heider, The Psychology of Interpersonal Relations, New York(1958)

[藤澤 06] 藤澤 等，小杉 考司，藤澤 隆史，渡邊 太，清水 裕士，石盛 真徳，ソシオン理論入門-心と社会の基礎科学，北大路書房 (2006)

[内野 09] 内野 康人之，渡辺 史章,“中学生のコミュニケーションスキルと学校適応感の関連”，宇都宮大学教育学部　教育実践総合センター紀要　第 32 号 (2009)

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

複数ロボット協調による一問一答型雑談対話からの脱却

Continuous conversation with two-robot coordination

杉山 弘晃 *1　水上 雅博 *1　成松 宏美 *1
Hiroaki Sugiyama　Masahiro Mizukami　Hiromi Narimatsu

*1NTT コミュニケーション科学基礎研究所
NTT Communication Science Laboratories

We have been working on a conversational dialogue system that raises user satisfaction and draws interests through dialogues, unlike a task-oriented dialogue that answers simple instructions and questions. To raise user satisfaction, systems should precisely respond to a user utterance and continue dialogue with topics that strongly related to the user utterance. However, most conversational systems, which are usually utilize one-turn query-response pairs, are difficult to naturally continue dialogue. In this study, by controlling dialogue topics with multiple robot coordination, we propose a novel conversational system with two-turn query-response pairs that can naturally continue consistent dialogue. Our field experiment at Kyoto city zoo shows that our proposed system achieves very high user satisfaction.

1. はじめに

近年，従来のタスク指向の対話システムとは異なる，雑談を行う対話システムに注目が集まっている [Ritter 11, Higashinaka 14]．雑談対話は，単純な命令や質問応答に答えるタスク対話とは異なり、対話そのものへのユーザの満足度を高めたり，対話を通して話している話題への興味や思考を引き出すことを目的とする対話である．ユーザの対話への満足度を高めるためには，対話相手に発話を受け止めてもらったという印象をユーザに感じさせることが重要である．この印象は，単に一問一答的によい応答をすれば充足されるわけではない．ユーザ発話に対してロボットが適切な応答をしたとしても，そこから話題が発展しない場合，ユーザは自身の発話が表層的にしか受け止められなかった，もしくはその話題に興味がないと表明されたように感じてしまう．そのため，受け止めたところから話題が発展していくことも，満足度向上には重要な要素である．

一方，現在の雑談対話システムでは，対応可能な話題の広さを優先した，一問一答的なアプローチが主に用いられている [Vinyals 15, Ritter 11, Higashinaka 14]．応答の複雑さを単純な一問一答に限定することで，雑談中の話題に応答できる幅広さを実現している．しかしながら，一問一答では対話が細切れとなり，まとまってしっかりと対話できたという満足を得られにくい．この課題に対し，ユーザ発話による話題遷移を許容しない，もしくはごく少数の分岐を用意しておく前提で，複数ターンのシナリオとして構築する場合もある [Iio 16, 渡辺 16]．話題遷移を許容しない場合の一般的な方策は，ロボットからユーザに質問し，ユーザの答えによらず,「そっか」などの相槌で受け止め,「僕は○○だよ」と切り返すという流れを繰り返すものである．このアプローチの問題点として，展開される話題がユーザ発話と直接対応するものではないため，十分な満足を与えることは難しい点がある．また，ユーザ発話に応じてシナリオを分岐させていく場合も，ある程度の話の展開に影響を与えているものの，複雑な内容は伝わらないため，理解されている感は少ない問題がある．

こうした課題に対し，杉山らは，ユーザ発話に一問一答の知識に基づいて応答するとともに，その内容に関連する別の一問一答知識を利用してロボット間で対話を行うアプローチを提案しており，通常の 1 対 1 の対話よりも対話の継続感が向上することを報告している [杉山 17]．しかしながら，彼らの構築した発話知識は，特定の話題に特化するよりもむしろ一般的な内容で構築されているため，対話の個別の話題・文脈とはやや乖離した（ユーザ発話の詳細とは関連しない）内容になることが多い．

本研究では，一問一答とシナリオの組み合わせとして，ミニシナリオと呼ぶ 2 ターン分の発話知識に基づく複数ロボット雑談対話システムを提案する．ミニシナリオは，ユーザが発話しそうな文とそれに後続する 3 発話から構成される．2 体のロボットと 1 人のユーザとの対話を前提とし，ユーザ発話へロボットが応答したあと，その内容を反映した追加の一問一答をロボット間で行うことで，ユーザ発話を起点として，詳細に話題が繋がる自然な対話を実現する．ユーザへの応答および追加の一問一答は全てロボットが発話するため，対話として自然につながるようにあらかじめ作成しておくことができることがポイントである．

また，ロボット間の対話を利用して，自然に話題を誘導することも可能である．そのため，システムが限られたドメインの発話知識しか保有しない場合でも，ユーザは違和感を感じることなく雑談を継続できる．本研究ではこの特性を活かし，狭いドメインに特化して質問応答と同程度に詳細な雑談用の発話知識を構築することで，雑談と質問応答を相互に行き来しながら知識を伝達するシステムの実現を目指す．また，本システムを京都市動物園に設置し，来場者（主に子ども）と対話させた結果について報告する．

2. 発話知識に関する関連研究

雑談対話システムが発話するための知識として主に用いられるものとして，一問一答形式の発話対がある．ユーザ発話に類似する入力文を選び，それに紐付いた出力文をシステム発話として用いる形式である．この方法の場合，人手で想定される応答対を記述するもの（ルール [Wallace 04, Sugiyama 14]）や，実際の人の対話例を利用するもの（用例 [水上 16, Ritter 11]），ある単語や述語項に対する応答を自動生成するもの [杉山 15]，ニューラルネットを用いて End-to-end で生成するもの [Vinyals 15] などがある．

ルールで記述する場合は，想定されるユーザ発話に対しては質の高い応答が期待できる一方，ユーザ発話に対するカバー

連絡先: 杉山 弘晃，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，TEL: 0774-93-5243，FAX: 0774-93-5245，sugiyama.hiroaki@lab.ntt.co.jp

発話文	応答文	後続発話文	後続発話応答文
お鼻が長いところが好き	ゾウさんのお鼻は筋肉でできてて小さいものもつかめるんだよ	【質問】鼻で吸ってるんじゃないの？	鼻の先が指のように分かれてて、その部分でつかんでるんだよ
ゾウさんすごくお鼻長いね！		【平叙】すごく器用なんだね	鼻の動きを観察していると、ゾウの気持ちが分かるらしいよ
ゾウさんのお鼻はとっても長い		【継続】しかも鼻の動きを観察していると、ゾウの気持ちが分かるんだって	鼻で気持ちが分かるってすごいね。
ゾウさん大きくてかっこいい	肩までの高さは2.5〜3mくらいあるんだよ	【質問】鼻の長さはどれくらいあるの？	1.5〜2mくらいの長さがあります
体が大きい		【平叙】そんなに大きいんだ	近くで見ると迫力があるよ
超でかい！		【継続】近くで見ると迫力があるよ	近くで見てみたいな

図 1: ミニシナリオの例（ゾウのいいところ）

率が低いことが課題である．用例を利用する場合は，マイクロブログ等の実際の対話を利用するか，実験用に集められた対話を利用するかで特性が異なる．実際の対話を利用する場合は，その話者間でのみ成立する前提知識なしには一問一答としても成立していないように見える用例が問題となる．また，対話の方向性は状況，時刻や期間，目的によって異なるが，そうした違いを取り扱わず一括りに扱ってしまうため，文脈と矛盾した発話が生成されうるという問題がある．さらに，対話中の文そのものを利用する場合には，著作権的な問題も存在する．実験用に集めた対話を利用する場合はこれらの問題は比較的緩和されるものの，用例の量が大幅に少なくなり，ユーザ発話に対するカバー率が低下する問題がある．

自動的に文を生成する場合は，カバー率は非常に高く，また著作権的な問題も発生しないという利点がある．しかしながら，文の生成自体が非常に難しいタスクであるため，一文として意味の通る文を作成することが難しい．また，複雑な内容の発話を作成できないという問題点がある．さらに，これらの方法のいずれにも当てはまる問題として，一問一答を基本として知識が作られているため，対話が細切れとなりしっかり対話できたという満足が得られにくいという点がある．

3. システムの構成

本研究では，2 体のロボットと 1 人のユーザとの対話を想定し，2 ターンの発話対から成るミニシナリオ（図 1）に基づく対話を提案する．さらに，ロボット間対話や話者切り替えにより応答可能な範囲へ話題の流れを誘導することで，狭いドメインに集中的に構築した発話知識を基に自然な対話を実現する．本章では，話題が連続的につながっているように感じられる対話を実現するための，発話知識の構築・運用方法および全体の実装について説明する．

3.1 ミニシナリオ：2 ターン単位の発話知識

ミニシナリオは，発話文，応答文，それらに対する後続の発話文とその応答文の 4 文を単位として構成される．ここでは，動物に関する対話を想定した例に基づいて，各文の説明および構築方法を以下に示す．

発話文は，ユーザが発話すると想定される文であり，ユーザの発話する範囲を詳細にカバーできるよう多数作成する．本研究では，対象とする動物について，いいところ，質問，トリビアのいずれかの発話種類ごとに，発話文を 50 文ずつ（5 文 x 10 名の発話作成者）作成した．例えば，ゾウのいいところについて，「お鼻が長いところが好き」や「ゾウさん大きくてかっこいい」などとなる．合わせて，ユーザ発話の表現の揺れを吸収できるよう，それぞれの発話文と異なる表現で同じ意味となる文を 5 文ずつ作成する．なお，同じ意味の発話文をまとめたところ，意味の異なり数は概ね 25〜30 種類程度となっていた．

次に，このように作成した発話文について，ロボットが発話する応答文を作成する．ロボットの発話に矛盾が生じないよう，応答文は動物の種類ごとに 1 名の発話作成者が作成するものとし，同じ意味の入力文に対しては，同じ応答文となるよう作成する．また，応答文に質問を入れると，後述する後続発話文との整合が取りにくくなるため，応答文は平叙文で作成することとする．ゾウの「お鼻が長いところが好き」という発話文に対する応答文として，「ゾウさんのお鼻は筋肉でできてて小さいものもつかめるんだよ」が作成された．

後続発話文は，それに紐づく発話文と応答文のペアに対して，対話として自然につながるよう作成された発話である．ここでは，質問，平叙，継続の 3 つのタイプの発話を作成している．質問と平叙は応答文の発話者に対して別の話者が発話するものとして作成し，継続は応答文の発話者自身が継続して発話するものとして作成する．例えば，応答文「ゾウさんのお鼻は筋肉でできてて小さいものもつかめるんだよ」の後続の質問には「鼻で吸ってるんじゃないの？」が作成された．

後続発話応答文は，後続発話文に対する自然な応答になるよう作成された発話であり，応答文と同様の方法で作成する．

以上のように発話知識を構成することで，後続発話は先行する発話・応答文に密接につながる発話となるため，一問一答をつなげて複数ターンとするよりも自然な対話を実現できる．

3.2 対話の構成

構築したミニシナリオに基づき，ユーザとの対話を実現する方法を説明する．通常のシナリオを用いた対話では，対話の内容と進行が一体となって構築されていることが多い．しかしこの方法では，ミニシナリオのように大量のシナリオにスケールさせることは難しい．本研究では，ミニシナリオとして構築した多数の知識を効率よく利用するため，対話の進行と内容を分離して設計する．具体的には，対話の進行については，図 2 のように yaml 形式でスクリプトを記述し，その中の一部分をミニシナリオを利用してテンプレート的に補完する方法である．図 2 はユーザから話しかけられた直後の応答部分について示したものである．図中，

```
- ["R1", "H", 1.0, "/応答文/", "/SPEAK"]
```

の 1 つ目の項目は話者（H：ユーザ，R1, R2：ロボット 1，2），2 つ目の項目は話しかける相手話者，3 つ目の項目は発話終了後の待機時間，4 つ目の項目は発話内容，5 つ目の項目はジェスチャを表す．<ANIMAL>のように<>で囲われた部分は，話題としている動物やユーザの名前など，対話を通して固定される内容が代入される．また，//で囲われた部分には，BC（BackChannel）以外は，現在の話題で選択されているミニシ

```
INITIAL_FAMOUS_YES:
- ["H", "", 0.0, "FAVORITE:BEGIN_WITH_USER_UTT", ""]
- ["R2", "H", 100.0, "<TARGET_ANIMAL>さんのどんなところが好きなの？", "/ASK"]
...

BEGIN_WITH_USER_UTT:
- ["R1", "H", 0.5, "/BC/", "/NOD"]
- ["R2", "H", 1.0, "/発話文/", "/SPEAK"]
- RANDOM:
  - TRANSIT:
      BODY_QA
  - TRANSIT:
      BODY_DEC
  - TRANSIT:
      BODY_SELF

BODY_QA:
- ["R1", "H", 1.0, "/応答文/", "/SPEAK"]
- RANDOM:
  - ["R2", "R1", 1.0, "へえー", "/NOD"]
  - ["R2", "R1", 1.0, "ふむ", "/NOD"]
- ["R2", "R1", 1.0, "/後続質問文/", "/SPEAK"]
- ["R1", "H", 1.0, "/後続質問文-応答文/", "/NOD"]
...
```

図 2: yaml で記述したスクリプト

ナリオの内容が代入される．話者が H の行は，ユーザ発話を待ち受ける状態へ移行するコマンドを表し，発話内容の項目にどのような発話を待ち受けるかと，その発話が入力された後の遷移先等の処理項目が記述されている．ユーザ発話を待ち受けている状態以外のタイミングでユーザ発話が入力された場合は，その発話の種類に応じた行動を行う．具体的には，動物のいいところについての発話であれば共感を，質問であればその回答を発話し，「へえ」などのフィラーであれば相槌を打った後，元の発話に戻る処理を行う．

図 2 の流れに沿って，基本的な対話の流れを説明する．ここでは TARGET_ANIMAL がゾウであるとする．まず 2 行目で，ユーザ発話が動物についてのいいところ（FAVORITE）である場合を対象とする待ち受け状態へ移行する．ここでは，ユーザ発話が FAVORITE であった場合，BEGIN_WITH_USER_UTT へ遷移するものとする．

次に，3 行目で「ゾウさんのどんなところが好きなの？」を発話し，ユーザ発話を待ち受ける．それに対し，例えばユーザが「鼻が長いところ」と発話した場合，いいところについての発話と認識され，BEGIN_WITH_USER_UTT に遷移する，同時にいいところに関するミニシナリオ中で，類似する発話文を検索する．

BEGIN_WITH_USER_UTT では，7 行目で R1 が相槌を打ち，8 行目で R2 がユーザ発話と同じ内容の発話をすることで，共感を表現する．その後，後続発話文のどれを選択するかをランダムに選択する．BODY_QA（質問）が選ばれた場合，18 行目に遷移し，/応答文/に図 1 の応答文を代入して「ゾウさんのお鼻は筋肉でできていて小さいものもつかめるんだよ」と R1 が発話する．ユーザ発話を一旦受け止めてから応答文を発話することで，ユーザ入力と多少異なる意味の発話文が検索され応答がやや不自然になった場合でも，違和感を軽減して対話を続けることができる．

R1 の応答文に対し，20，21 行目を利用して R2 が R1 に相槌を打ちつつ，22 行目の後続質問文「鼻で吸ってるんじゃないの？」を発話し，R1 は H に向き直りながら，23 行目の後続質問文-応答文の「鼻の先が指のように別れてて，その部分でつかんでるんだよ」を発話する．このようにロボット間での対話を見せることで，ユーザの発話によって対話の内容が変動し，かつそこから対話がスムーズにつながっている印象を与えることができる．

ミニシナリオ 1 つ分の対話が終了した後は，類似した意味のミニシナリオを利用してロボット間で対話を継続したり，ユーザに質問を出して新たな発話を引き出すなどして対話を継続する．

3.3 システムの実装

対話ロボットには，CommU[*1] を用いる．視線や首を動かすことができ，話者交代をスムーズに表現することができる．音声を受け取るマイクは，指向性・ノイズ抑圧性能が高い，インテリジェントマイク [*2] を用いる．音声認識エンジンには NTT-TX 製の SpeechRec[*3] を用いる．今回，話題が動物に特化していること，また話者が小学生程度の子どもを想定していることから，通常のドメインの音声認識エンジンでは，認識率の低下が予想される．そのため，こうした発声を正しく認識できるようにするため，事前に収録した子どもの対話音声を用いて音響モデルのドメイン適応を，ミニシナリオ中の文を利用して言語モデルのドメイン適応を行った．さらに，ユーザが言いよどんだ場合に発話区間を誤って切り出さないようにするため，ボタンを押しながら話す Push-to-talk 方式を採用する．音声合成は，CommU の外見に合わせた子供の声として，NTT-TX 社製の音声合成 [*4] を用いる．

4. 京都市動物園における実証実験

4.1 実験設定

提案システムを京都市動物園に設置し，2/1 から 2/28 までの 1ヶ月間来場者と対話する実証実験を行った．実施場所は，京都市動物園の無料エリアにある，図書館カフェと呼ばれるエリアである．主に親子で本を読みながら食事や休憩を取るスペースとなっており，特に休日は多数の来場者が訪れる場所である．本実験では，提案するシステムがどの程度満足度の高い対話を実現できるかを，実ユーザを対象に評価することを目的とする．合わせて，適切な発話タイミングやユーザの対話への興味を推定する元データとして，対話中のユーザの表情や音声の収録を行う．対話の様子を図 3 に示す．



図 3: 動物園における対話の様子

対話の対象とする動物は，京都市動物園で飼育されている動物の中で人気の高い，ゾウ，キリン，カバ，レッサーパンダ，ツシマヤマネコ，トラ，フクロウ，ゴリラ，ペンギン，バクの 10 種類である．

来場者への案内は園内の看板や Web 等を通して行った．対話に参加する場合には，対話の方法について説明するとともに，タブレット PC を用いて対話中のユーザの呼び名や年齢・性別の設定，対象動物の選択，および本人が 18 歳以上もしくは保護者がいる場合のみ動画等のデータ取得に関する説明および同意取得を行った．

上記準備の後，実際に来場者とロボットとの間で対話を行った．なお，デモ時間や対話安定性の制約上，ユーザが 6 回発話した段階で，ミニシナリオの切れ目で終了モードに移行し，

∗1 https://www.vstone.co.jp/products/sota/index.html
∗2 http://www.ntt.co.jp/md/products/product_29.html
∗3 http://www.v-series.jp/speechrec/
∗4 http://www.v-series.jp/futurevoice/

「そろそろ時間みたい」と対話の終了を促す形で対話の終了処理を行った．また対話終了後，ユーザ評価を 5 段階（1：そう思わない，5：そう思う）で入力した．対話の楽しさや話題の対象への興味が対話の満足度を表すと考え，評価項目には，1. ロボットと話すのは楽しかったですか？(楽しさ)，2. 選んだ動物に興味を持てましたか？(興味)，3. 選んだ動物に詳しくなれましたか？(知識) の 3 項目を設定した．

4.2 結果と分析

実験に参加した延べ人数は，付き添う保護者を含め，概ね 400-600 人程度であった．そのうちデータ取得の同意を取れた人数は 238 名であった．本研究では，有効な同意を取得できた体験者のデータのみを用いて分析を行う．

まず，参加者全体の評価値は，1. 楽しさ：4.52，2. 興味：4.28，3. 知識：4.04 であった．5 段階評価で 4.5 以上は極めて高い値であり，ほとんどの体験者が楽しいと感じたことがわかる．一方，3 の知識については，4.0 は超えているものの楽しさ・興味に比べるとやや低い評価値となっていた．

次に，年齢の分布，および年齢ごとの評価値を図 4 に示す．来場者として，当初小学生低学年くらいを想定していたものの，実際には未就学児が非常に多く体験していた．一方，小学生中学年以上および中高生はほとんど来園していないことがわかる．評価値で見ていくと，1. 楽しさと 2. 興味は年齢に依らず概ね横ばいであった．3. 知識については，有意差も出ていないものの，6-8, 13-19, 20-39 歳の評価が高い一方，9-12 歳の落ち込みが大きい．実際に体験者の様子を観察していると，6-8 歳は知識のレベルが程よく合致しており，知識の満足度向上につながったものと考えられる．しかしながら，9-12 歳程度で動物園に来場する子どもはもともと非常に動物に興味があり知識も極めて豊富な子が多く，小さい子どもに合わせた知識では十分な満足を与えられなかったものと考えられる．一方，それより大きい 13 歳以上，特に 20 歳以上になると，普通程度の知識の来場者が再び増加し，かつ一般的な対話システムやロボットの対話レベルとの比較で評価するようになるため，評価値が向上したものと考えられる．

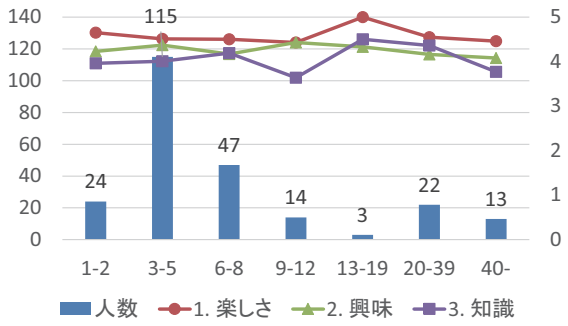


図 4: 年齢に対する評価値

男女の体験者数はそれぞれ 116 名，119 名（回答なし 3 名）であり，評価値は男性は 4.47, 4,32, 3.95，女性は 4.56, 4.23, 4.11 で有意差はなかった．

また，観察に基づく定性的な分析として，4 歳以下はロボットの発話を正しく理解すること自体が難しい（オープンな質問に的確に答えられないなど）場合が多く，論理的に見れば破綻している状態がほとんどであった．しかしながら，その状態であっても，図 4 の結果からも，楽しく対話していた子が多いことがわかる．内容のやりとり以外の観点での対話の楽しさを解き明かす手がかりになると考えられる．

加えて，対話後に感想を尋ねたところ，今回の対話の仕方（ロボット発話→人発話→ロボット間で対話 の繰り返し）でも，しっかりつながった対話と感じたという意見が多かった．ロボット間で話すところまでを応答と見れば，構造的には一問一答と類似しているものの，つながった対話と感じられていたという結果は，今後の対話ロボット研究を進めていく上で非常に有用な知見である．一方，ロボットが話しすぎている，という意見も多くあった．スクリプトでは頻繁に人に話を振るように設計していたが，それでもなお不足と感じられていたため，話を振るタイミングやユーザが割り込みやすい隙をうまく制御する必要があると考えられる．特に今回，対話の安定性を志向して Push-to-talk 式のターンテイクを採用していたものの，これにより，話を振られるまで割り込みにくいという印象を強めていた可能性があるため，ターンテイクの制御と合わせたデザインが必要である．

5. まとめ

本稿では，2 体のロボット間の対話や話者交代による話題制御を利用し，特定の動物の話題についてユーザ発話に的確に応じながら複数ターンに渡る自然な対話を実現するシステムを提案した．また，京都市動物園に本システムを設置し来場者と対話する実証実験を通して，非常に高いレベルで対話が楽しいと感じられていたことを示した．

今後の展開として，ユーザが話に入り込みやすいタイミングの推定や，内容以外の部分でユーザが心地よく感じるための要素について検討を行う．

謝辞

本実証実験は，京都市動物園および NTT 西日本の協力により実現されたものである．両者の多大なる支援に感謝する．

参考文献

[Higashinaka 14] Higashinaka, R., Imamura, K., Meguro, T., Miyazaki, C., Kobayashi, N., Sugiyama, H., Hirano, T., Makino, T., and Matsuo, Y.: Towards an open-domain conversational system fully based on natural language processing, in *Proc. COLING*, pp. 928–939 (2014)

[Iio 16] Iio, T., Yoshikawa, Y., and Ishiguro, H.: Pre-scheduled Turn-Taking between Robots to Make Conversation Coherent, in *Proc. HAI*, pp. 19–25 (2016)

[Ritter 11] Ritter, A., Cherry, C., and Dolan, W. B.: Data-Driven Response Generation in Social Media, in *Proc. EMNLP*, pp. 583–593 (2011)

[Sugiyama 14] Sugiyama, H., Meguro, T., and Higashinaka, R.: Large-scale Collection and Analysis of Personal Question-answer Pairs for Conversational Agents, in *Proc. IVA*, pp. 420–433 (2014)

[Vinyals 15] Vinyals, O. and Le, Q.: A Neural Conversational Model, in *ICML Deep Learning Workshop* (2015)

[Wallace 04] Wallace, R. S.: The Anatomy of A.L.I.C.E., *ALICE Artificial Intelligence Foundation, Inc.* (2004)

[水上 16] 水上雅博, Nio, L., 木付英士, 野村敏男, Neubig, G., 吉野幸一郎, Sakti, S., 戸田智基, 中村哲：快適度推定に基づく用例ベース対話システム, 人工知能学会論文誌, Vol. 31, No. 1, pp. DSF–C_1–12 (2016)

[杉山 15] 杉山弘晃, 目黒豊美, 東中竜一郎, 南泰浩：任意の話題を持つユーザ発話に対する係り受けと用例を利用した応答文の生成, 人工知能学会論文誌, Vol. 30, No. 1, pp. 183–194 (2015)

[杉山 17] 杉山弘晃, 目黒豊美, 吉川雄一郎, 大和淳司：複数ロボット間連携による対話破綻回避効果の分析, 人工知能学会全国大会, pp. 1B2–OS–25b–2 (2017)

[渡辺 16] 渡辺美紀, 小川浩平, 石黒浩：タッチディスプレイを通じて誘導的な対話を行う販売アンドロイド, 人工知能学会全国大会, pp. 2O3–2 (2016)

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

連続協力ゲームにおける提携構造の慣性を考慮した提携形成シミュレーション機構の試作

A Preliminary Approach on a Coalition Formation Simulator with Inertia on Continuous Cooperative Games

堀江将章 *1　福田直樹 *2
Masaaki Horie　Naoki Fukuta

*1静岡大学情報学部
Department of Infomatics, Shizuoka University

*2静岡大学学術院情報学領域
College of Informatics, Academic Institute, Shizuoka University

There is a possiblility of change from the best coalition structure formation at the moment to the best coalition structure at the next moment in a real-world coalition formation scenario. In this paper, we present a preliminary approach about constructing a continuous cooperative game simulator, which is focused on the situation where a coalition structure can be changed by adding new conditions of coalition formations. This preliminary simulator takes a list of pair of timing and a MC-nets rule added as a continuous cooperative game. We define a distance between two coalition structure as its costs of changes to model Inertia. We present how a coalition formation simulation can be done with such as inertia.

1. はじめに

協力ゲームは，組み合わせ最適化問題からのアプローチ [Lesca 17, Aadithya 11, Conitzer 06]，重み付きグラフ分割問題からのアプローチ [Bachrach 13] が提案されているが，その最適な提携構造を求めることは一般には NP-hard であるとされる [Lesca 17, Bachrach 13]．これらの研究では，協力ゲームの議論の前提として事前に全ての提携とその値が求められていると仮定している．

協力ゲームの適用先の一つの例として，市場における複数企業の提携などがあるが，企業をとりまく環境は時間の経過とともに変化することを考えると，前述のアプローチには可能な提携構造の時系列的変化がモデルには必ずしも含まれない．このことから，すでに構成されている協力ゲームの中での最良の提携構造を見つけることができても，外的要因などから変化することを考慮していないため，必ずしも長期的に安定な提携構造を構成できなかったり，環境の変化に伴う提携構造の変化をモデル上でうまく扱えない可能性がある．本研究では，提携構造の変化を外部から与えるコストに基づく慣性によって調整し，コストを越えたときに初めて変化が起こるような提携構造の変化をモデル化し，その提携構造の変化モデルのシミュレーション機構を試作することで，どのようにコストが提携形成に影響を与えるかを観測できるようにする．本シミュレーション機構は，協力ゲームの構成が時間とともに変化することを想定し，プレイヤーは常に利得を向上させようと行動することを仮定した際の提携構造の変化を，連続協力ゲームとしてシミュレーション可能とする．

2. 背景

2.1 協力ゲーム

協力ゲームはプレイヤー間に存在する提携とその利得の組の集合が与えられ，ゲームに参加しているプレイヤーが各自の利得を最大化するようなプレイヤーの組み合わせを求める問題である [Aumann 74, Driessen 13, Rothe 15]．Aumann ら [Aumann 74] によると特性関数で構成されたゲームであり，事前に全ての提携に対応する価値が与えられている． 非協力ゲームにおいて，そのゲームに参加するプレイヤーはそれぞれの行動を個別に選択し，その行動は自分自身のゴールを実現する，もしくは自分自身の利益を最大化するものである．

連絡先: 堀江将章，静岡大学情報学部情報科学科，〒 432-8011
静岡県浜松市中区城北 3-5-1，horie.masaaki.14@shizuoka.ac.jp

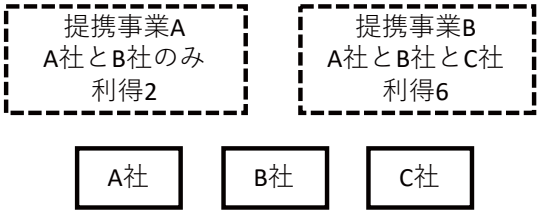


図 1: 協力ゲームの条件の例

それに対して協力ゲームにおいては，プレイヤーは提携とも呼ばれるグループを構成し，協調した選択を行なうことでそれぞれのゴールを実現する．しかし全てのプレイヤーが利他的であるとは想定しておらず，彼らは自分自身に割り振られる利益が増える場合にのみ提携に参加する．プレイヤーは彼ら自身の働きによって集団労働の利益を分割しなければならないので，競争は，協力ゲームにおいて重要な働きをする．

ここで重要なことは、全てのプレイヤーは事前に提携が与えられた状態で、自身の利益を最大化するように動くことで結果として協力しているように見えるという点であり，n 人のプレイヤーの集合 A を考えたとき，$S \subseteq A$ となるような集合 S を提携と呼ぶ．プレイヤー A とプレイヤー B が個々で行動を起こした場合に得ることのできる効用を $v(A)$，$v(B)$ とし，$v(A)+v(B) \geq v(A+B)$ となったときに $v(S) = v(A+B) - (v(A)+v(B))$ で表される $v(S)$ を提携から得られる効用として定義する手法がある．

実世界に協力ゲームのような現象が見られる例としては，企業間の提携事業などが挙げられる．例えば図 1 のような状況が挙げられる．

2.2 Marginal Contribution Net

Marginal Contribution Net(MC-net) は，Ieong[Ieong 05] らによって提案された協力ゲームの表現方法のひとつであり，協力ゲームを提携ルールの集合として表現するものである．MC-net の強みは，そのサイズがエージェント間の相互関係の複雑さに依存する点であるとされ，それまでの表現方法はゲー

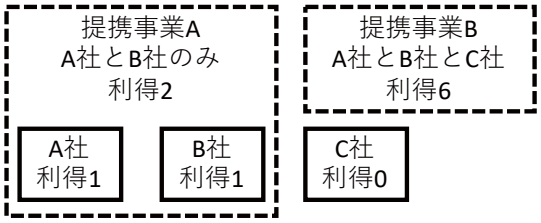


図 2: 提携事業 A を選択した場合の提携構造の変化

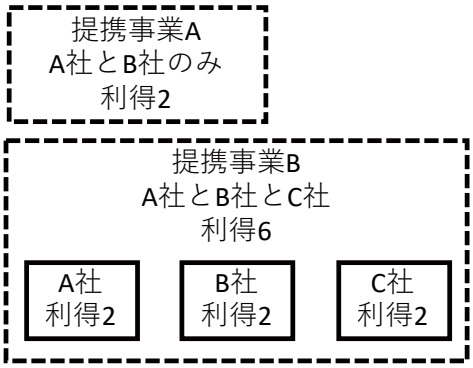


図 3: 提携事業 B を選択した場合の提携構造の変化

ムに参加するプレイヤーの数に依存してルールのサイズが増加する問題を解決したといえる．

MC-net による協力ゲーム G は提携ルールの集合 Φ とプレイヤー集合 A との組で表される，ルール集合 $\Phi = \{\phi_1, \phi_2, \dots\}$ であり，それぞれのルールは定義 1 に沿う形で表現される．

定義 1. *MC-net* ルール 提携ルール ϕ は，提携に属するプレイヤー集合 $P = \{a_i, a_j, \dots\}$ と提携に属してはいけないプレイヤー集合 $N = \{a_q, a_p, \dots\}$ と提携から得られる利得 v の組である．

$$\phi_i = \{P_i, N_i, v_i\}(P_i \cap N_i = \phi)$$

MC-net によるルール表現は LISP[McCarthy 60] の S 式による表現も可能である．本研究では，S 式による MC-net の協力ゲーム，提携のルール，提携構造の表現を，表 1 に示した表記により記載する．集合をリストとして表現し，一つのルールは必要なプレイヤー集合，不要なプレイヤー集合，提携の効用の組で表現する．

2.3 連続協力ゲーム

本研究では，連続協力ゲームは，複数のタイムステップから構成されている協力ゲームであり，タイムステップごとに協力ゲームのプレイヤーと提携によって得られる効用が変化するものと定義する．このような状況においては，時間が経過するにつれて，ある時点で最良であった提携構造が別の時点では最良ではなくなることが考えられる．こうした状況を引き起こす実際の要因としては，市場に新たな技術を持った企業の参加や，提携事業の追加が考えられる．

この状況を協力ゲームとして見ると，図 4 のように提携を示すルールの追加やプレイヤーの追加で協力ゲームの設定が変化したとみなすことができる．ここで，実社会での提携の変化をモデルに反映することを考えると，この提携構造を変化させるためには，現在の状況から提携を変更するために契約を変更したり提携事業から離脱するためのコストが必要となる．

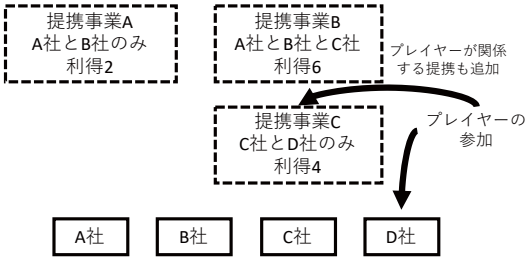


図 4: 既存の提携と衝突する提携の追加による協力ゲームの変化

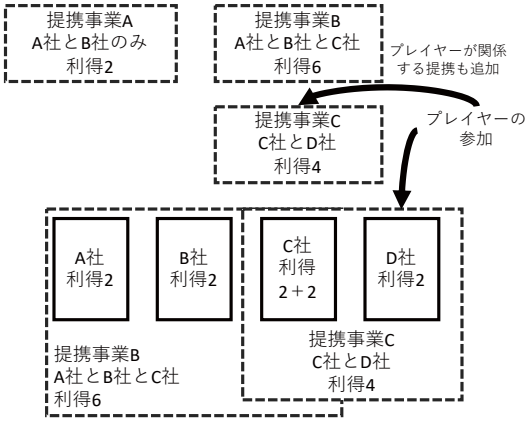


図 5: プレイヤーの追加による協力ゲームの変化

本研究においては，提携構造を変化させるためのコストを提携構造の慣性を表すものとして定義する．

実社会では図 5 のように新たなプレイヤーの参加によって協力ゲームの設定が変化することが予想できる．このとき，追加される前の状態で提携事業 B が選択されていると，その提携構造を破棄して同等の提携を構成できるプレイヤー C が存在する．このプレイヤー C は，その立ち位置により提携事業 B と提携事業 C のどちらを選んでも同等の効用を得ることができる上，全てのプレイヤーが一つの提携に属するのであれば提携事業 B と提携事業 C をの二つの提携から利得が得られる．

しかし，この時に追加される提携が図 4 に示すような既存の提携構造と衝突するような提携構造であった場合，C 社が提携事業 B から離れて提携事業 C を形成することがある．提携構造の変化に対する慣性を考えない場合には，得られる効用が同等であるにも関わらず提携構造の変更が続く可能性がある．

実社会においては，そのような提携構造の変化が緩慢にしか働かず，よりよい提携が存在したとしてもその提携に参加しない場合もありえる．その理由として考えられるのが，一つの市場を独占することを禁止する法律や提携事業の契約期間に関する制約，これらを含めた提携構造を変化させるために必要なコストが生じることであり，これら協力ゲームの設定の変化を提携構造の変化に即座に反映することを抑止するものを，本研究では提携構造の慣性とする．提携形成の過程に慣性を導入することにより，同等の効用を持つ提携構造から提携構造への変化は抑止され，不要な提携構造の変化を減少させる状況をモデルとして表現し，その変化の様子をシミュレーションできることが期待される．

表 1: MC-net による表現と S 式の対応表

	MC-net	対応する S 式
協力ゲーム	$G = \{A, \Phi\}$	(A Φ)
提携ルール	$\phi = \{\{a_i, a_j, \ldots\}, \{a_p, a_q, \ldots\}, v\}$	((a$_i$ a$_j$ ...) (a$_p$ a$_q$ ...) v)
提携構造	$CS = \{\{a_1, a_2\}, \{a_3\}, ..., \{a_{n-1}, a_n\}$	((a$_1$ a$_2$) (a$_3$) ... (a$_{n-1}$ a$_n$))

3. 本研究のアプローチ

本研究では，各エージェントが他のエージェントと何らかのプロトコルを経由して提携を組んで，提携形成を行う．形成された提携構造を評価して現在の提携構造との距離を算出する．もし，生成された提携構造が距離を越えるような利益を持っている場合，各エージェントが提携を移動するかどうかの判断を行い，移動すると判断したエージェントがある提携から別の提携へ移動を行う．この結果，提携構造が変化する．この提携形成の過程では，一部のエージェントのみが提携から離脱する場合があり，得られる利得が減ることも考えられる．その次のラウンドの再移動によって提携構造の効用が向上しつづけている場合には，段階的に提携構造が変化する．

本研究では，提携構造間の距離を求めるために，提携構造の提携ごとの Jaccard 指数を利用することを考える．ある状態における二つの提携の距離を求められると仮定する．

ここでは，まず，どんな提携構造であったとしても N 人のプレイヤーが参加している協力ゲームなら N 個の提携が含まれているとみなして Jaccard 指数を求めることを考える．

単純な Jaccard 指数を求めると，提携構造 ((A B C)) と提携構造 ((A B) (C)) の類似度が 0 となり，提携構造 ((A B C)) と提携構造 ((A) (B) (C)) の類似度についても 0 となるため，提携構造の間のコストとして単純に Jaccard 指数を求める手法はあまり効果的には機能しない．

この条件で類似度が 0 となってしまう課題の解決手法として，どのような提携構造であっても，参加しているプレイヤーの人数分の提携を仮定して，あるプレイヤーが一つ提携を構成するとプレイヤーが一人も属さない提携が生まれるとみなすことで次元を揃える方法がある．この方法では N 人のプレイヤーが存在したときに，N^2 回だけ提携間の Jaccard 指数を計算する必要がある．

他の方法として，二つの提携構造 CS_a，CS_b の間の類似度を求める場合に $CS_a \backslash CS_b$ と $CS_b \backslash CS_a$ について Jaccard 指数を求める方法についても検討する．これは，提携構造の同じ部分を類似度 1 として計算を省略し，異なっている部分の類似度を求めることで提携構造の慣性を表すパラメータとして利用するものである．

4. 提携形成シミュレーション機構の概要

図 6 に，シミュレーション機構の構成を示す．本シミュレーション機構は，提携構造の評価器と，最適な提携構造を近似的に高速に求めるための遺伝的学習モジュールを実装したマルチエージェントによる提携構造生成器からなる．協力ゲームの表現は MC-nets に沿って，提携に属するプレイヤーの集合とそれに対する提携の価値の組のルール集合として表される．シミュレーション初期状態として，ランダムな遺伝子を持つエージェントを複数体生成し，そのエージェントの遺伝子から提携構造を生成する．その後，得られる提携構造を Listings 1 に示す提携構造評価器によって提携構造の効用を求め，ルーレット法によって個体を選択し，交叉，複製，もしくは突然変異を

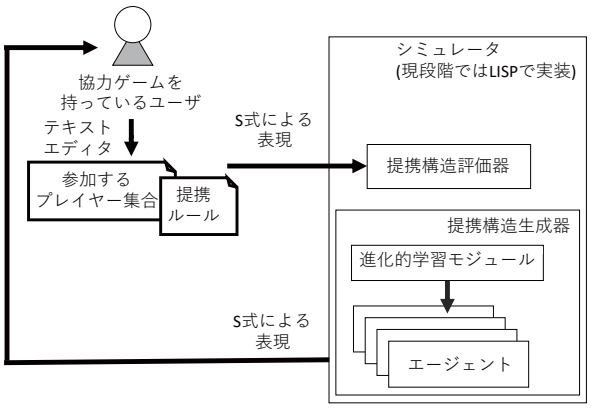


図 6: 提携形成シミュレータの構成

起こす．交叉の手法は確率 0.5 での一様交叉を使用している．

Listing 1: 提携構造の評価関数

```
;ルールを適用する関数;
(defun apply-rule (coalition rule)
 (if
  (not (or (set-difference (positive-player-set rule)
       coalition)
           (intersection coalition (negative-player-set
               rule))))
  (rule-value rule)
  0))

;; 提携の値を求める関数
(defun coalition-value-of (coalition game)
 (loop for i in game
  sum (apply-rule coalition i)))

;; 提携構造の値を求める関数
(defun coalition-structure-value-of (coalitionstructure
     game)
 (loop for j in coalitionstructure
  sum (coalition-value-of j game)))
```

5. 提携形成シミュレーション機構の動作例

図 7 と図 8 に，本研究で試作したシミュレータによる提携構造変化の動作例を示す．本動作例に使用したルール追加のタイミングと追加するルールは，図 9 に示す．

図 7 は，提携構造の距離を考慮せず常に提携構造生成器から出力された提携構造を選択した場合の結果である．ここで，ALICE, BOB, CHARLEY, DAN, ELLY, および FUKU はそれぞれ異なるプレイヤーを示し，丸括弧で括られた名前同士は同じ提携に属しているプレイヤーを表している．たとえば，(ALICE BOB) は，ALICE と BOB という 2 つのプレイヤーが同じ提携に属していることを示す．EFFICIENCY はその提携構造から得られる利得を表わしている．このとき，2 タイムステップ目と 3 タイムステップ目において同じ効用であるにもかかわらず，異なる提携構造が出力されている．

それに対して，図 8 では，提携構造の距離をどのような変化も 3 であるとして動作をさせた場合の結果を示している．このとき，1 タイムステップ目に提携構造が形成されると，その時点から 7 タイムステップ目まで変化していない．これは，新た

```
TIMESTEP :1 ((DAN) (BOB FUKU) (ALICE) (CHARLEY ELLY))
EFFICIENCY :0
TIMESTEP :2 ((DAN) (ALICE BOB CHARLEY) (ELLY FUKU))
EFFICIENCY :4
TIMESTEP :3 ((ALICE BOB CHARLEY DAN) (ELLY FUKU))
EFFICIENCY :4
TIMESTEP :4 ((ALICE BOB CHARLEY DAN) (ELLY FUKU))
EFFICIENCY :5
TIMESTEP :5 ((BOB) (ELLY FUKU) (ALICE CHARLEY DAN))
EFFICIENCY :7
TIMESTEP :6 ((BOB ELLY FUKU) (ALICE CHARLEY DAN))
EFFICIENCY :7
TIMESTEP :7 ((ELLY FUKU) (BOB CHARLEY) (ALICE DAN))
EFFICIENCY :7
TIMESTEP :8 ((CHARLEY) (BOB DAN ELLY FUKU) (ALICE))
EFFICIENCY :10
TIMESTEP :9 ((CHARLEY) (BOB DAN ELLY FUKU) (ALICE))
EFFICIENCY :14
TIMESTEP :10 ((CHARLEY) (BOB DAN ELLY FUKU) (ALICE))
EFFICIENCY :14
```

図 7: 提携構造の変化にコストを掛けなかった場合の動作例

```
TIMESTEP :1 ((CHARLEY) (ELLY FUKU) (ALICE BOB DAN))
EFFICIENCY :3
TIMESTEP :2 ((CHARLEY) (ELLY FUKU) (ALICE BOB DAN))
EFFICIENCY :3
TIMESTEP :3 ((CHARLEY) (ELLY FUKU) (ALICE BOB DAN))
EFFICIENCY :3
TIMESTEP :4 ((CHARLEY) (ELLY FUKU) (ALICE BOB DAN))
EFFICIENCY :4
TIMESTEP :5 ((CHARLEY) (ELLY FUKU) (ALICE BOB DAN))
EFFICIENCY :4
TIMESTEP :6 ((CHARLEY) (ELLY FUKU) (ALICE BOB DAN))
EFFICIENCY :4
TIMESTEP :7 ((CHARLEY) (ELLY FUKU) (ALICE BOB DAN))
EFFICIENCY :4
TIMESTEP :8 ((ALICE CHARLEY) (BOB DAN ELLY FUKU))
EFFICIENCY :10
TIMESTEP :9 ((ALICE CHARLEY) (BOB DAN ELLY FUKU))
EFFICIENCY :12
TIMESTEP :10 ((ALICE CHARLEY) (BOB DAN ELLY FUKU))
EFFICIENCY :12
```

図 8: 提携構造の変化のコストを 3 と定義した場合の動作例

に形成された提携構造の効用が 7 を越えないため現在の状況を維持しようとしているものと考えられる．3 タイムステップ目から 4 タイムステップ目で効用が 1 増加しているのは，4 ステップ目で新たに追加されたルール `((alice dan) () 1)` によって既存の提携構造に新たな効用が追加されたからである．

6. まとめと今後の課題

本研究では，連続協力ゲームの提携形成シミュレーション機構の試作について述べた．シミュレーション中において提携形成過程に慣性を導入することにより，異なった構造を持つ提携構造への変化が阻害され，段階的な提携構造の変化が起きることを観測した．提携構造の慣性の導入により，等しい効用を持つ提携構造への変化が提案される状況であったとしても，変化に対するコストの影響で提携構造が変化しないことを観測した．

今後の課題としては，提携構造の距離の定義方法の洗練や，プレイヤーのゲームからの離脱および参入を考慮することが挙げられる．本シミュレーション機構においては，提携構造の慣性をハイパーパラメータとして設定可能としておりシミュレーション中に変化することはないものの，提携構造の間の距離を

```
(defparameter *RULE-WITH-TIME*
  '((1 . ((alice bob charley) () 1))
    (1 . ((fuku elly) (charley) 3))
    (4 . ((alice dan) () 1))
    (4 . ((alice) (bob) 3))
    (7 . ((bob dan fuku) (alice) 4))
    (9 . (() (fuku) 1))))
```

図 9: ルール追加のタイミングのリスト例

慣性の指標とすることで提携構造が変化する際により近い提携構造を選択することが可能になる．

参考文献

[Aadithya 11] Aadithya, K., Michalak, T., and Jennings, N.: Representation of Coalitional Games with Algebraic Decision Diagrams, Technical Report UCB/EECS-2011-8, EECS Department, University of California, Berkeley (2011)

[Aumann 74] Aumann, R. J. and Dreze, J. H.: Cooperative games with coalition structures, *International Journal of Game Theory*, Vol. 3, No. 4, pp. 217–237 (1974)

[Bachrach 13] Bachrach, Y., Kohli, P., Kolmogorov, V., and Zadimoghaddam, M.: Optimal Coalition Structure Generation in Cooperative Graph Games, in *Proceedings of the Twenty-Seventh AAAI Conference on Artificial Intelligence*, AAAI'13, pp. 81–87, AAAI Press (2013)

[Conitzer 06] Conitzer, V. and Sandholm, T.: Complexity of constructing solutions in the core based on synergies among coalitions, *Artificial Intelligence*, Vol. 170, No. 6, pp. 607 – 619 (2006)

[Driessen 13] Driessen, T. S.: *Cooperative games, solutions and applications*, Vol. 3, Springer Science & Business Media (2013)

[Ieong 05] Ieong, S. and Shoham, Y.: Marginal Contribution Nets: A Compact Representation Scheme for Coalitional Games, in *Proceedings of the 6th ACM Conference on Electronic Commerce*, EC '05, pp. 193–202, New York, NY, USA (2005)

[Lesca 17] Lesca, J., Perny, P., and Yokoo, M.: Coalition Structure Generation and CS-core: Results on the Tractability Frontier for games represented by MC-nets, in *Proceedings of the 16th Conference on Autonomous Agents and MultiAgent Systems*, pp. 308–316International Foundation for Autonomous Agents and Multiagent Systems (2017)

[McCarthy 60] McCarthy, J.: Recursive Functions of Symbolic Expressions and Their Computation by Machine, Part I, *Commun. ACM*, Vol. 3, No. 4, pp. 184–195 (1960)

[Rothe 15] Rothe, J. and Rothe, I.: *Economics and Computation: An Introduction to Algorithmic Game Theory, Computational Social Choice, and Fair Division*, Springer Texts in Business and Economics, Springer Berlin Heidelberg (2015)

Oral presentation | Organized Session | [Organized Session] OS-18

[3K1-OS-18a] [Organized Session] OS-18

Thu. Jun 7, 2018 1:50 PM - 3:10 PM Room K (3F Azisai Mokuren)

[3K1-OS-18a-01] High-Speed Calculation in Structural Analysis by Reinforcement Learning

○Soshi Nakamura[1], Takuya Suzuki[2] （1. McGill University, 2. Takenaka Corporation）

1:50 PM - 2:10 PM

[3K1-OS-18a-02] A simulation of total evacuation drill in office building using multi agent model

○Takaki Tojo[1], Mineko Imanishi[1], Akihide Jo[1] （1. Takenaka Corporation）

2:10 PM - 2:30 PM

[3K1-OS-18a-03] Damage evaluation of building via convolutional neural network

○Takenori Hida[1], Taro Yaoyama[1], Tsuyoshi Takada[1] （1. The University of Tokyo）

2:30 PM - 2:50 PM

[3K1-OS-18a-04] Image Recognition Examination for Classification of Reinforcing Bar

○Kyosuke Ichikawa[1], Go Sakaguchi[1] （1. Ark Information System）

2:50 PM - 3:10 PM

©The Japanese Society for Artificial Intelligence

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

強化学習による構造解析の高速化

High-Speed Calculation in Structural Analysis by Reinforcement Learning

中村 壮志[*1]
Soshi Nakamura

鈴木 琢也[*2]
Takuya Suzuki

[*1] マギル大学
McGill University

[*2] 竹中工務店
Takenaka Corporation

By improvement of computer's performance, it has become to enable to simulate the behavior of structure, soil and so on using the nonlinear structural analysis of large and complex models. However, these simulations require lots number of convergent calculation to search a convergent solution. Although there are several convergent methods such as Newton's method, there is no almighty method that fits all situations. Hence, it is up to the person carrying out the analysis to select one of these methods. Considering this situation, in this paper, we propose a method to choose and combine the appropriate convergent method using the concept of Q-learning from reinforcement learning. First, using simple analysis model, we train an action value table to choose the appropriate convergent method with Q-learning. Then, we carried out an analysis using obtained action value table and show that our method can make the convergence time shorter than conventional ones.

1. はじめに

近年の計算機能力の発達に伴い，構造解析分野における要素数・節点数の多い大規模な解析モデル（図 1）を用いたより高精度な数値シミュレーション解析が現実的になりつつある（例えば[Shigeno 2014]）。この大規模解析は，対象とする構造物が線形モデルに留まる場合においては，既に実用化レベルに達している。しかし，構造物に線形性を仮定することは限界があり，今後は，非線形状態に至るまでの解析が求められるようになっていくと考えられる。現状では，大規模モデルの非線形解析を陰解法によって行う場合，非常に大きな計算時間が必要となり，実用化に向けた大きな課題のひとつとなっている。

一般に陰解法に基づく非線形構造解析における解は，外力等の時々刻々の条件から，Try & Error の収束計算によって求められる。収束計算には，初期剛性法（修正 Newton 法），接線剛性法（Newton 法），BFGS 法，ラインサーチ法など様々なものがある[野口 1995]が，それぞれの手法には長所，短所があり解こうとする問題に応じて適切な手法は異なるため，どの問題に対しても有効な収斂手法は明示されていない。そのため，実際にどの収斂方法を選択するかは，解析実施者の経験（あるいは勘）に委ねられているのが現状である。

このような課題に対し，著者らは，これら既往の収斂手法を問題や収斂状況に応じて適切に組み合わせることを考えている。それぞれの手法を最もふさわしい場面で選択することができれば，これまでの単一の収斂手法のみを用いる場合に比べて，効率よく収斂解が探索できる可能性がある。一方，計算を早期に終了するための，適切な組み合わせ方法は，モデルの規模，計算機のスペック等にも依存し，人が設定することは非常に困難であると考えられる。そこで，本研究においては，この適切な収斂方法の選択を，強化学習における Q 学習の枠組みで行う手法を提案する。まず，行動価値テーブルを用いて適切な収斂手法を選択する提案手法を説明する。つづいて，簡単な例題を使って，Q 学習を用いて行動価値テーブルの更新を行う。最後に，学習の結果を用いて数値計算を実施し，従来手法と比較して高速化が可能になっているかを検証する。

連絡先：鈴木琢也，竹中工務店，千葉県印西市大塚 1-5-1，
0476-47-1700，0476-47-6460，suzuki.takuya@takenaka.co.jp

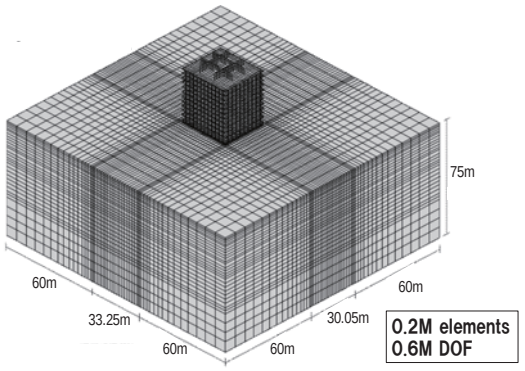


図 1　大規模解析モデルの一例[Shigeno 2014]

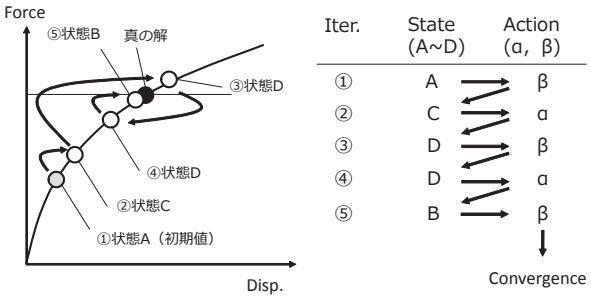


図 2　提案法による収斂計算のイメージ

2. ハイブリッド収斂手法の概要

図 2 には提案する収斂計算のイメージを示す。

ここでは簡単のため，2 種類の収斂法（α,β）を組み合わせて収斂計算を行う場合を考える。図に示すように，ある解析ステップにおいて収斂解を得ようとする場合，まず，現時点の状態（A~D）に基づいて行動価値テーブルを参照し，最も価値の高い収斂手法を選択する。つづいて，選択された収斂手法を用いて予測解を算出する。さらに，その予測解の許容誤差を確認し，

許容範囲内であれば，次のステップへ，範囲外であれば，更新された状態に基づいて再度行動価値テーブルの参照，収斂手法の選択を繰り返す。具体的な行動価値テーブルの構成や，個々の収斂解析手法については後述する。

3. 検討対象例題

提案手法の検証に用いる例題解析について説明する。

解析モデルは，図 3 に示す地盤を模擬した要素数 7452，節点数 8664 のモデルとする。地盤のせん断剛性は 18MPa，ポアソン比は 0.3，単位体積質量は 1.8t/m^{3}とする。非線形特性には，VonMises の降伏条件を用い，降伏応力度は 50kPa，降伏後の二次剛性は 2.0MPa とし，地盤の拘束圧による剛性上昇を考慮する。境界条件は，底面固定，側面繰り返し境界とし，上部地盤の剛体を鉛直下向きに 2000kN の荷重を 200kN ずつ 10Step に分けて載荷し，変形解析を実施する。

本研究では，この例題解析の収斂計算を接線剛性法（ニュートン法）と初期剛性法（準ニュートン法）とを組み合わせることで高速化が可能であるかどうかを検証する。両者の収斂方法の違いを図 4 に示す。

ここで，接線剛性法は，毎回接線勾配を更新するため予測解の精度が高く比較的少ない収斂回数で収斂解を得られることを特徴とする。しかしながら，接線勾配の更新や逆行列の算定に時間を要するため，大規模なモデルでは 1 回の接線勾配の更新に多くの時間を要する場合がある。一方，初期剛性法は接線勾配を更新せず，常に同じ勾配を用いる手法である。そのため 1 回の予測解の計算に必要な時間は接線剛性法よりも短いが，予測解の精度が低く，収斂回数は増えてしまう。

なお，本検討例題を全て接線剛性法によって行った場合の解析時間は 210 秒，全て初期剛性法によって行った場合は 35 秒であった。今回のモデルは要素数・節点数が比較的大きいため接線勾配法においては，収斂回数を低減できるメリットよりも 1 回の更新に時間がかかるデメリットの方が大きかったものと推察される。

4. 学習計画

学習には Q 学習[Watkins 92]を用いる。行動価値テーブルの構成を図 5 に示す。図に示すように，状態は，「前回までに初期剛性法を繰り返したか」，すなわち「最後に接線剛性法を選択したのは何回前か」で分ける。ただし，最初の3回分については，別の状態として認識する。この表中の網掛けした部分の行動価値を Q 学習によって算定する。

学習は，前述の解析モデルを用いて，様々な収斂手法選択条件下で 10000 回（10STEP×1000 回）実施する。学習時の収斂手法選択は，更新回数を 30 回までに，1 回ないし 2 回接線剛性法を選択するものとして，モンテカルロ手法によってランダムに変化させる。このように，接線剛性法の選択回数を絞ったのは，前章の結果より，接線剛性は計算時間的に不利であり，より少なくする方が有効であると考えたためである。

報酬 R は，各ステップの収斂に要した時間 t から下記の報酬関数を用いて，行動価値テーブルの各行動に分配する。収斂に要した時間が少ないほど，大きな報酬が得られるようにしている。

$$R = 1/t \qquad (1)$$

なお，割引率は考慮せず，(1)式で得られた値を選択した行動に単純に加算していく。

学習のフローを図 6 に示す。

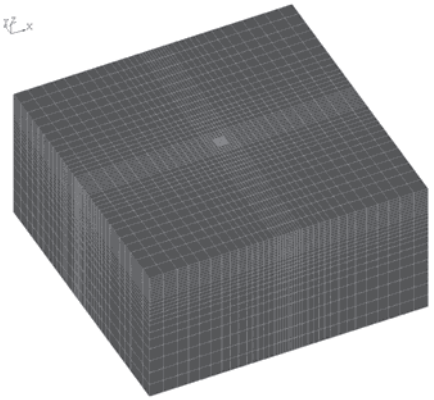
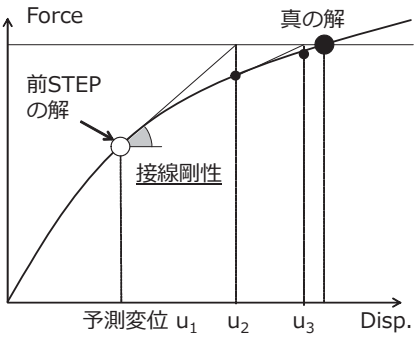
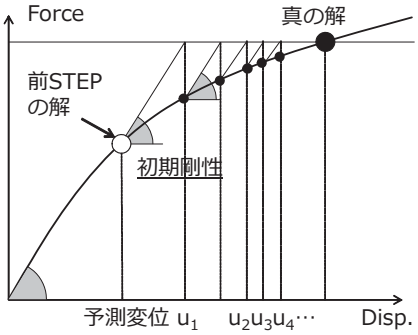


図 3　解析モデル（100m×100m×50m）



(a)接線剛性法



(b)初期剛性法

図 4　接線剛性法と初期剛性法の違い

State		Action	
		初期剛性法	接線剛性法
Iter.　1回目			
Iter.　2回目			
Iter.　3回目			
Iter. 4回目以降	前回に接線剛性法を選択(before1)		
	前回まで初期剛性法を連続1回選択(before2)		
	前回まで初期剛性法を連続2回選択(before3)		
	・・・		
	前回まで初期剛性法を連続28回選択before29)		

図 5　行動価値テーブルの構成

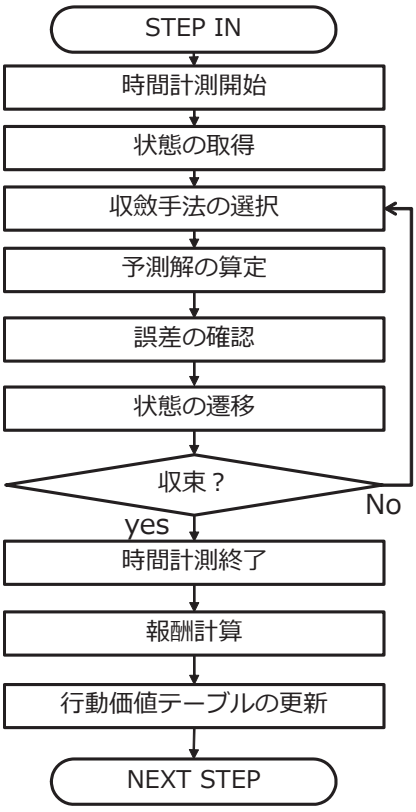


図 6　学習フロー図

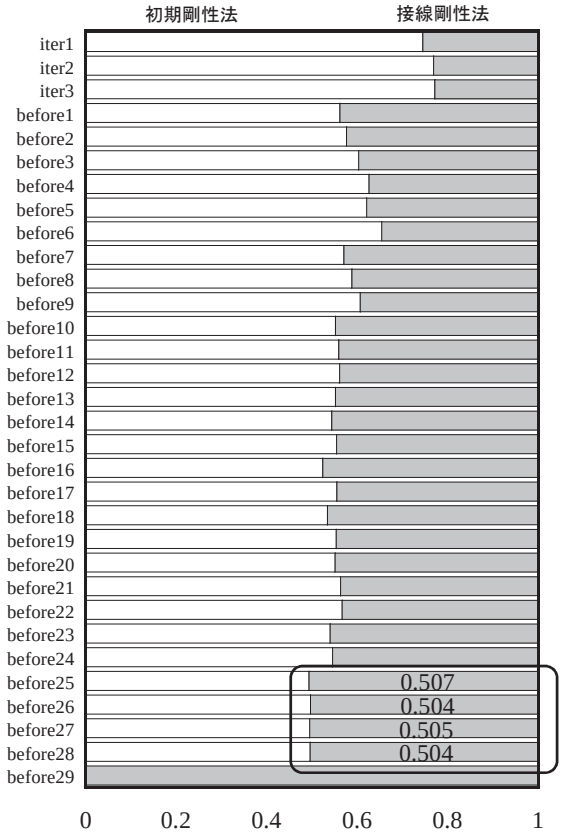


図 7　学習後の行動価値テーブル

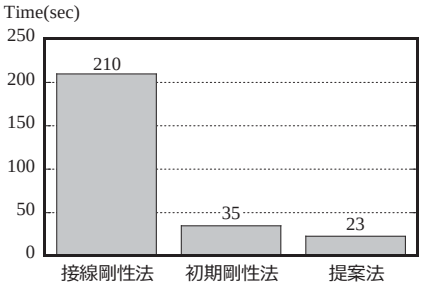


図 8　計算時間の比較

5. 学習結果

図 7 には，学習によって得られた行動価値テーブルの値を示す。なお，今回はモンテカルロ的に収斂手法を決め打ちで実施しているため，各状態に対して，それぞれの手法の効果を等確率で検討できていない可能性を考慮し，最終的に得られた Q 値を頻度で除算するとともに，両方の手法の和が 1 となるように正規化して表示している。

図より，初期剛性法を連続して選択した回数が少ない場合には初期剛性を選択する価値が高く，連続選択の回数が多くなるにつれて徐々に，接線剛性法を選択する価値が高くなる傾向があることがわかる。特に初めのイテレーション 3 回においては，いずれも初期剛性法を選択する価値の方が高い結果となった。今回のテストモデルは比較的大規模であり，1 回の接線剛性更新にかかる計算コストが大きいため，短いスパンで何度も接線剛性法を選択する価値は低くなったものと考えられる。

算定した行動価値の中で，初期剛性法よりも接線剛性法を選択する価値が高くなる状態は，連続で初期剛性法を選択した回数が 24～28(before25-29)回のときであった。ただし，このうち before29 の価値は今回のモンテカルロ探索で，初期剛性法を選択する機会がなかったために生じた特異値であるため，有意な値ではない。これらの結果より，今回のモデルは 25 回おきに接線剛性法を選択することが，計算時間削減に有効であると推察される。

そこで，25 回目のみに接線剛性法を選択して計算時間を計測した結果を図 8 に示す。図に示すように 25 回目のみを接線剛性法を選択した場合の計算時間は 23 秒となり，接線剛性法のみを選択した場合の 210 秒，初期剛性法のみを選択した場合の 35 秒よりも計算時間を短縮できることが確認できた。

6. まとめ

本研究においては，行動価値テーブルを用いて複数の収斂計算方法を適切に選択して収斂を行う手法を提案した。さらに，簡単な例題を使って，強化学習を用いて行動価値テーブルの更新を行い，その結果得られる行動価値テーブルを用いて数値計算を実施し，従来手法と比較して高速化が可能になっていることを確認した。

参考文献

[Shigeno 2014] Shigeno, Y., Hamada, J., Nakamura, N.: Hybrid parallelization of earthquake response analysis using K computer, Proceeding of 14thIACMAG, 2014.

[野口 1995] 野口裕久，久田俊明:非線形有限要素法の基礎と応用，丸善，1995.

[Watkins 92] Watkin, C. J. C. H. and Dayan, P.: Technical note Q-learning. Machine Learning 8(3):279-292, 1992

マルチエージェントモデルによるオフィスの全棟避難訓練シミュレーション

A simulation of total evacuation drill in office building using multi agent model

東城峻樹[*1] Takaki Tojo　今西美音子[*1] Mimeko Imanishi　城明秀[*1] Akihide Jo

[*1] 竹中工務店 Takenaka Corporation

Evacuation planning is an important issue to estimate cost and safety of buildings in the basic design phase for the architectural design. Building safety is evaluated according to evacuation safety verification method, multi agent simulation model and otherwise. However, specialized knowledge about human behavior of the building evacuation is insufficient. In this paper, an evacuation simulation of total evacuation drill in office building using multi agent model is conducted. Moreover, the result of simulation is compared with acquired measurement data of actual evacuation behavior especially for evacuation time and route selections. The route selections of simulation are different from that of actual behavior.

1. はじめに

建築設計において，避難計画は基本設計プランに関わる重要な課題である．設計実務者においては，例えば避難安全検証法[国土交通省 2001]による比較的簡易な計算，あるいは群集流動の可視化が可能なマルチエージェントモデル[天野 2013]（以下，MA モデル）によるシミュレーションなどを実施し，建物プランの安全性評価を行っている．

一方，現実における建物避難時の人間行動は，未だ不明点が多い．前述の計算手法を用いて計画を策定する場合も，歩行速度などのパラメータから避難者の経路選択に至るまで，必要な数値や行動選択に仮定が含まれることが一般的である．そのため，各種歩行実験[例えば城 2017]により得られたデータなどを蓄積し，実際のデータと設定数値などを比較・検証していくことが設計精度の向上の観点からも重要となる．

本検討では，文献[今西 2018]に記載の実際のオフィスビルにて実施された全棟避難訓練を対象に，MA モデルを用いて，ブラインドシミュレーションを行い，訓練時に取得された実データ（以下，訓練時データ），特に避難時間や経路選択を対象に両者の結果を比較する．ここで，ブラインドシミュレーションとは，避難者の初期配置など必要最低限のみ訓練時データに基づくパラメータを考慮するほかは，慣用的に使用する設計仮定などに基づく状態で，実際の訓練時データを参照せずに計算を実施することを指す．

2. 全棟避難訓練の概要

シミュレーションの対象とした全棟避難訓練の詳細は，文献[今西 2018]に記載があるため，ここでは概要のみを示す．取得された訓練時データの詳細な取得方法なども同文献を参照されたい．

検討対象建物は，地下 1 階，地上 4 階建てのオフィスビルであり，訓練時には執務スペースである 1 階~3 階を対象として屋内での行動データが得られている．図 1(a)~(c)に，対象となる建物の 1~3 階の平面図を示す．但し，屋外や直接避難に使用しない範囲は一部を省略している．訓練時には，図中に示す避難階段および通路（各階段 3 か所，通路 2 か所：□にて表示）に設置されたカメラにより避難行動が記録され，途中経路の行動は取得されていない．ここでは，カメラが設置された階段 3 か所および近傍の交差路を通る経路をそれぞれ Staircase1~3，Crossing1,2 と称す．Crossing1,2 間の通路は，避難者のおよその歩行速度を算定するのに利用している．避難者（従業員）は，

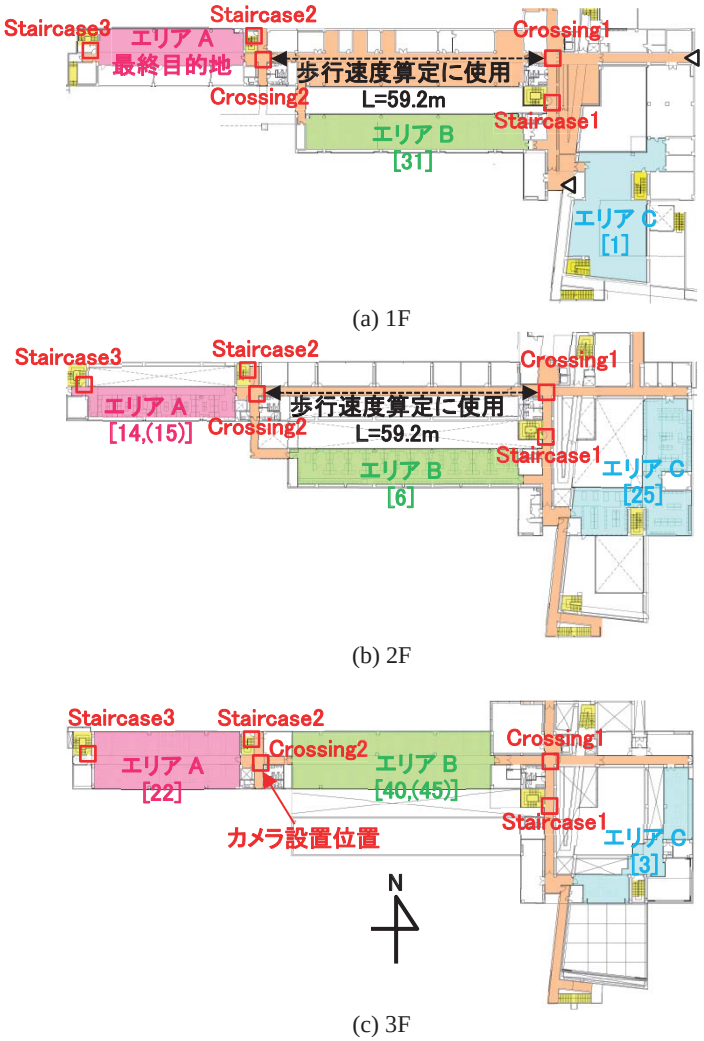


図 1　対象オフィスの各階平面図

連絡先：東城峻樹，竹中工務店，千葉県印西市大塚 1-5-1，080-2454-9143，0476-47-3050，toujou.takaki@takenaka.co.jp

図中に示す各階のエリア A~C に計 150 名程度，在席していたとされ，うち 140 人程度について有効なデータが取得されている．なお，当該建物の用途上の関係から，通常のオフィスビル（0.125 人/m^2[国土交通省 2001]）に比べ人口密度は最大で 0.09 人/m^2 程度とやや小さい．当日は，天候の影響から調査対象外としていた建物屋外を移動する予定の従業員約 50 名が，実際には，屋外から屋内に合流して避難がなされていたことがわかっている．これらの避難者は，図 1(a)の◁より，屋外から屋内へ合流したと推察され，1F 部分の避難行動（後述する表 1 の歩行速度など）において，その影響が含まれたデータである点に注意を要する。図 1 中に，各エリアにおけるデータ取得人数を[ ]で示す．また，訓練時にデータ取得に必要なマーカーの不設置などで，データ取得がなされていないものの，当日在席していたことが確認できたため，シミュレーションでは反映した人数が異なる場合のみ( )で併記する．避難時には，移動通路や使用する階段（それぞれ，図中，橙色，黄色で表示）は制限されておらず，集合場所である 1F 西側のエリア A（最終目的地）までの経路は避難者が自由に選択している．

3. シミュレーションの概要

前述の全棟避難訓練を対象に，ブラインドシミュレーションを行う．シミュレーションには，ポテンシャル型の MA モデルを用いた汎用コード SimTread[木村 2009]を用いる．SimTread は，目的地までの距離に基づくポテンシャル値によって進路を決定する。そのため，本検討では最終目的地（1F エリア A）だけでなく，以降に示す経路選択仮定に従い，中間目的地を配置する．

以下に，主なシミュレーション設定を箇条書きで示す。1)については，文献[今西 2018]のデータ取得結果に基づき，それ以外は，避難安全検証法などで考慮するパラメータや慣用的な仮定を採用する。

1) 在館者の数は，同訓練時に行われたアンケートを基に，避難開始時の位置が推定された 148 人（マーカー不設置者等を含む）とする．なお，2 章で言及した屋外から合流した避難者（50 人程度）については，条件設定が困難であることから，検討対象から除外する．
2) エージェントの歩行速度は一律 1.3 m/s とする[国土交通省 2001]．
3) 階段エリアは，歩行速度の制限を設け，上限速度を 0.78m/s とする[国土交通省 2001]．
4) エージェントは，最も近くの避難階段を選択して避難を開始する（全ての避難階段に同じ重みの目的地を配置する）．その後，最終目的地を目指す．
5) 避難開始時刻 t_{start} は，避難放送完了と同時と仮定し，その時点を 0 秒として，一斉に避難を開始する．

図 2 に，代表として対象建物の 3F 平面のモデル図を示す．歩行速度への影響を考慮し，執務スペース内の主要な什器は障害物としてレイアウトする．

4. シミュレーションと訓練時データの比較

ここでは，ブラインドシミュレーションと訓練時データの双方より得られた結果から避難時の行動特性を比較する．但し，訓練時データのうち，同一時刻付近に距離の離れた複数地点でデータが存在するなど，データの取得精度が低いと考えられるものは分析から除外する．

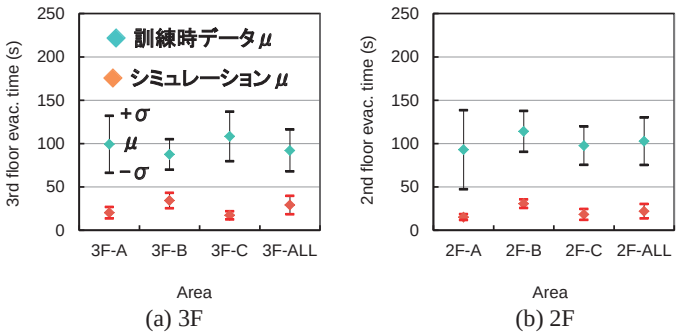
4.1 避難開始エリアと避難時間の関係

図 3(a),(b)にそれぞれ 3F，2F の各執務エリアから避難開始した避難者の各階避難完了時間の比較を示す．ここで，階避難時間は，当該階の避難者が階段（図 1，Staircase1~3）に設置されたカメラからフレームアウトした時間として定義する．シミュレーションにおいても，おおよそ同じとなる到達位置を設定し，計測する．また，避難時間は，各エリアにおける全避難者の平均値 μ とする．更に同図には標準偏差 σ を考慮した $\mu \pm \sigma$ の範囲を併記する．

同図(a),(b)より，各階とも，訓練時データに比べて，シミュレーションは，60~80 秒程階避難までの時間が早い．また，各エリアの避難時間のばらつき$\pm\sigma$ も，シミュレーションに比べ，訓練時データの方が大きい．これは，階段への到達時間が，避難開始位置のみの差ではなく，実際に避難を開始した時間や，平均的な歩行速度などが，実際の訓練時はばらつきが大きいことを示唆している．なお，エリア A~C における，それぞれの階避難完了時間の差異は，双方とも 10~20 秒程度である．但し，避難経路の選択が異なるため，訓練時データとシミュレーションの避難時間の傾向は，両者でやや異なる．



図 2　シミュレーションのモデル図（3F）



(a) 3F　　(b) 2F

図 3　階避難時間の比較

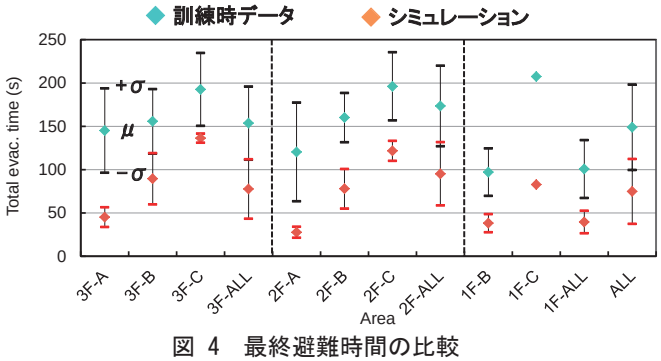


図 4　最終避難時間の比較

表 1　訓練時データによる歩行速度

階数	2F	1F
歩行速度(m/s)	1.4	0.6

図 4 に 1~3F の各エリアから最終目的地までの避難完了時間の比較を示す. 避難時間は, 図 3 と同様に $\mu \pm \sigma$ の範囲を示す.

同図より, 3F, 2F については訓練時データとシミュレーションを比べると, 平均的には, 最終避難完了時において, 60~100 秒程度の差異があり, 各階避難完了時のデータとシミュレーションの差に対し, 若干増加する傾向があるものの, 各階避難完了時点での時間差と大きく変わらないまま, 避難完了に至る傾向が認められる. これより, 訓練時データとシミュレーションの避難完了時間の差異は, 初期行動時(階避難時の開始時刻や歩行速度)の影響が大きいものと考えられる. また, 途中の経路選択は一致しないものの(詳細は後述), 各通路や階段での歩行速度, 滞留が発生する箇所は概ね対応していたものと推察される. 表 1 に, 訓練時データにおいて図 1 で示した 1F, 2F 通路(Crossing1~2)を通過した避難者の平均移動時間から求めた歩行速度を示す。2F における歩行速度はシミュレーションで設定した 1.3m/s と比較的近い 1.4m/s となっている. また, 屋外からの避難者(シミュレーションでは非考慮)と Crossing1 にて合流があったと推察される 1F 通路では, 歩行速度が半分程度に低下している.

図 4 について, 各階ごとに, 全体的な傾向をみると, 避難完了時間がエリア A<B<C の順に増加しており, 最終目的地からの距離が遠いエリアの方が, 避難にかかる時間が増加する様子が, 双方とも窺える. また, 3F, 2F の各エリアとも図 3 に比べ, 図 4 では平均避難時間 μ に対するばらつき σ の幅が大きくなる傾向にある. 階避難時間に大きく関わる初期の行動(避難開始時間や開始時の歩行速度)で生じたばらつきに加えて, 他の階の出入り口や交差路などで避難者間の合流が増えることで, 訓練時データ, シミュレーションとも各エリアの避難完了時間のばらつきが大きくなる傾向がみられる.

4.2 避難経路の選択

ここでは, 3 章の前提条件によるシミュレーションの経路選択(最も近くの避難階段を選択)と訓練時データより得られた実際の経路選択を, 各エリアについて比較する.

図 5(a)~(c)に 3F, 図 6(a)~(c)に 2F の, 各 A~C のエリアにおける, 避難経路の選択結果を示す. それぞれ, 左図が訓練時データ, 右図がシミュレーションの結果である. 図中の数値は, 各エリアにおいて, 図 1 に示した階段(Staircase1~3)を通った割合(所属エリアの経路選択人数/所属エリアの合計人数)を示す. なお, シミュレーションでは, Staircase1~3 以外の経路を選択した場合は etc と表記する.

図 5,6(a)より, エリア A に関しては, 最終目的地の直上に位置し, 執務エリアの両側へ避難階段があることから, 概ね, 避難開始時点(多くの避難者は自席)から距離の近い避難階段を選択したものと考えられる. そのため, 訓練時データ, シミュレーションの結果は概ね対応する. 一方, 各図(b),(c)より, エリア B, C に関しては, それぞれ右図のシミュレーションでは最も近い避難階段を経路選択に仮定しており, 必ずしも最終目的地に近いルートを選択しないのに対し, 左図の訓練時データを見ると, 実際には, ほぼ 9 割を超える避難者が Staircase2, すなわち, より最終目的地に近い階段を選択している. 図 5(c)の避難者に着目すると, 上記の傾向が顕著に表れており, 左図の訓練時データでは, 全ての避難者が, Staircase2 を選択している. すなわち, エリア C から北側の通路に出て, その後エリア B を通過して移動しており, 一旦通路に出て他のエリアを通過しての避難経路選択がなされている. 今回対象とした避難訓練では, 屋内の一か所を目指した避難であり, 最終目的地により近い経路となった可能性がある. また, 避難者が従業員であり, 経路を熟知している点も, 留意が必要である.

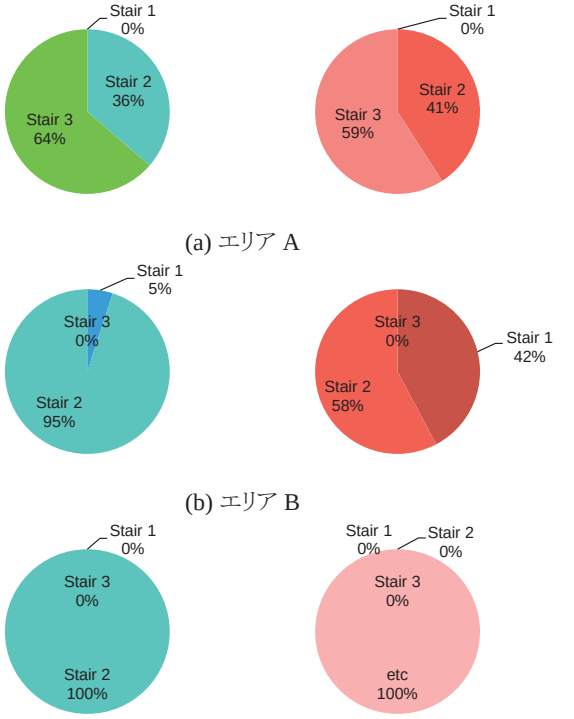


図 5　3F 避難経路の比較（左:訓練, 右:シミュレーション）

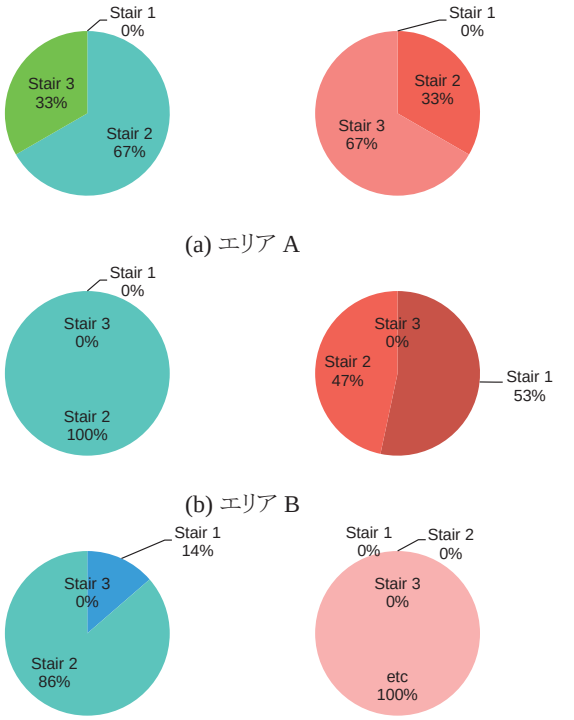


図 6　2F 避難経路の比較（左:訓練, 右:シミュレーション）

4.3 まとめ

オフィスの全棟避難訓練を対象に，ブラインドシミュレーションを行い，訓練時データと比較を行った．得られた結果は以下である．

1) 避難時間は，各階，最終避難時間ともに，訓練時データによる実時間に比べ，シミュレーションの方が，1 分以上短い傾向にある．これは，階避難の結果より，初期の行動（避難開始時間や歩行速度の設定）による差異が大きいと考えられる．
2) 途中経路における，避難者の歩行速度は，屋外避難者の合流する 1F 部分を除き，概ね対応する傾向が示唆される．
3) 避難経路の選択は，最終目的地に最も近い経路（階段）を選択する傾向にあり，本シミュレーションで仮定した行動とは異なっている．

今後，今回得られた結果を基に，パラメータスタディなどを行い，歩行経路の選択や，設定値の差異が与える影響について詳細に検討する予定である．

参考文献

[国土交通省 2001] 国土交通省: 2001 年版 避難安全検証法の解説及び計算例とその解説，2001.

[天野 2013] 天野和洋ほか: 熱煙流動を考慮した避難シミュレータの開発，日本火災学会研究発表会梗概集，日本火災学会, 2013.

[城 2017] 城明秀ほか: 空間条件が群集歩行性状に与える影響に関する実験的研究 日本建築学会計画系論文集，日本建築学会, 2017.

[今西 2018] 今西美音子: オフィスの全棟避難訓練における移動経路計測，日本火災学会研究発表会梗概集，日本火災学会, 2018(掲載予定).

[木村 2009] 木村謙ほか: マルチエージェントモデルによる群衆歩行性状の表現，日本建築学会計画系論文集，日本建築学会, 2009.

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建築物の被災度判定

Damage evaluation of building via convolutional neural network

肥田 剛典[*1] Takenori Hida
八百山 太郎[*1] Taro Yaoyama
高田毅士[*1] Tsuyoshi Takada

[*1] 東京大学大学院 工学系研究科 建築学専攻
Department of Architecture, Graduate School of Engineering, The University of Tokyo

In order to carry out prompt restoration activities after the occurrence of a natural disaster such as an earthquake, it is important to grasp the buildings' damage situation and damage distribution of the affected area as soon as possible. In this study, the buildings' damage is evaluated from the image data of building by using Convolutional Neural Network. Furthermore, to grasp the geographical distribution of the damage, a results of the damage evaluated by CNN are plotted on a map.

1. はじめに

2016 年熊本地震において，多くの建物被害が発生した．地震等の自然災害発生後に迅速な復旧活動を行うためには，可及的速やかに被災地の被害状況や分布を把握することが不可欠である．

本研究では，深層学習 (Deep Learning) の手法の一つである畳み込みニューラルネットワーク（Convolutional Neural Network [LeCun 98], 以降 CNN と記す）を用いて，建物の外観の画像データから被害の有無を判定する手法 [肥田 17] について検討する．さらに，CNN による被害判定結果を地図上に表示し，被害の地理的分布を把握する手法を構築する．

2. 画像データと CNN の概要

本研究で用いる建物画像の例を図 1 に示す．本研究では，木造，RC 造，S 造建物を対象とした．有被害建物の画像群は，2004 年新潟県中越地震，2007 年新潟県中越沖地震，2011 年東北地方太平洋沖地震，2013 年埼玉県越谷市竜巻被害および 2016 年熊本地震時に撮影した写真から構成される．従って，建物被害は地震の揺れによる被害の他，津波被害や竜巻被害を含む．無被害建物の画像は被災していない都市で無作為に撮影した健全な建物の外観の写真を用いることとした．無被害および有被害の写真をそれぞれ 1660 枚ずつ用いて，各画像を部分的に抽出し，または±5° 回転させることにより，無被害画像と有被害画像をそれぞれ 24900 枚ずつ用意した．



a) 無被害建物　　b) 有被害建物

図 1　学習に用いた建物写真の例

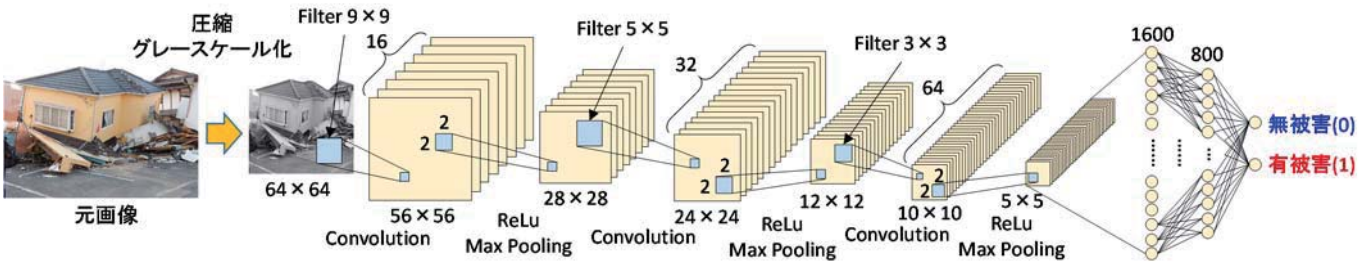


図 2　CNN の構造

連絡先：肥田 剛典，東京大学大学院工学系研究科建築学専攻，東京都文京区本郷 7-3-1，hida@load.arch.t.u-tokyo.ac.jp

本研究で用いる CNN の構造を図 2 に示す. 教師データとしては, 無被害を 0, 有被害を 1 として与えた. 学習には用意した画像 49800 枚のうち 44820 枚の画像を用いることとし, 残りの 4980 枚の画像を用いて学習結果の検証を行うこととした.

学習結果を図 3 に示す。損失率は学習開始から急激に下降する。正答率は学習開始から急激に上昇し、30 エポック付近で 92%程度に達する。その後、徐々に正答率が上昇し、500 エポック以降で 96%程度となった。

3. CNN による建物被害判定

2016 年熊本地震の被害調査を行い, その際に撮影した建物の外観の画像を用いて被害判定を行う. なお, ここで用いる画像は CNN の学習には用いていない.

CNN による被害判定結果と応急危険度判定結果を比較した例を表 1 に示す。写真 a および d では応急危険度判定結果と CNN による判定結果が対応している。これに対し、写真 b のように、外観に損傷が明瞭に表れない建物の被害判定は CNN では難しい可能性がある。また、写真 c のように樹木が多く撮影されている場合も誤判定となった。これらは今後の課題としたい。

熊本地震時の建物の被害写真に Grad-CAM [Selvaraju 17] を適用した例を図 4 に示す. この建物は, CNN により「被害有り」と判定された. CAM から, 画像の左下部の影響が大きいことが分かる. この部位は, 建物の崩壊により外壁が破壊され, 断熱材や壁下地材が露出している部分に対応している. 本稿で構築した CNN は, 画像上のこのような特徴の有無から, 建物の被害の有無を判定していると考えられる.

CNN による被害判定結果をさらに検証するため, 建物被害の悉皆調査の結果 [国総研 16] と CNN による被害有無の判定結果を比較して図 5 に示す. CNN による被害判定では, 写真を撮影した際の GPS 記録と被写体(建物)の位置が若干ずれることに注意が必要である. そのため悉皆調査結果と CNN による被害判定結果の位置が若干異なるものの, 両者による被害判定結果の分布は概ね対応している. 特に, 県道 28 号線以南～秋津川の国道 443 号線以西の地域において悉皆調査で建物の大破倒壊率が 50%以上となっており, CNN による判定結果もほぼ全て「被害あり」と判定されている. このことから, CNN を用いた被害判定が概ね妥当であることが分かる.

4. 結論

本研究では、ディープラーニングの手法の一つである畳み込みニューラルネットワークを用いた地震時建物被害の判定手法について検討した。学習したモデルで予測された被害判定結果は 96%程度の正答率となり、概ね良好な精度で被害判定を行うことが出来た。2016 年熊本地震における建物被害を予測した被害分布は既往の悉皆調査の報告と概ね良好に対応した。これにより、本手法の妥当性が示された。

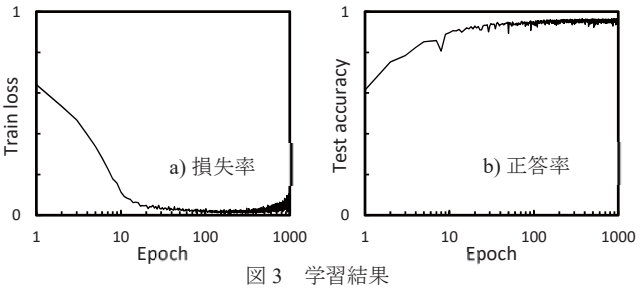


図 3　学習結果

表 1　CNN による被害判定と応急危険度判定結果の比較

	a	b	c	d
建物画像				
応急危険度判定	調査済み	危険	調査済み	危険
CNN	被害無し	被害無し	被害あり	被害あり



図 4　Grad-CAM による判定結果の可視化の例

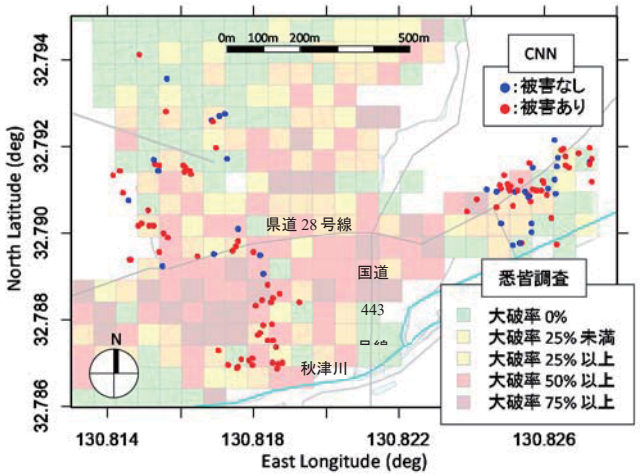


図 5　2016 年熊本地震における益城町の悉皆調査による建物の大破率[5]と CNN による被害判定結果の比較

参考文献

[LeCun 98] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner: Gradient-based learning applied to document recognition. Proc. of the IEEE, Vol. 86, No. 11, pp. 2278-2324, 1998.

[肥田 17] 肥田剛典, 八百山太郎, 高田毅士:ディープラーニングによる地震時建物被害判定と被害の地理的分布推定手法, 日本建築学会大会学術講演梗概集(中国), 構造Ⅱ, pp. 417-418, 2017. 8

[Selvaraju 17] Ramprasaath R. Selvaraju, Michael Cogswell, Abhishek Das, Ramakrishna Vedantam, Devi Parikh, and Dhruv Batra: Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization, 2017 IEEE International Conference on Computer Vision, Venice, Italy, 2017. 10

[国総研 16] 国土総合技術研究所: 熊本地震における建築物被害の原因分析を行う委員会報告書, 2016. 9

画像認識技術の鉄筋自動識別への試適用

Image Recognition Examination for Classification of Reinforcing Bar

市川 享祐[*1]
Kyosuke Ichikawa

坂口 剛[*1]
Go Sakaguchi

[*1] 株式会社アーク情報システム
ARK Information Systems Co., Ltd.

In reinforcing bar works, prevention of misalignment is an important issue. There are rolling marks for identification on rebar in Japan, but it is small and hard to see, marks are different depending on the manufacturer, so human errors may occur. Therefore, we conducted experiments to classify reinforcing bar images by convolution neural networks (CNNs). In addition, we examined inference results via Gradient-weighted Class Activation Mapping (Grad-CAM). As a result, classification of reinforcing bar was possible, and it was confirmed that the system focused on the roll mark.

1. はじめに

鉄筋コンクリート構造物の工事では，鉄筋の種類や配置等についての検査(配筋検査)が行われる．配筋とその検査に誤りがあった場合，建物の耐久性・強度に問題が生じる危険性がある．そのため，正確な検査が必要とされるが，人間による配筋検査は検査品質にばらつきが生じる上，多くの時間と手間を要する．

日本建設業連合会等によって，配筋ミスの防止に決め手となる鉄筋識別方法が検討され，課題が整理されている[日建連14]．鉄筋識別の手段として，鉄筋表面のロールマークを目視する方法があるが，マークが小さくて見えにくい事，マークの間隔が広くて探しづらい事，メーカーによってマークが異なる事などが問題視されている．そこで本検討では，配筋検査における品質確保や検査の時間短縮を目的とし，畳込みニューラルネットワーク(CNN)によるロールマークの自動認識を試みた．尚、この検討には汎用 DeepLearning ソフトウェア ARK-AI を用いた．

2. 問題設定

使用した鉄筋は図 1 の 16 種(メーカー4 社，径 4 種)である．鋼種はいずれも SD345 とした．ロールマークの認識問題を，メーカー認識問題と径認識問題に分けて検討した．メーカー認識問題では，鉄筋画像を 4 種のメーカー(朝日工業(株)，共英製鋼(株)，JFE 条鋼(株)，東京鐵鋼(株))に分類した．径認識問題では，メーカーごとにそれぞれ，4 種の径(D16，D19，D22，D25)に分類した．

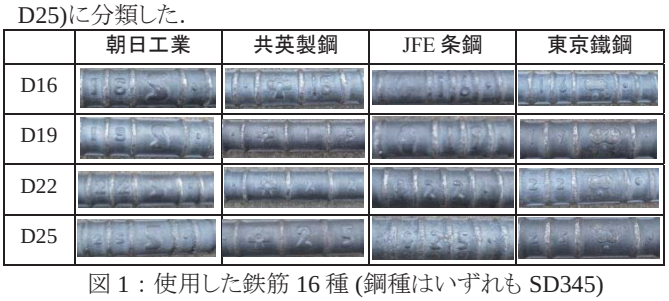


図 1：使用した鉄筋 16 種 (鋼種はいずれも SD345)

3. 入力画像

用意した鉄筋画像の例を図 2 に，画像点数を表 1 に示す．

連絡先：市川享祐，株式会社アーク情報システム，東京都千代田区五番町 4-2 東プレビル，03-3234-9232，03-3234-9403，ichikawa.kyosuke@ark-info-sys.co.jp

Traning set，Validation set，Test set の 3 種のデータセットを用意した．Traning set は学習用のセットである．このセットについては，カメラをずらしながら連続撮影することで，可能な限り多くの画像を用意した(そのため，同様な背景の画像が複数含まれる)．Validation set や Test set は，学習させていない画像を認識できるかどうかをテストするためのものである．特に Validation set は，学習のどの反復段階で得られたパラメータを採用するかの指標に用いた(原則として，Validation set に対する損失が最も低い段階でのパラメータを採用した)．Test set は採用したパラメータに対する精度評価に用いた．Traning set，Validation set，Test set のいずれの画像も重複はしていない．尚，画像は 256×192 ピクセルのカラー画像とした．



図 2：使用した鉄筋画像例

表 1：鉄筋画像点数

メーカー	径	画像点数		
		Training	Validation	Test
朝日工業	D16	1,294	20	20
	D19	1,250	20	20
	D22	1,226	20	20
	D25	1,291	20	20
共英製鋼	D16	1,262	20	20
	D19	1,208	20	20
	D22	1,254	20	20
	D25	1,158	20	20
JFE 条鋼	D16	1,263	20	20
	D19	1,236	20	20
	D22	1,165	20	20
	D25	1,297	20	20
東京鐵鋼	D16	1,269	20	20
	D19	1,102	20	20
	D22	1,248	20	20
	D25	996	20	20
計		19,519	320	320

4. CNN の設定

本検討で用いた CNN の構成を図 3 に示す. これは, VGG19[Simonyan 14]をベースとした. その他の設定を表 2 に示す. 尚, ドロップアウトは全結合層にのみ適用した.

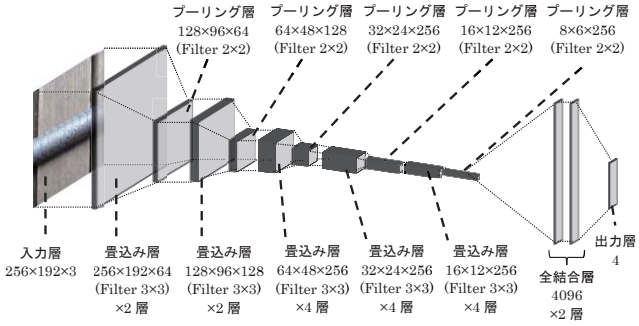


図 3：CNN の構成

表 2：ハイパーパラメータ

エポック数	500
ミニバッチサイズ	128
ドロップアウト率	75%
重み行列初期値(乱数)の正規分布標準偏差	0.05
活性化関数	ReLU (出力層は Softmax)
損失関数	Cross-entropy
最適化手法	Adam
初期学習率	0.001

5. Grad-CAM の導入と調整

CNN の中間層の出力が, 出力層の出力に与える影響を可視化する手法として, Saliency map[Simonyan 13], Grad-CAM[Selvaraju 16]など, 複数提案されている. 本検討では Grad-CAM をベースに, max-pooling 層の出力が出力層の出力に与える影響を可視化した. あるクラスcに対応するヒートマップL^cは式(1)によって得られる.

$$\begin{cases} \alpha_k^c \coloneqq \frac{1}{Z}\sum_i\sum_j \frac{\partial y^c}{\partial A_{i,j}^k}, \\ L^c = ReLU\left(\sum_k \alpha_k^c A^k\right). \end{cases} \tag{1}$$

ここで, Aは特徴マップ, Zは特徴マップのサイズ, yは出力層の出力ベクトルであり, 添字のi, jは行列番号, kは特徴マップの番号を表す. すなわち, 特徴マップに対する出力y^cの変化率を整理して可視化する.

ただし, 本検討では第一式に ReLU を適用することで, 負の変化率の影響を除外した. すなわち, 次の式(2)を用いた.

$$\begin{cases} \alpha_k^c \coloneqq \frac{1}{Z}\sum_i\sum_j ReLU\left(\frac{\partial y^c}{\partial A_{i,j}^k}\right), \\ L^c = ReLU\left(\sum_k \alpha_k^c A^k\right). \end{cases} \tag{2}$$

これにより, 特徴マップ上の局所的な正の変化率が, 他の箇所の負の変化率によって相殺されることを防いだ. あるいは, 本検討では用いていないが, CAM[Zhou 16]のアプローチを利用した式(3)による方法もある(ただし, $\circ$は行列成分ごとの積である).

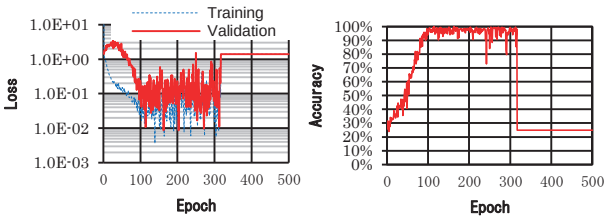
$$L^c = ReLU\left(\sum_k \frac{\partial y^c}{\partial A^k} \circ A^k\right) \tag{3}$$

6. 検証結果

6.1 メーカー認識問題の結果

メーカー認識問題の学習結果を図 4 に示す. Validation set に対する正答率は 114 エポックで 100%となった. Validation set に対する損失が最小となった 203 エポックのパラメータを採用した(このときの Validation set に対する正答率は 99.7%).

採用したパラメータで Test set のメーカー認識を行った. 結果は表 3 のとおりであり, 98.1%の正答率が得られた. 認識の正答例を図 5 に示す. 上段は入力画像, 下段は Grad-CAM によって得られた(出力クラスに対する)ヒートマップである. Grad-CAM は出力層に最も近い max-pooling 層を対象としている. 基本的にメーカーのマークに着目していることが分かる. 径を表す数字もメーカーによって形が異なるためか, 数字に着目する様子も見られた. また, 誤答例を図 6 に示す.



(a) 損失推移　　(b) Validation set 正答率推移

図 4：メーカー認識問題の学習結果

表 3：メーカー認識問題の結果(Test set)

画像点数	正答数	正答率
320	314	98.1%

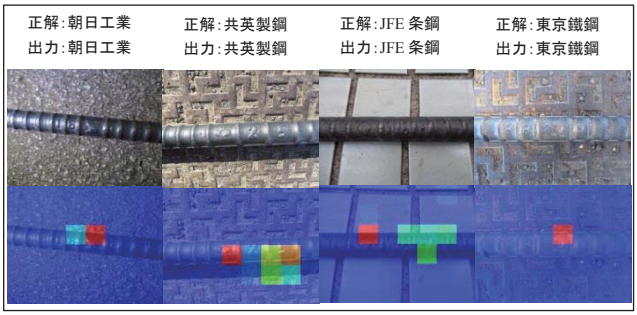


図 5：メーカー認識問題の正答画像例

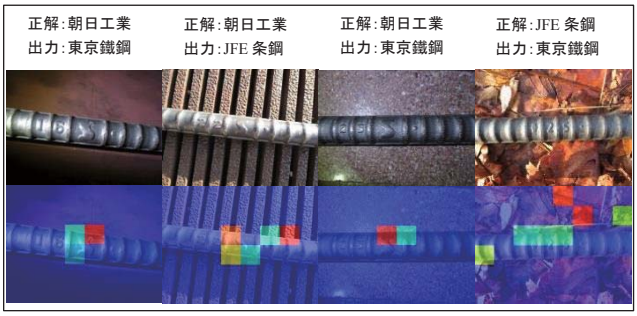


図 6：メーカー認識問題の誤答画像例

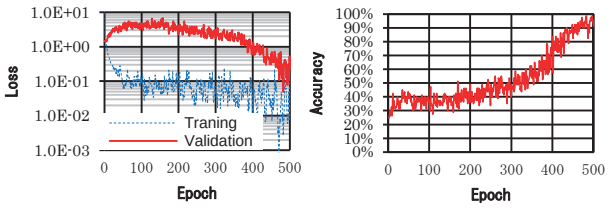
6.2 径認識問題の結果

径認識問題では，メーカーごとに径の分類を行った．基本的には Validation set に対する損失が最小となった時点でのパラメータを採用したが，東京鐵鋼については 2 エポックから損失が下がらなくなったため，500 エポックでのパラメータを採用した(2 エポックでは，Training set に対する損失も下がり切っていないため例外とした)．Test set に対する径認識結果を表 4 に示す．共英製鋼については 90%以上の正答率が得られたが，その他のメーカーについては 80%を下回った．

表 4：径認識問題の結果(Test set)

メーカー	画像点数	正当数	正答率
朝日工業	80	50	62.5%
共英製鋼	80	77	96.3%
JFE 条鋼	80	61	76.3%
東京鐵鋼	80	25	31.3%

共英製鋼の学習結果を図 7 に示す．Validation set に対する損失が最小となった 482 エポックのパラメータを採用した(このときの Validation set に対する正答率は 98.8%)．採用したパラメータで Test set のメーカー認識を行った．正答率は表 4 の通り 96.3%である．認識の正答例を図 8 に示す．上段は入力画像，下段は Grad-CAM によって得られた(出力クラスに対する)ヒートマップである．鉄筋には着目しているが，径の数字だけでなく他の箇所も見ていることが分かる．



(a) 損失推移　　(b) Validation set 正答率推移

図 7：共英製鋼に対する径認識問題の学習結果

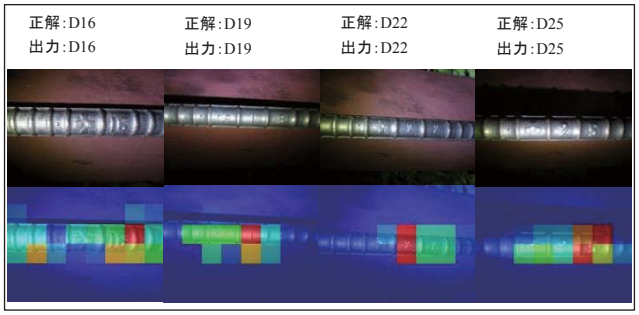


図 8：共英製鋼に対する径認識問題の正答画像例

7. Grad-CAM 比較

最後に Grad-CAM について，式(1)，式(2)，式(3)のヒートマップの例を図 9 に示しておく．これは，メーカー認識問題において，CNN の各 max-pooling 層に対して Grad-CAM を適用した例である．4 つめの pooling 層を見ると，式(1)ではヒートマップがなくなっているが，式(2)，(3)では表示されている．

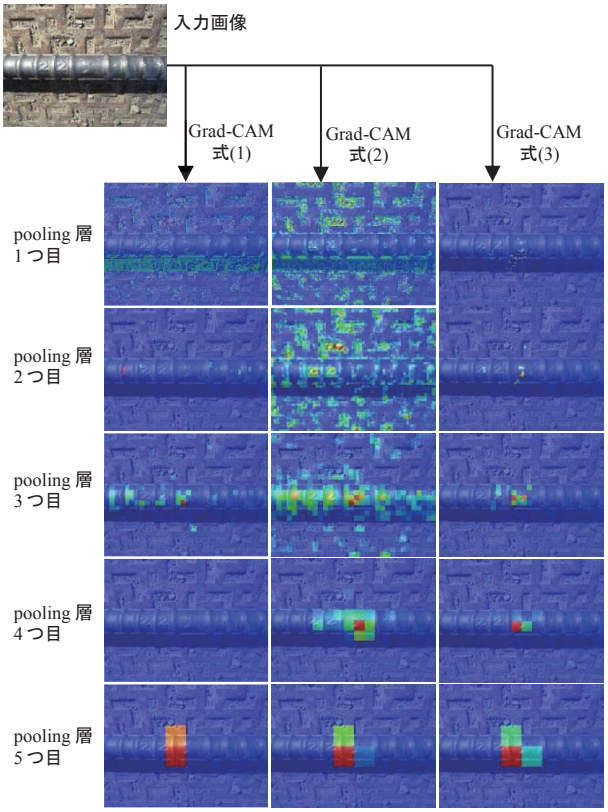


図 9：Grad-CAM の各調整の違い

8. まとめ

以上の検討により，CNN による鉄筋ロールマークの自動認識がある程度可能であることが分かった．ただし，径認識問題については精度が比較的悪く，教師データのバリエーションを増やす等の対策が必要である．今後の課題としては，組みあがった鉄筋への対応，鋼種・鉄筋本数・ピッチなどの認識がある．

謝辞

鉄筋を提供して頂いた朝日工業(株)，共英製鋼(株)，JFE 条鋼(株)，東京鐵鋼(株)に感謝の意を表す．また，本検討は日本建築学会の「建築構造の技術革新と人工知能特別研究委員会」で実施したものであり，その活動の中で委員会メンバーに参考となる意見を多くいただいた．ここに感謝の意を表する．

参考文献

[日建連 14] 一般社団法人日本建設業連合会 建築生産委員会: 鉄筋識別方法の改善について－カラー識別マーキングとロールマークの現状と今後の課題－, 2014.

[Simonyan 14] Simonyan, K. and Zisserman, A.: Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv:1409.1556*, 2014.

[Simonyan 13] Simonyan, K., et al.: Deep inside convolutional networks: Visualising image classification models and saliency maps, *arXiv preprint arXiv:1312.6034*, 2013.

[Selvaraju 16] Selvaraju, Ramprasaath R., et al.: Grad-CAM: Why did you say that? Visual Explanations from Deep Networks via Gradient-based Localization, *arXiv preprint arXiv:1610.02391*, 2016.

[Zhou 16] Zhou, B., et al.: Learning Deep Features for Discriminative Localization, In *CVPR*, 2016.

Oral presentation | Organized Session | [Organized Session] OS-18

[3K2-OS-18b] [Organized Session] OS-18

Thu. Jun 7, 2018 3:50 PM - 5:10 PM Room K (3F Azisai Mokuren)

[3K2-OS-18b-01] Prototype and implementation of privacy-sensitive human flow measurement system using depth sensor

○Takanobu Otsuka[1], Tomohiro Nishida[1], Daichi Shibata[1], Takayuki Ito[1] （1. Nagoya Institute of Technology）

3:50 PM - 4:10 PM

[3K2-OS-18b-02] Damage Detection of Wooden Structural Members Using Piezoelectric Sensor and Autoencoder for Structural Health Monitoring

○Natsuhiko Sakiyama[1], Ayumu Ushigome[1], Sakuya Kishi[1], Akihiro Kishi[1], Yoichiro Hashizume[1], Takashi Nakajima[1], Takumi Ito[1] （1. Tokyo University of Science）

4:10 PM - 4:30 PM

[3K2-OS-18b-03] Charge Control of Regenerative Power for Energy-Saving Railway Systems

○Yasuhiro Yoshida[1], Sachiyo Arai[1] （1. Chiba University）

4:30 PM - 4:50 PM

[3K2-OS-18b-04] Microscopic Simulation of Coupled Traffic and Electric Grids

○Hideaki Uchida[1], Hideki Fujii[1], Shinobu Yoshimura[1] （1. The University of Tokyo）

4:50 PM - 5:10 PM

©The Japanese Society for Artificial Intelligence

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

プライバシに配慮した深度センサ式人流計測システムの試作と実装

Prototype and implementation of privacy-sensitive human flow measurement system using depth sensor

大塚孝信 *1*2 Takanobu Otsuka　西田智裕 *2 Tomohiro Nishida　柴田大地 *1 Daichi Shibata　伊藤孝行 *1*2 Takayuki Ito

*1名古屋工業大学大学院 情報工学専攻
Department of Computer Science, Nagoya Institute of Technology

*2名古屋工業大学 コレクティブインテリジェンス研究所
Center for Collective Intelligence, Nagoya Institute of Technology

In urban design, design considering pedestrian flow lines is important. Large scale redevelopment around Nagoya station is planned due to opening of Linear Central Shinkansen 's Nagoya Station. Along with redevelopment, it is necessary to design a flow line that is easy to use for users by considering flow lines around the station. In this research, by collecting actual human flows at major stations in Nagoya city and modeling it, it is utilized for simulation aimed at redevelopment of cities.

1. はじめに

都市デザインにおいては, 歩行者の動線を考慮した設計が重要である. 我々の住む愛知県名古屋市においては, 2017 年に開業を予定しているリニア中央新幹線の名古屋駅の開発に伴い, 名古屋駅周辺の大規模な再開発が予定されている. 再開発に伴い, 駅周辺の動線を考慮することで, 利用者にとって使いやすい動線設計を行う必要がある. 利用者にとって使いやすい動線を設計するためには, 実際の人間行動をモデル化し, 出入口や構造物の位置を最適な配置をシミュレーションすることが重要である. しかし, 歩行行動を単純にモデル化するだけでは現実的なシミュレーションとは言い難い. そのため, 実際の人流（人の流れ）を収集し, 多様な歩行行動のモデルを生成することで, 現実的なシミュレーションが可能となる.

人流データの収集について，歩行している個々人からの同意を取得することが難しい. 一般的には, 監視カメラ等から取得した動画データを画像認識することで人流を計測することが可能である. しかし, 動画データを用いる以上, 個々人の肖像権の問題が発生する. 特に, 自らの所有地ではなく公共の空間においては, 個人情報保護の観点から, 被験者には事前告知や同意書が必要となることが多く, 現実的に不可能である. そのため我々は, 個々人からの同意を取ることが困難な状況を想定し, 深度センサを用いて個人情報を収集することなしに人流データを収集する方法を用いることで, 実際の人間行動データに基づく行動モデルを作成し, シミュレータ上の歩行者行動則に反映することで, 駅構内や歩道, および公園などの空間における歩行者行動シミュレートのための人流計測手法を実装し, 実際の駅構内の人流を計測することを可能とした. さらに, 電源確保できない場所への設置を前提とし, モバイルバッテリを利用することで 19 時間以上計測可能な自律型計測装置を実現した.

本論文の構成を示す. まずはじめに, 2 章にて人流計測における関連研究を示す. 次に, 3 章にて本研究の特徴であるプライバシに配慮した人流計測手法について述べる, 4 章では, 深度データから取得したセンサ値によるデータ化について述べ, 5 章にて実験設定と実験結果について述べる. 最後に 6 章にてまとめと今後の課題を示す.

連絡先: 大塚孝信，名古屋工業大学，愛知県名古屋市昭和区御器所町，otsuka.takanobu@nitech.ac.jp

2. 関連研究

人流計測手法には多くの方法があり, 広く研究されている. 我々と同じく深度センサを用いて人流を計測する研究 [山下 09] があるが, 深度センサの情報をリアルタイムに処理し, ネットワーク経由で送信しているため高性能な計算機が必要であり, AC100V 電源が供給可能な場所にしか設置ができない問題がある.

また, ステレオカメラを用いて人流を計測する手法 [柴田 13][大西 10] については, 視差情報を活用した処理にて人流を計測することが可能であるが, 撮影エリア内に重なって存在する人間の認識が困難であり, かつ動画での撮影のため, 個人情報保護の観点から問題がある. さらに, 超音波センサを利用して通過人数をカウントする研究 [味呑 11] もあるが, センサエリアが狭く, 大規模な人流測定を行うには適さない. その他にも, RFID タグを用いた研究 [山下 11] や, WiFi の mac アドレスを利用した研究 [森本 15] による人流計測も存在する. しかし, RFID タグ方式については, 被験者に対して RFID を配布する必要がある上に, 専用の RFID タグを常に身につけて貰う必要が生じる. また, WiFi の mac アドレスを利用した方法については, 事前に被験者の持つデバイスの mac アドレスを入手することが必要である. Wifi の mac アドレスや RFID については, 個人の氏名等と照合可能である場合は個人情報にあたるため, 被験者の同意が必要となる. そのため, 公共空間を代表とする実験環境において, 大規模な人流計測を行うことが困難である.

我々は, 深度センサを用い, 個人情報を取得することなく人流計測可能なシステムを実装した. さらに, 電源確保できない場所への設置を前提とし, モバイルバッテリを利用することで連続 19 時間以上計測可能な自律型計測装置を実現した. この結果により, 屋内外の大規模な空間において, 設置自由度の高い人流計測が可能となる.

3. 個人情報保護に配慮した大規模人流計測

3.1 人流計測における個人情報

個人情報とは, 個人が特定可能な符号や画像等である. 日本国の外郭団体である個人情報保護委員会の発行した資料 [個人情報保護委員会 17] の定義では,

”当該情報に含まれる氏名, 生年月日その他の記述等（文書, 図画若しくは電磁的記録（電磁的方式（電子的方式, 磁気的方式その他人の知覚によっては認識することができない方式をいう. 次項第 2 号において同じ. ）で作られる記録をいう. 第 18 条第 2 項において同じ. ）に記載され, 若しくは記録され, 又は音声, 動作その他の方法を用いて表された一切の事項（個人識別符号を除く. ）をいう. 以下同じ. ）により特定の個人を識別することができるもの（他の情報と容易に照合することができ, それにより特定の個人を識別することができることとなるものを含む. ）”

とある. そのため, mac アドレスや RFID などの, 個別の ID と個人の氏名などが照合可能な場合についても個人情報に該当する. 現実空間における人流計測の方法として, ビデオカメラに代表されるイメージセンサを用いた方法が広く使われている. イメージセンサを用いた人流計測については, 既存のネットワークカメラ等を用いて収集した動画データにより物体認識を行い, 人の流れを計測することで, 人流計測が可能である. そのため, 既に防犯用としてネットワークカメラが設置されている駅構内や施設, 公園などでは, 既存設備を利用できるため, 広く活用されている. しかし, イメージセンサを用いた方式では, 収集した生データ内に個々人を特定可能な情報が多く含まれているため, 個人情報保護の観点においては広く収集することは困難である. 特に, カメラ画像を利用した人流追跡実験については, 2014 年に大阪駅にて行われた実証実験が市民の要望により中止となった事例も存在するため, 完全に個人情報を判別不可能な計測手法とする必要がある.

我々は, イメージセンサ方式ではなく, 赤外線を用いた深度センサを用いることで, 個人情報を特定不可能な状態でのデータ収集を行う人流計測手法を提案することで, 愛知県名古屋市のターミナル駅構内において, 実際の人流データを収集することに成功した. 実際に使用した機材構成について以下に示す.

- 深度センサ: Intel Realsense R200
- スティック PC: Diginnos Stick DG-STK4D
- microSD カード: 64GB
- モバイルバッテリ: 26,800mAh

本システムの最大の特徴は, 外部電源供給を必要とせず, 19 時間以上の人流計測が可能な点である. 連続稼働時間を 19 時間以上とした根拠として, 駅構内への設置は, 乗降客の妨げとならないように列車の始発時間帯に設置することが求められる. 名古屋地区においては, 5 時台が始発時間帯となるため, 設置後の 18 時間後は 23 時となり, 朝と夕方の通勤時間帯の混雑した時間の両方の人流データを収集することが必要である. 以上の理由により 19 時間以上の連続稼働可能時間を設定した. そのため, 本研究にて用いるスティック PC は省電力プロセッサ搭載モデルを選定すると共に, WiFi や不要なサービスの停止についても行っている.

また, 深度センサについては Intel 社製の RealSense R200 センサを選定している（以下 R200), R200 の選定理由として, USB によるパスパワー駆動が可能かつ小型な点が挙げられる. 類似のセンサとしては, Microsoft 社の Kinect や LinX 社の Xtion が挙げられるが, Kinect センサは外部電源が必要であり, Xtion についてはパスパワー駆動が可能であるが, R200 と比較した場合, センサ本体が比較的大型という問題点がある. さらに, Kinect と Xtion の一部モデルは製造が打ち切られており, 入手性の問題もあることから R200 を選定している. 深度センサ R200 の詳細を図 1 に示す.

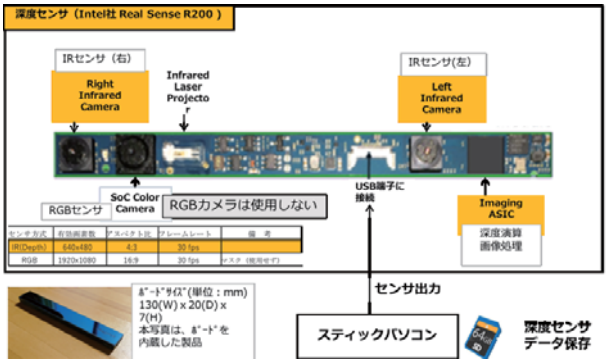


図 1: 深度センサ詳細

R200 は他の深度センサと同じく, 非可視光線である赤外線を対象物に照射し, 対象物からの反射赤外線を 2 つの赤外線イメージセンサから収集することで 640x480(VGA) の各画素点の深度情報を収集することが出来る.

本研究では, R200 との通信において, RGB カメラの情報は取得せず, 深度センサの情報のみをスティック PC が取得し, microSD カードにデータを保存している. また, R200 のカメラ部については, マスキングテープを貼付することにより, 外観からカメラ部が隠されていることを認識できるようにしている. 通信制御については Intel RealSense SDK 内のソフトウェアを改良し, PC 起動時に自動的に起動し, あらかじめ設定された収集時間に到達した時点で自動的にシャットダウンさせるソフトウェアを開発した.

3.2 個人情報に配慮したクリッピング手法の実装

深度センサは, 赤外線レーザを広範囲に照射し, 赤外線反射情報をセンサユニット上に配置された複眼の赤外線イメージセンサにより読み取ることで, 各画素における深度（対象物までの距離）を出力する仕組みとなっている. 深度センサからの情報は, USB3.0 規格にてスティックパソコン上のデータ収録アプリケーションにより SD カードに時系列データとして保存する. また, 深度情報を広範囲に測定する場合, 対象となる測定物の外形がおおまかに把握可能である. 個人情報を特定するまでの情報は得られないと考えるが, 体型の情報が入手できるという問題がある. そのため我々は, 深度センサからの距離情報を画素ごとにクリッピングすることで, 全身の深度データではなく, 肩から上のみの深度データのみ収集する方式を提案することで, 個人情報を完全に秘匿した状態での人流計測が可能な方法を提案している. 深度センサ情報のクリッピングイメージを図 2 に示す.

深度センサ情報のクリッピング処理は, VGA サイズの深度データの Y 軸方向毎に取得可能な範囲を設定することで, 全身の輪郭を収集不可能な設定としており, 深度センサから取得されるデータ列を接続された PC 内にて処理し, 処理後のデータを microSD に保存している.

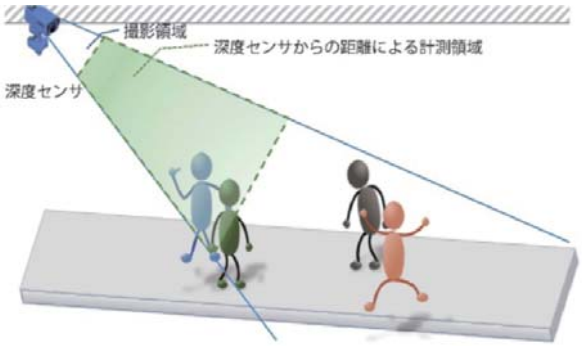


図 2: 深度センサ情報のクリッピングイメージ

4. 深度センサ情報の認識と行動モデル構築

4.1 深度センサ情報

深度データの情報は, VGA サイズのデータ列を 30fps にて収集している. 深度情報は各画素点におけるグレイスケールの濃淡として表示が可能である. 本研究では, コンピュータビジョン向けのライブラリである OpenCV を用いて人間の行動を認識し, 行動パスとして表現することで, 個々人の動きをモデル化する. センサ情報取得から行動軌跡への変換の概要を図 3 に示す. 本図においては, 参考のため RGB カメラにより取得された画像についても参考情報として表示している.

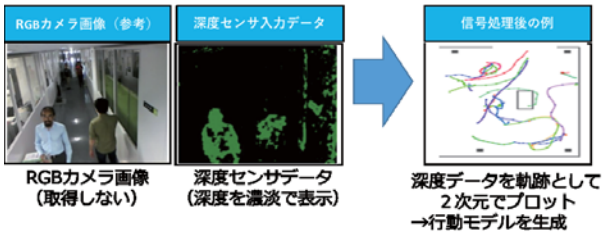


図 3: データ処理の流れ

以上のように, 深度センサ情報を用いて 2 次元平面上に軌跡をプロットすることで, 個々人の歩行速度や対向した際の動線を表現することが出来る.

4.2 OpenCV を用いた人体認識と座標変換手法

本節では, 実際に取得した深度データからの座標変換方法について述べる. 深度センサは, 駅構内の案内看板等に設置されるため, 上方から約 50 度の角度にて深度データを収集する. そのため, センサ取得範囲の中で複数の人間が重なり合った場合には, 同一の深度情報が取得されることとなる. つまり, 前後に取得された深度情報から, 個人の動線を特定することが必要となる. 実際に駅構内で得られた深度情報を OpenCV によって認識させた例を図 4 に示す.

本図のように, 対向する人間がすれ違う際には, センサに対して手前側の深度データ情報のみが取得可能である.

本研究では, 連続するデータに対してすれ違いの際の動線を分離するために, 空間拡張法 (Region Growing) を用いている. 空間拡張法は, 空間的に連続した領域を拡張することで, 目標とする輪郭を時系列的に抽出する方法である. そのため, センサ範囲に存在する物体の重なりについて, 連続したデータとして入力することで, 個々人の動線を分離することが可能である. 図 5 に, 空間拡張法によって分離された各個人の動線を示す. 縦軸は各個人の連続した動線が分離された状態を示しており, 下面の XY 軸はセンサ認識範囲 (約 5m 角) を示している. センサの左右方向はセンサ中心を 0 として, センサ範囲の長手方法は 1m-5m として表現されている.

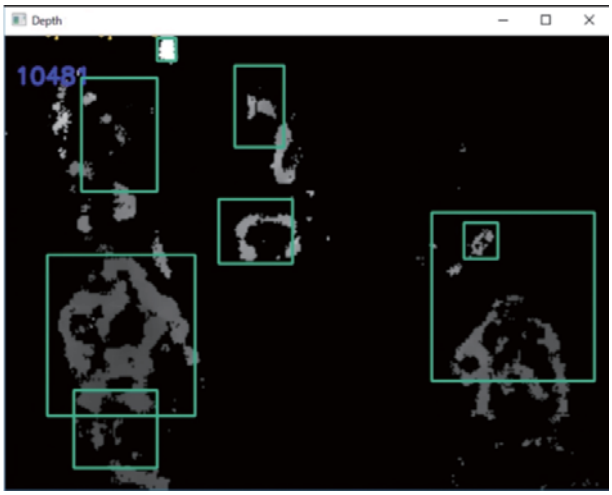


図 4: OpenCV による認識例

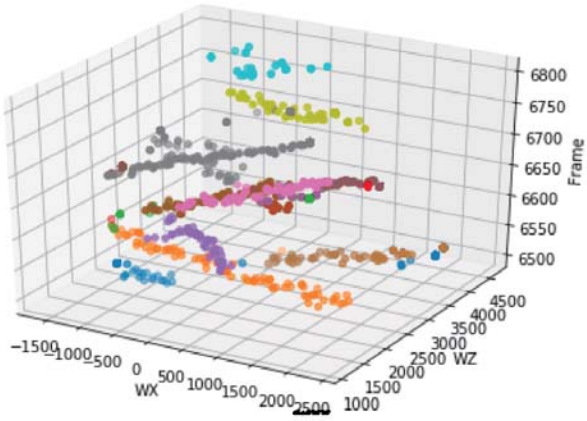


図 5: 空間拡張法による動線分離

以上により, 深度センサ情報から個々人の行動軌跡を取得している. 次章では駅構内にて実施した実験結果について述べる.

5. 評価実験

5.1 実験設定

本節では実際に機器を設置した実験設定について述べる本実験では, 愛知県名古屋市のターミナル駅に本研究で実装した深度センサ収集装置を設置し, データ収集を行った. 以下に実験期間と機器数について述べる.

- 実験期間：2017 年 11 月 3 日〜16 日の間の 6 日間
- 実験時間：午前 5 時〜午前 0 時（約 18 時間)

- 設置機器数：5 台（1 日ごとに計測場所を変更して実施）

実験に関しては, 始発時間帯である午前 5 時に機器を設置し, 終電時間後に回収した. 案内看板への設置例を図 6 に示す.



図 6: 案内看板への設置例

案内看板は, 平均して高さ 3.1m に存在することから, 被験者は装置の存在に気づくことなく行動を行っている. また, 告知事項として常時 2 名, 告知パネルを持った説明員を装置設置箇所近傍に配置することで, データ収集を希望されない被験者が存在する場合に迂回路を案内するなどの配慮を行った上で実験を実施した. 案内看板への設置には, 看板の塗装面を痛めることなく貼付が可能な両面テープを利用し, 万が一の落下時に対しても落下することのないよう, セフティワイヤーを取付けることで設置及び安全面への配慮を行っている.

5.2 実験結果

本節では実際に得られた深度データを基に, 4 章にて述べた提案手法を用いて座標変換を行っている. 本研究では, まずはじめに歩行速度の分布を収集することで, 歩行速度の異なる人間の分布を把握することとした. 歩行速度については, 座標変換を行った後, センシング範囲に入り, 範囲外に出るまでの速度を mm/s として分布をグラフ化した. 本実験結果は 2017 年 11 月 7 日に取得された 1 台の収集装置の約 1000 件のデータを利用している. 図 7 に結果を示す.

実験結果により, 平均して歩行速度 1000mm/s 近辺の割合が高いことがわかった. 分布グラフにおける 4000mm/s が歩行者が走った際の速度限界と考えられるため, 4000mm/s 以上のデータについてはノイズデータと考える. 本実験では, 平日だけではなく, 休日のデータについても収集しているため平日の混雑時と休日の人流の差異についても表現できる. また, 本実験においては 11 月の特定日のみ実験を行っているが, 年末年始の帰省ラッシュ時やクリスマスや鉄道機関の運行停止発生時の人流情報を収集することにより, さまざまな条件下での人流モデルを構築することも可能である. 本手法により, 実際の人流情報を収集することが可能であることを示した.

6. 今後の課題

本論文では, プライバシに配慮した人流計測装置を試作するとともに, 実際の駅構内に設置することで人流データを収集可能なことを示した. また, 座標変換を行うことで, 個々人の歩行軌跡を表現することが出来るため, 障害物や他人と対向した

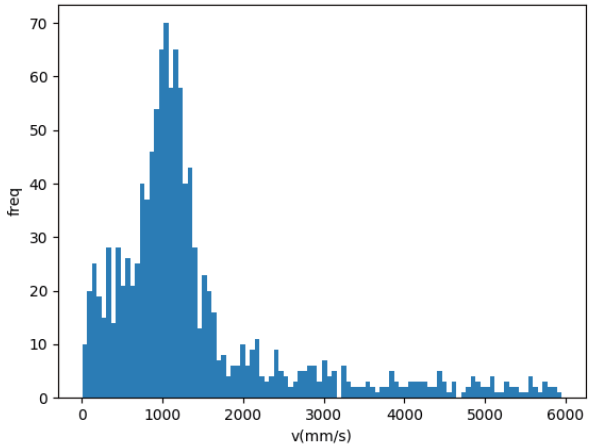


図 7: 歩行速度の分布グラフ

場合の行動パターンをモデル化することが出来る. 今後は, 歩行速度の分布だけではなく, 軌跡データをパターンとして認識させることで, 都市計画のシミュレーション等に利用していく.

参考文献

[山下 09] 山下倫央, 副田俊介, and 野田五十樹. ”人流計測による避難誘導効果の実証的検証.” 研究報告ヒューマンコンピュータインタラクション (HCI) 2009.25 (2009): 1-8.

[柴田 13] 柴田雅聡, et al. ”差分ステレオを用いた人流計測手法の屋外実環境における実証実験.” 日本機械学会論文集 C 編 79.800 (2013): 1036-1045.

[大西 10] 大西正輝, and 依田育士. ”大型複合施設における長期間にわたる人流比較と可視化手法.” 電子情報通信学会論文誌 D 93.4 (2010): 486-493.

[味呑 11] 味呑翔平, et al. ”超音波センサーによる人流観測システムの開発と評価 (インターネット計測, ネットワーク監視, ネットワークセキュリティ, トラヒック理論及び一般).” 電子情報通信学会技術研究報告. IA, インターネットアーキテクチャ 111.347 (2011): 13-18.

[山下 11] 山下倫央, et al. ”センサデータマイニングを活用した安全安心な避難誘導への取組み.” 電子情報通信学会誌 94.4 (2011): 294-298.

[森本 15] 森本哲郎, et al. ”Wi-fi パケットセンサを用いた人流解析と可視化.” データ工学と情報マネジメントに関するフォーラム (DEIM2015) 論文集 (2015).

[個人情報保護委員会 17] 個人情報の保護に関する法律についてのガイドライン, 平成 29 年 3 月版, 個人情報保護委員会, https://www.ppc.go.jp/files/pdf/guidelines01.pdf (2018.3.8 閲覧)

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

構造ヘルスモニタリングのための圧電センサと自己符号化器による耐震木造壁の損傷検知

Damage Detection of Wooden Structural Members Using Piezoelectric Sensor and Autoencoder for Structural Health Monitoring

崎山 夏彦[*1] 牛米 歩[*1] 岸 朔矢[*2] 岸 映裕[*2] 橋爪 洋一郎[*2] 中嶋 宇史[*2, 3] 伊藤 拓海[*1]
Natsuhiko Sakiyama Ayumu Ushigome Sakuya Kishi Akihiro Kishi Yoichiro Hashizume Takashi Nakajima Takumi Ito

[*1] 東京理科大学工学部建築学科
Department of Architecture, Faculty of Engineering, Tokyo University of Science

[*2] 東京理科大学理学部応用物理学科
Department of Applied Physics, Faculty of Science, Tokyo University of Science

[*3] JST さきがけ
JST PRESTO

We tried to identify the state of members injured by natural disasters by machine learning using the vibration response waveform of a piezoelectric sensor attached a wooden element. We destroyed step by step a wooden wall connected to columns. In each destruction stage, the vibrational characteristic is measured by a piezoelectric sensor. The oscillating source to obtain data models vibrations of natural vibration coming from a wind and so on. We detected the injury of a member by using autoencoder which learned only the waveform of the element which is not injured.

1. はじめに

近年，耐震技術の向上により，巨大地震による甚大な建物被害は減少してきている．しかし，東日本大震災や熊本地震などでの経験を踏まえ，震災建物の立入・再使用の可否の判定や，建物の復旧のため，構造学上の損傷度に基づく迅速かつ適正な判定方法の確立の重要性が改めて認識されている．現在，二次被害の防止として応急危険度判定，建物の継続使用・復旧可否の診断として被災度区分判定が整備・運用されているが，これらは緊急時に膨大な建物の迅速な判定のために簡便化されており，判定基準の工学的裏付けや，診断結果の精度について課題が指摘されている．また，これらの診断・判定は，建築構造の専門家の現地調査によるため，人員不足，余震に対する安全面，調査長期化による復旧遅れなどの課題がある．

そこで，近年はセンサや無線技術の小型化・低コスト化，人工知能関連の技術革新により，建物の健全性を自動診断する次世代の「構造ヘルスモニタリング」が注目されている．この中で，加速度計による診断は高層建築物などで実用化が進んでいるが，層レベルの損傷予測にとどまっており，部材レベルの損傷の診断や定量化には至っていない．また，木材の損傷診断手法として，貫入法・超音波探傷法があるが，コストと使用者のスキルに依存するといった課題がある．

そこで本研究では，部材レベルの損傷検知のための計測法と解析法の開発を試みる．具体的には，圧電素子により部材の振動特性を計測し，振動波形データから部材の損傷度の検知と評価を試みるものである．

本稿では，建築構造用の木造耐震壁の水平載荷試験を行い，各レベルの損傷を与え，生活・交通振動等に相当する微弱な振動を与えて，その振動波形データに対して自己符号化器を用いた損傷度の検知を試みる．自己符号化器を使用することで，汎用性のある検知システムの開発を目的とし，各種構造形式や種別，部材・部位への適用も期待される．

2. 実験概要

本稿では，構造用木造耐震壁の損傷検知を対象としている．そこで，地震による各レベルの損傷を与える目的で，静的繰返し載荷試験を行う．

図 1, 3 にセットアップ図と載荷計画を示す．厚物合板（板厚 24mm）を 2 枚用い，載荷用の鉄骨剛柱（両端ピン）を挟みこみ，対角線方向 4 か所を高力ボルトで締結する．これにより，木壁には対角線方向に圧縮・引張が生じる．

図 2 の層間変形角で載荷を制御し，現行の被災度区分判定で小破，中破，大破に相当する振幅とする．各振幅の最大変形後に除荷し，図 1 に示す A の位置に小型の振動器で振動を 30

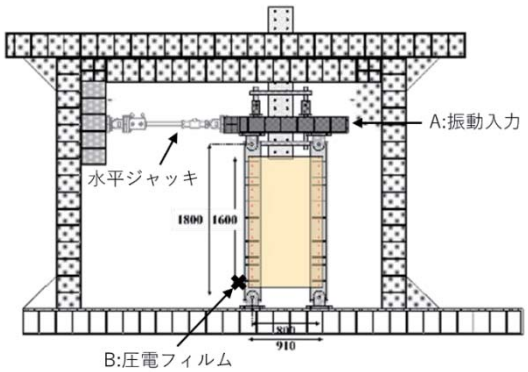


図1. セットアップ図

連絡先：崎山 夏彦，東京理科大学工学部建築学科伊藤拓海研究室所属，東京都葛飾区新宿 6-3-1，4114050@ed.tus.ac.jp

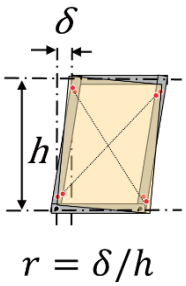


図 2.層間変形角

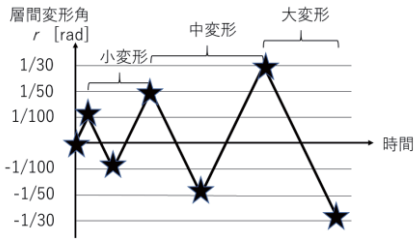


図 3. 載荷計画
★において振動を検出する.

秒与える．なお，振動器は，交通振動や生活振動，風などを想定し，規則的な振幅の振動を設定した．

PVDF 圧電フィルムは試験体の力学特性に基づき，弾性部位の図 1 の B の位置に貼付した（サンプリングは 0.001 秒）．小型振動器による振動は，木壁を伝搬した後に圧電フィルムで検出する．

3. 解析的検討

3.1 解析概要

実験前のいわゆる未損傷の木壁の振動データを用いて自己符号化器に学習させ，得られた自己符号化器を用いて，損傷を与えた木壁の損傷度の検知を試みる．

3.2 学習・検証データ

1 回の計測から得られた 30 秒のデータから，長さ 0.06 秒の一続きのデータを切り出し 1 つの学習・検証データとする．図 4 にデータの一例を示す．学習時には未損傷の木壁のデータのみを，検証には全ての損傷度のデータを用いた．

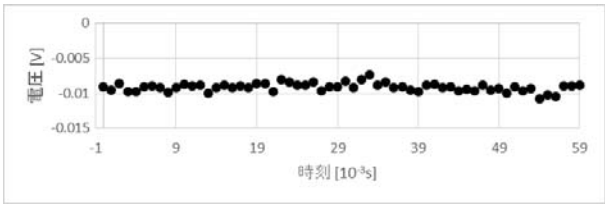


図 4. 学習・検証に用いるデータの一例

3.3 自己符号化器

自己符号化器を用いて学習データの教師なし学習を行う．自己符号化器は入力層，隠れ層，出力層の三層からなるニューラルネットワークの一種である．本研究で用いる構成を図 5 に示す．入力層の値と出力層の値の差の二乗平均を誤差として定義する．この誤差は学習データの再現性の程度を示す．未損傷のデータのみを学習データとすることで，誤差が大きいほど未損傷の場合に比べて振動特性が変化していることを意味する．

3.4 解析結果

図6に検証データの誤差を示す．未損傷の場合に比べ，損傷時のほうが誤差は大きい．このことから，振動の伝搬特性について，人間では識別し得ない振動についても，機械的に損傷の有無を検知可能であると考えられる．ただし，損傷の程度については，本研究では明確に識別できなかった．損傷度合いの定量的な識別は今後の課題となる．

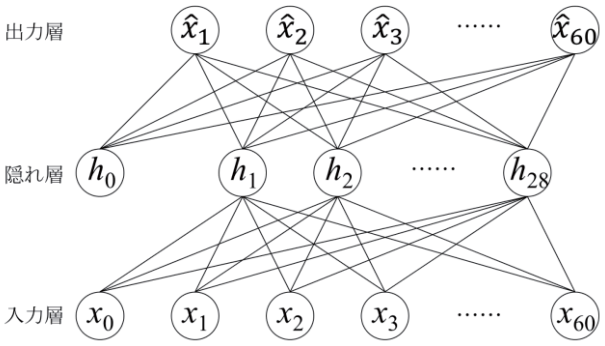


図 5.自己符号化器の構成

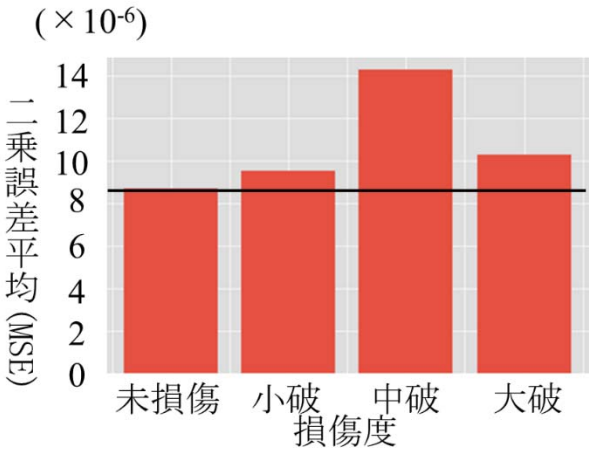


図 6.未損傷部材の振動に対する各損傷度の
自己符号化器における入出力の誤差

4. まとめ

本稿で得られた知見を以下に示す．

- 自己符号化器と圧電フィルムを用いて，損傷を受ける前のデータを学習しておきさえすれば，部材レベルでの損傷の有無を検知できることを示せた．
- センサを直接取り付けられない部材でも，部材の振動伝搬特性の変化を利用して，損傷の有無を検知できる．

5. 謝辞

本稿の実験は，本学工学部建築学科の中家優太さん，米澤泰斗さん，作間景さんにお手伝いをいただきました．また，本研究は一般財団法人大成学術財団より助成を得て実施されました．ここに記して謝意を表します．

参考文献

[国土交通省 2011] 国土交通省: 多世代利用住宅の維持管理・流通を支える構造ヘルスモニタリング技術の利用ガイドライン, 国土交通省 , 2011.

[白石 2017] 白石 理人, 森井 雄史, 岡田 敬一: 高層建物の振動台実験へのモニタリング技術の適用事例, 2017 年度日本建築学会大会（中国）構造部門（鋼構造）パネルディスカッション資料, 2017.

[国土交通省監修 2015] 日本建築防災学会: 再使用の可能性を判定し，復旧するための震災建築物の被災度区分判定基準および復旧技術指針 木造建築物，日本建築防災協会, 2016.

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

鉄道システムの省エネルギー実現に向けた回生電力の充放電制御

Charge Control of Regenerative Power for Energy-Saving Railway Systems

吉田 賢央[*1] 荒井 幸代[*1]
Yasuhiro Yoshida Sachiyo Arai

[*1]千葉大学大学院融合理工学府 都市環境システム
Department of Urban Environment System, Graduate School of Science and Engineering, Chiba University

Recently, utilization of regenerated power from the brake operation has drawn attention to help for energy conservation of railway systems. In this paper, we introduce reinforcement learning with actor-critic to acquire the appropriate rules that decide the amount of charge/discharge so that the fluctuation of the SOC (State of Charge) can be suppressed. In the previous researches, the control rules are hand-crafted based on human empirical heuristics that has limitations on suppressing electricity supply-demand dynamics in the railway system.

We show some empirical results of both previous research and our proposed one, and find that the generated rules via reinforcement learning show the better performance than the ones by the previous researches.

1. 本研究の背景と目的

鉄道システムにおける省エネルギー実現のために，列車減速時に発生する回生電力の有効利用が注目されている．本研究では，回生電力の有効利用法として蓄電池を導入し，その充放電制御による鉄道システム内の電力需給バランスを実現する．具体的には蓄電池の充電率を抑えた制御則の獲得を目的とする．蓄電池の充電率を一定にかつ小さく保つことができれば，廉価な蓄電池設置で済むことや電気の劣化も抑えることができる．

従来の人間の経験則に基づくルールベース制御は，鉄道システム内の電力需給ダイナミックスに対して限界がある．そこで本研究では，強化学習を適用し，蓄電池充電率の安定化を目的とした，蓄電池の充放電制御アルゴリズムを提案する．

2. 問題設定

2.1 電力需給モデル

図 1 に本研究で対象とする鉄道システム内の電力需給モデルを示す．列車，変電所，蓄電池は架線を介して電力需給する．(1) 式に鉄道システム内の電力需給バランス H[kW] を定義する．

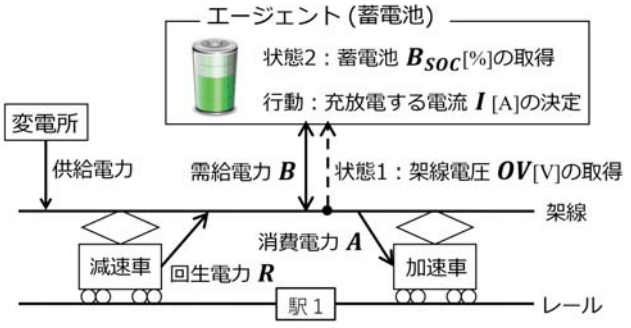


図 1: 鉄道システム内の電力需給モデル

連絡先: 吉田 賢央，千葉大学大学院融合理工学府 都市環境システム，千葉市稲毛区弥生町 1-33，aesa2088@chiba-u.jp

$$H = R - (A + B) \tag{1}$$

(1) 式を構成する需給電力は，列車の加速に必要な需要電力 A[kW]，回生ブレーキによる供給電力 R[kW]（回生電力），蓄電池の充放電電流 I[A] から計算される蓄電池の需給電力 B[kW] の三つである．なお，本研究では蓄電池がエージェントであり，充放電電流 I を制御対象とする．また，蓄電池の充電率 C[%] は蓄電池の需給電力 B によって変動する．

充電率 C の安定化には理想範囲として下限 $C_{\min}$，上限 $C_{\max}$ を設定する．充電率 C は (2) 式，(3) 式にしたがって変動し，下限 $C_{\min}$ と上限 $C_{\max}$ を超えない充放電電流 I を制御する．蓄電量と蓄電池容量を E[kWh]，$E_{\max}$ とし，制御間隔を Δt[s] とする．

$$C_t = \frac{E_t + B_t \Delta t}{E_{\max}} \cdot 100 \tag{2}$$

$$E_t = \frac{E_{\max} C_{t-1}}{100} \tag{3}$$

2.2 既存手法

蓄電池への入力情報は架線電圧 (Overhead power line Voltage)OV[V] と充電率 C である．架線電圧 OV は電力需給バランス H が正のとき上昇し，負のときに降下する性質をもつ．

既存手法では上記の性質を利用したルールベースの制御則を用い，架線電圧 OV を入力し，充放電電流 I を出力する．図 2 に既存手法で用いる制御則を示す．この制御則により電力需給バランス H の安定化を考慮している．ただし図 2 の制御則は充電率 C の安定化を考慮していないルールを設定している．

現実に電力需給バランス H と充電率 C の両面を考慮したルールは存在する．しかし，ルールベース制御では独立した多変数を入力する場合，ハンドコードですべてのルールを明確に決定することは困難である．また，ハンドコードによる制御則は人間の経験則に基づいているため，最適保証をもたない．

これまでにも充電率 C を考慮した充放電制御の研究 [Satake 14] がされてきた．文献 [Satake 14] の研究では，鉄道システム内の消費電力と回生電力が均衡すると推測した場合

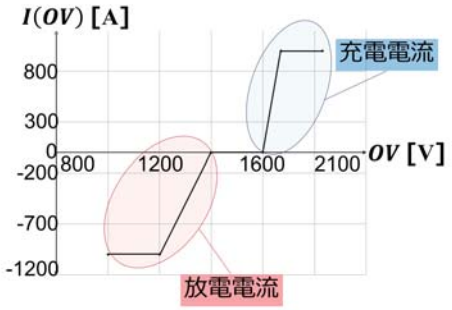


図 2: 既存手法の制御則例

Algorithm 1 Actor-Critic を用いた学習方法

状態 s，正規分布 $\mathcal{N}(\mu_s,\sigma_s)$ を初期化
$t=0$ に初期化
while $t \leq t_{\text{terminal}}$ **do**
状態 s_t を観測
Actor で正規分布 (μ_s,σ_s) に従った方策 π から
行動 a_t を出力
次状態 s_{t+1} を観測
報酬 r_{t+1} を観測
//正規分布 $\mathcal{N}(\mu_s,\sigma_s)$ の更新

$$V(s_t) \leftarrow V(s_t) + \alpha\Big(r_{t+1} + \gamma V(s_{t+1}) - V(s_t)\Big) \tag{4}$$

$$\delta_t = r_{t+1} + \gamma V_{s_{t+1}} - V_{s_t} \tag{5}$$

if $\delta_t \geq 0$ **then**

$$\mu_s \leftarrow \mu + \beta_\mu \delta_t (a_t - \mu) \tag{6}$$

end if

$$\omega_s \leftarrow \omega_s + \beta_\omega \delta_t ((a_t-\mu)^2 - \sigma^2)(1-\sigma) \tag{7}$$

$$\sigma_s = \frac{1}{1+\exp(-\omega_s)} \tag{8}$$

end while

に，充電率 C から初期値に向けて充放電する制御を取り入れている．これにより，充電率 C についても考慮した充放電制御を実現している．しかし，文献 [Satake 14] の制御則は鉄道システム内の消費電力と回生電力の均衡が極めて少ない環境において，充電率の初期値に向かう制御がとられず，充電率 C の考慮はできない．

3. 提案法

本研究では強化学習の一つである TD(0) 法 [Sutton 98] を用いて蓄電池の充放電制御則を獲得する方法を提案する．強化学習は，環境モデルが未知で，ハンドコードによるルールが記述できない場合でも報酬による試行錯誤によって最適な制御則の獲得が期待できる．

TD(0) 法はある時刻 t の状態 s_t の価値 V_{s_t} を (4) 式によって更新する．r_{t+1} は次の時刻 $t+1$ における状態 s_{t+1} への遷移時に得られる報酬値であり，エージェントは r_t が最大となる行動を選択する．なお，α,γ はそれぞれ学習率，割引率を示す．ここで，TD(0) 法で扱える状態と行動はともに離散表現であるのに対し，対象問題では，「状態入力として，架線電圧 OV と蓄電池充電率 C」，「行動出力として，蓄電池の充放電電流 I」といずれも連続量である．そこで，TD(0) 法への状態入力を離散化し，TD(0) 法で出力される離散行動ではなく，電力の制御量として連続行動を出力する．その出力法に Actor-Critic[Kimura 00] を用いる．

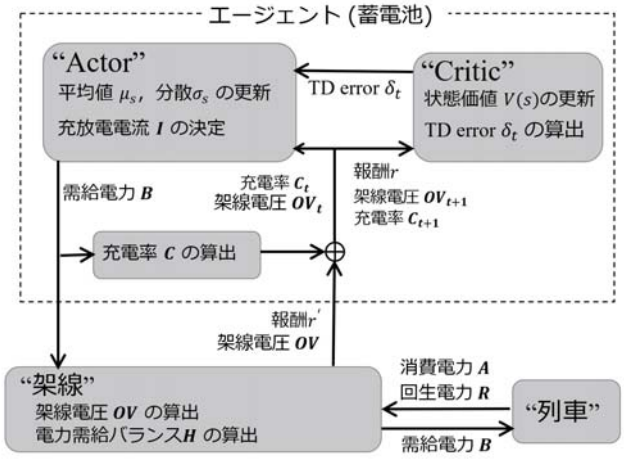


図 3: 鉄道システムにおける学習エージェントモデルの全体像

Algorithm 2 蓄電池の充放電制御

エージェントにおける状態 s，方策 $\pi(\mu_s,\sigma_s)$ を初期化
$t=0$ に初期化
while $t \leq t_{\text{terminal}}$ **do**
//充放電制御
架線電圧 OV，充電率 C を観測
方策 π にしたがって充放電電流 I を決定
(2) 式にしたがって充電率 C を更新
//価値 V，方策 π の更新
価値 $V(s)$，方策 $\pi(\mu_s,\sigma_s)$ の更新
end while

3.1 Actor-Critic を用いた離散行動の出力

Algorithm1 に Actor-Critic を用いた学習手順を示す．1 エピソードの最終ステップを t_{terminal} とする．Actor-Critic は行動選択部 Actor と状態評価部 Critic から構成されており，提案法では各状態 s での行動 a_s を正規分布 $\mathcal{N}(\mu_s,\sigma_s)$ に基づいて確率的な連続行動で出力する．μ_s と σ_s の値は TD(0) 法の更新式の差分である TD 誤差 (TD error) δ_t によって更新する．提案法では $\delta_t < 0$ のときには σ_s だけを更新し，μ_s については更新しない更新方法 [Kagaya 13] を用いる．なお，ω_s はシグモイド関数を用いて σ_s が 0 以下をとらないための内部変数，β_μ,β_ω は方策割引率である．また，学習中における局所解への収束と発散を防止するため，μ_s，σ_s の値域はそれぞれ $-4.0 \leq \mu_s \leq 4.0$，$0.0 \leq \sigma_s \leq 100.0$ とする．

3.2 蓄電池の充放電制御への適応

図 3 に鉄道システム内における電力および，エージェントが扱う情報の流れを示し，Algorithm2 に強化学習エージェントによる充放電制御アルゴリズムを示す．まず，時刻 t における鉄道システム内の需給電力 A_t, R_t, B_t によって架線電圧 OV および，充電率 C が毎時刻変化する．次に，充放電制御は刻

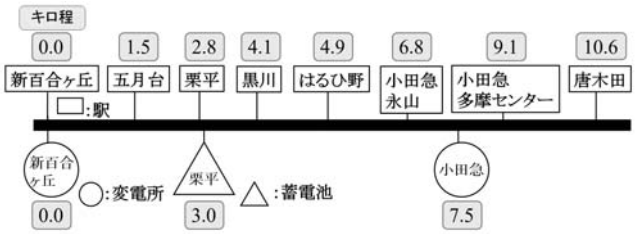


図 4: 対象線区の路線図

み時間 Δt 毎に行われ，状態入力として $s = (OV, C)$ を観測する．最後に，この状態入力からエージェントは充放電制御を行い，行動出力として充放電電流 I を出力する．なお，提案法では Algorithm1 によって出力される行動 a_t の値域が充放電電流 I の値域と異なるため，最終的に出力された値に適当な係数を乗算し，充放電電流 I として出力する．

エージェントには充電率 C と電力需給バランス H の安定化に関する報酬 r が (9) 式，(10) 式に基づいて与えられる．

$$r_t^{'} = \begin{cases} B_{\max} - |H_t| & \text{if } -B_{\max} \leq R - A \leq B_{\max} \\ -B_t & \text{if } R - A < -B_{\max} \\ B_t & \text{if } B_{\max} < R - A \end{cases} \tag{9}$$

$$r_t = \begin{cases} r_t^{'} & \text{if } C_{\min} < C_{t+1} < C_{\max} \\ r_{\min}^{'} & \text{otherwise} \end{cases} \tag{10}$$

(9) 式は電力需給バランス H の安定化に関する報酬であり，蓄電池の充放電制御によって電力需給バランス H を抑えた電力を報酬 $r^{'}$ として算出する．ただし，蓄電池による需給電力 B には上限 $B_{\max}$，下限 $B_{\min}$ が存在するため，上限 $B_{\max}$ または $B_{\min}$ を鉄道システム内の電力 $R - A$ が超える際には需給電力 B または $-B$ を報酬 $r^{'}$ とする．また，充電率 C が理想範囲を超えたときに報酬 $r^{'}$ の最小値 $r_{\min}^{'}$ を報酬 r とする．

報酬を与えられたエージェントは観測した状態の価値 $V(s)$ と平均値 μ_s，分散 σ_s を (4) 式，(6) 式，(8) 式にしたがって更新する．

以上の処理を繰り返すことによって充電率 C を考慮した制御則を獲得する．獲得した制御則を鉄道システムに適応し，鉄道システム内の電力需給バランス H を安定化する．

4. 提案法の有効性に関する実験

提案法による蓄電池の充放電制御の有効性を二つの実験によって確かめる．

4.1 実験設定

図 4 に計算機実験で対象とする鉄道システムに関して駅，変電所，蓄電池の位置関係を示す路線図を示す．実験 1 では図 4 における新百合ヶ丘駅から栗平駅の 3 駅，実験 2 では対象線区すべての 8 駅を 1 台の列車が走行する．

刻み時間 $\Delta t = 0.001$ とし，時刻 t 毎の充放電電流 $I(-200 < I < 200)$ を決定する．状態入力は架線電圧 $OV(1200 < OV < 1820)$，充電率 $C(0 < C < 100)$ である．本実験では初期架線電圧 $OV_0 = 1620$，蓄電池の初期充電率 $C_0 = 50$ とする．報酬 r は 3.2 節にしたがって毎時刻与える．強化学習のパラメータは学習率 $\alpha = 0.001$，割引率 $\gamma = 0.5$，方策割引率 $\beta_\mu = \beta_\sigma = 0.001$ とする．

充電率 C の安定化に向けた理想範囲 $C_{\min} \leq C \leq C_{\max}$ を，実験 1 の環境で既存手法を用いた場合の充電率変動幅 $(49.4 \leq C \leq 50.5)$ とする．充電率変動幅は初期充電率 C_0 を基準としたときに，最も変動した変動量を上限 $C_{\max}$，下限 $C_{\min}$ とした範囲である．

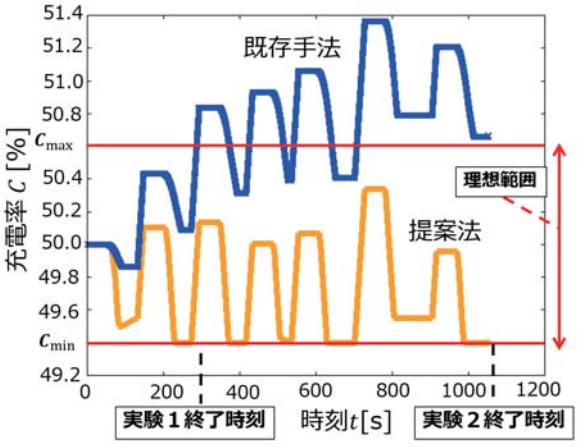


図 5: 充電率 C の時間推移

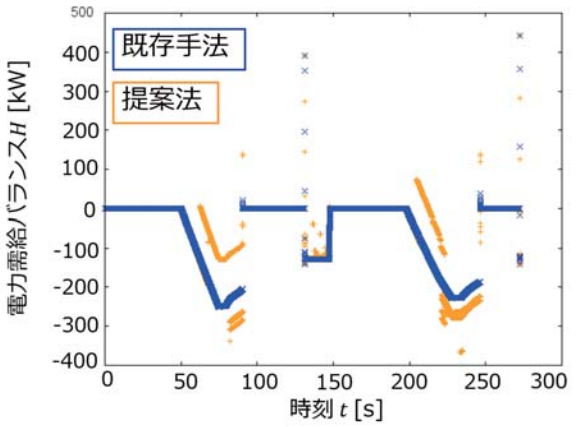


図 6: 実験 1 における電力需給バランス H の時間推移

4.2 実験結果および考察

■蓄電池充電率 C の安定化

図 5 に実験 2 における充電率 C の時間推移を示す．縦軸は充電率 C，横軸は時刻を示している．既存手法では蓄電池充電率の変動が，実験 2 の終了時刻までに理想範囲を超過しているのに対し，提案法では理想範囲内に抑えられていることがわかる．したがって，提案法により充電率 C の安定化を考慮した制御則の獲得ができたと考えられる．

■電力需給バランス H の安定化

図 6，表 1 に電力需給バランス H の安定化に関する実験結果をまとめる．図 6 は実験 1 における電力需給バランス H の時間推移を示し，縦軸は電力需給バランス H，横軸が時刻 t を示している．図 6 より $t = 60$ から $t = 90$，および $t = 210$ から $t = 250$ のときで提案法と既存手法に電力需給バランス H の差異が確認できる．この結果から提案法の性能を評価することは困難だと考えられる．

ここで，表 1 から総電力量，および最大最小値を比較する．電力需給バランス H の総電力量について，実験 1 および実験 2 の両方で提案法は既存手法に対して総電力量を削減できた．

最大最小値について，最大値は提案法と既存手法に大きな差はない．最小値は提案法の方が低く，電力需給バランス H

表 1: 提案法と既存手法の電力需給バランス H

実験	制御手法	電力需給バランス H		
		総電力量	最大値	最小値
実験 1	既存手法	45.65	441.97	-249.51
(3 駅)	提案法	39.01	441.97	-349.24
実験 2	既存手法	158.72	441.97	-249.51
(8 駅)	提案法	157.11	441.98	-396.08

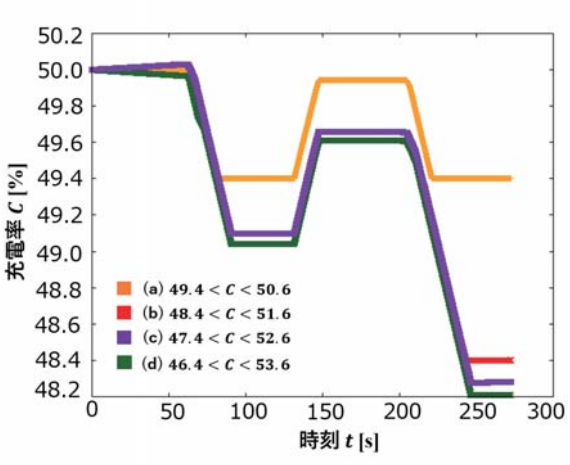


図 7: 理想範囲ごとの充電率 C の時間推移

の一時的なピークは提案法の方が大きかった．これは一時的なピークを抑える報酬設計ではなかったためであり，新たな報酬設計が必要である．

以上から提案法は，既存手法と比較して同等以上の制御結果を示した．とくに，充電率 C の安定化については既存手法よりも充電率の変動が安定した制御結果であった．よって，提案法では既存手法のルールベース制御では対応できない制御則の獲得が期待でき，有効であると考えられる．

5. 提案法の適応性に関する実験

5.1 実験設定

実験 1 で設定した環境から充電率 C の理想範囲を上限下限 1% ずつ最大 3% まで緩和させる．本実験では (a)$49.4 \leq C \leq 50.6$, (b)$48.4 \leq C \leq 51.6$, (c)$47.4 \leq C \leq 52.6$, (d)$46.4 \leq C \leq 53.6$ の 4 通りを充電率 C の理想範囲として実験する．

強化学習のパラメータは学習率 $\alpha = 0.001$，割引率 $\gamma = 0.5$，方策割引率 $\beta_\mu = \beta_\sigma = 0.001$ とする．実験 1 と同様に図 4 における新百合ヶ丘駅から栗平駅を 1 台の列車が走行する．上記の環境で提案法による蓄電池の充放電制御を行い，設定する充電率 C の理想範囲に対して適応性の有無を確認する．

5.2 実験結果および考察

■蓄電池充電率 C の安定化

図 7 に充電率 C の時間変動を示す．縦軸は充電率 C，横軸は時刻 t を示している．設定したすべての理想範囲において，各理想範囲内で制御ができている．(a)，(b) の場合は列車走行中に各理想範囲の下限 $C_{\min}$ まで変動しているのに対し，(c)，(d) では理想範囲の下限 $C_{\min}$ には至らなかった．これは，充電率 C の理想範囲に関係なく電力需給バランス H の安定化に向けて最適な方策 π が獲得できたためだと考えられる．

■電力需給バランス H の安定化

表 2 に電力需給バランス H の安定化に関する実験結果をまとめる．充電率 C の緩和が大きいほど総電力量の削減も大きいことがわかる．ただし，(d) では (c) のときと比べてほとんど同じ値を示した．これは，前述したとおり充電率 C の理想範囲に関係なく電力需給バランス H の安定化に向けて最適な方策 π が獲得できたためだと考えられる．

表 2: 理想範囲ごとの電力需給バランス H

実験	理想範囲		電力需給バランス H		
	$C_{\min}$	$C_{\max}$	総電力量	最大値	最小値
(a)	49.4	50.6	39.01	441.97	-349.24
(b)	48.4	51.6	32.31	441.97	-327.9
(c)	47.4	52.6	31.41	441.97	-304.2
(d)	46.4	53.6	31.39	441.97	-317.17

最大値は理想範囲の緩和にかかわらず，同じ値を示した．最小値については (d) のときを除いて，理想範囲を緩和をするほど一時的なピークを抑えた．

理想範囲が (d) のときは (c) のときと総電力量がほとんど同じ値であり，(c) のときが提案法の中で電力需給バランスの一時的なピークを最も抑えている．ただし，既存手法と比べると総電力量は大きく抑えられているが，一時的なピークは抑えられていない．4.2 節での考察と同様に，一時的なピークを考慮した報酬設計でないためだと考えられる．

本実験で充電率 C の理想範囲を緩和した際に各理想範囲に対応した制御則獲得ができた．以上より提案法による充放電制御の充電率 C の安定化に関する適応性が確認できたと考える．

6. 結論および今後の課題

本研究では，鉄道システムの省エネルギーの実現に向けて電力需給バランスを実現し，充電率を安定化する蓄電池の充放電制御アルゴリズムとして制御則の獲得に強化学習を用いた．計算機実験では，提案法が充電率と電力需給バランスの安定化の両面から既存手法と比較し有効であり，設定する充電率の理想範囲に対して適応性があることを確かめた．

一方，現状では提案法によって電力需給バランスの一時的なピークを抑えることはできていない．これは，ピークを抑えることを考慮した報酬設計をしていないからである．そこで，さらなる電力需給バランスの安定化に向け，一時的なピークを抑える充放電制御アルゴリズムの設計が今後の課題である．

また，本研究ではエージェントが蓄電池だけのシングルエージェントである．今後は列車の運転行動も制御対象に加えたマルチエージェント環境への拡張を検討する．

参考文献

[Satake 14] 佐竹信彦，野木雅之 and 保科俊一郎，“鉄道向け回生電力蓄電システム，”東芝レビュー 69.8，pp.52-55，(2014)

[Sutton 98] R. S. Sutton and A. G. Barto,“Reinforcement learn-ing: An introduction, ”MIT press Cambridge, Vol.1,No.1(1998)

[Kimura 00] 木村元 and 小林重信，“Actor に適正度の履歴を用いた Actor-Critic アルゴリズム：不完全な Value-Function のもとでの強化学習，”人工知能学会誌，Vol. 15，No. 2，pp. 267-275 (2000)

[Kagaya 13] 加賀谷駿 and 荒井幸代，“太陽光発電の変動抑制に向けた強化学習エージェントモデル，”電子情報通信学会論文誌 D，96.12，pp.3000-3008，(2013)

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

道路交通網と電力系統の連成シミュレーション

Microscopic Simulation of Coupled Traffic and Electric Grids

内田 英明 *1　藤井 秀樹 *1　吉村 忍 *1
Hideaki Uchida　Hideki Fujii　Shinobu Yoshimura

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

Realization of a sustainable low-carbon society is required globally, and energy consumption reduction derived from fossil fuels has been emphasized. In the transportation sector, which accounts for a large percentage of energy consumption, EVs with high environmental performance has been popularized and it is important to use renewable energy for its charging effectively. In this research, we proposed a coupled simulation model that can represent interactions between transport and electric power systems. Since the charging event is coupled to the electric power system mechanism, the spread of EVs will affect not only the road transport network but also the electric power system. As a result of the numerical experiments, it was implied that the concentration of low-output charge after returning home might cause a voltage drop in the distribution system. This phenomenon became more prominent as the penetration rate of EV increased, and the possibility that it deviates from the legal range of the reference voltage is shown in some scenarios.

1. はじめに

持続可能な低炭素社会の実現は世界的な要請である．温室効果ガスの排出量の多くはエネルギー起源二酸化炭素によって占められていることから，化石燃料由来のエネルギー消費を低減することが重要視されるようになっている．エネルギー消費において大きな割合を占める運輸部門においては，近年環境性能の高い電気自動車（Electric Vehicle： EV）が注目を集めている．航続距離の短さや充電設備（Charging Station： CS）の未整備により現状の普及率は 1%未満に留まるが [1]，多くの国において，税制優遇やガソリン車の将来的な製造中止など EV への転換の機運が高まっている．ただし，EV の普及に伴い化石燃料の消費が増大してしまうことは本末転倒であり，充電には太陽光・風力・水力といった再生可能エネルギーが利用されることこそが本質的である．

再生可能エネルギーの動向に目を向けると，太陽光発電（Photovoltaics： PV）と風力発電の導入量が大きな割合を占めている [2]．これらは天候により大きく出力変動する電源であり，大量に電力系統に連系すると系統運用上の問題，例えば余剰電力による配電系統の電圧上昇や周波数変動等の課題が指摘されている．余剰発生時においては変動電源の出力抑制が実施されるが，低炭素化の取り組みを念頭に置くと回避すべき事象であることは明らかである．対策の一つとしては電力貯蔵技術が挙げられており，その有力な候補のひとつとして EV が系統の安定化に資するものと期待されている．

このように，低炭素社会の実現に向けては EV が大きな役割を果たすと考えられており，その際には再生可能エネルギーを有効に利用することが重要である．これまでガソリンを燃料として自動車が走行している道路交通網と，主に出力制御可能な電源によって維持されていた電力系統は互いに影響しあうことは考えられなかったが，今後普及していく EV を介して相互作用が発生することが予想される．

このような将来の課題は常に不確定性を内包しており，厳密な解決は困難であることから，有力な方法論のひとつとしてシミュレーションによるアプローチが採用される．しかし，これまでの検討の多くは道路交通網，ないしは電力系統のどちらかに着目したものであり，双方のメカニズムにまたがる相互作用については十分なシミュレーションモデルの開発がなされてこなかった．そこで，本研究ではこれらの 2 つのメカニズムをモデル化し，相互作用を表現可能な連成シミュレーションモデルを構築する．道路交通のメカニズムの表現には著者らが開発したマルチエージェント交通シミュレータ ADVENTURE_Mates[3][4] を使用する．本研究では新たに電力系統のメカニズムを表現するための潮流計算コードを開発し，CS オブジェクトを介して相互のモデルを連成する．モデルの全体像を図 1 に示す．続いて，この連成効果が大きいと考えられる配電系統網における電圧不安定化現象を再現し，交通状況が系統に対してどのような影響を及ぼすかを明らかにする．



図 1: 交通-電力系統 連成シミュレーションの概念図

2. 電力系統モデル

2.1 電圧不安定現象

電力系統は供給量（発電量）と需要量（負荷）が均衡し同時同量が達成さることで正しく機能するため，時々刻々変化する

連絡先: 内田英明，東京大学大学院工学系研究システム創成学専攻，〒 113-8656 東京都文京区本郷 7-3-1 工学部 8 号館 423 室，03-5841-1864，uchida@save.sys.t.u-tokyo.ac.jp

需要に対し供給量が適切になるよう制御する需給調整機能が備わっている．これは種々の観測だけでなく事前に策定される需要予測と運転計画・設備投資によって達成される．EV の充電需要規模は普及に合わせて徐々に拡大していくと考えられるため，現状の需給調整機能では系統に大きな影響を与える可能性がある [5].

EV の充電需要が系統に与える影響としては，電圧不安定現象が考えられる．これは現在導入量が拡大している再生可能エネルギーの出力変動によって既に顕在化しており，現状再生可能エネルギーは需要家側において系統連系していることから特に低圧配電系統において顕著である．需要拡大により電気の流れが増すと需要家側の電圧が低下するが，系統電圧の適正範囲内での維持は系統運転上の基本的事項であり，電圧調整設備や調相設備により安定化を図る．EV の充電による新たな需要に起因する電圧不安定化のリスクに対応するには，運用目標電圧の見直しや電圧調整設備・調相設備の新規整備が必要となる．

2.2 潮流計算

電力系統の運用・計画のために系統内部各所の電圧や電線・変圧器を流れる電力の分布を把握することは重要であり，その基礎的な分析が潮流計算である．電力系統は交流回路であり，原理的には交流回路計算と同等である．回路計算は電圧源・電流源を所与とし，回路内のノード電圧・ブランチを流れる電流を計算することである．潮流計算の場合には，次の 3 つの条件を与えることで解が定まる.「系統構成」は発電機，変圧器，送電線，負荷などの設備の接続関係,「設備定数」は変圧器，送電線のインピーダンス及びアドミタンス,「運用条件」は発電機や負荷における電圧，有効電力，無効電力など，計算の拘束条件に該当する．

2.3 Backward Forward Sweep 法

一般に潮流計算に用いられる手法には Newton-Raphson 法 [6] や Fast Decoupled 法 [7] がある．これらは主に高圧の送電系統を中心に適用されてきたが，放射状のトポロジーを持つ配電系統においては悪条件であるほか，配電系統のように路線の抵抗がリアクタンスに対して無視できない大きさである場合には収束性が悪化する．しかし近年は分散電源の増加などに伴い配電系統の潮流計算の必要性が指摘されるようになっている．そこで本研究では，配電系統における潮流計算手法として Backward Forward Sweep 法 [8][9] を採用する．本手法は電流計算に対応する Backward Sweep と電圧計算に対応する Forward Sweep を繰り返し，得られる電力値が収束することで出力とする．本手法は系統構成が木構造であることを前提とすることで状態変数を低減し，送電系統に比べてノード数が多く計算負荷がクリティカルである配電系統に特化した高速計算である．配電系統のように路線の抵抗がリアクタンスに対して卓越する場合においても収束性が良好であることが知られている．

Backward Forward Sweep 法は以下の通り 3 つのプロセスによって成り立っている．初めに，ある反復ステップ k において，k-1 ステップで得られた各ノードの有効電力・無効電力の損失分を系統上流に掃き出していく Backward Sweep である．式 1，2 が対応する．ここで P は有効電力，Q は無効電力，V は電圧である．また R はブランチの抵抗，X がリアクタンスである．r は s に対して上位のノードであることを表す．Backward Sweep ではキルヒホッフの法則より，ノードに流れ込む電流の総和は等しくなるため，下位から上位へ重ね合わせることで全ノードの電流が計算でいる，続いて式 3 に示す Forward Sweep である．Backward Forward Sweep 法では最上位ノードをスラックノードとし，基準電圧及び位相角 0 を与える．そして最上位から系統下流へ掃き出していくことで，反復ステップ k における電あるが求まる．これを式 4 に示す打ち切り精度で終了することで系統が収束する．

Backward Sweep：電流計算

$$P_s^k = P_r^{k-1} + \frac{R\left\{(P_r^{k-1})^2 + (Q_r^{k-1})^2\right\}}{(V_r^{k-1})^2} \tag{1}$$

$$Q_s^k = Q_r^{k-1} + \frac{X\left\{(P_r^{k-1})^2 + (Q_r^{k-1})^2\right\}}{(V_r^{k-1})^2} \tag{2}$$

Forward Sweep：電圧計算

$$V_r^k = V_s^k \left(1 - \frac{P_s^k R + Q_s^k X}{(V_s^k)^2} + j\frac{Q_s^k R + P_s^k X}{(V_s^k)^2}\right) \tag{3}$$

電圧の収束条件

$$V^k - V^{k-1} < \epsilon \tag{4}$$

3. 交通-電力連成モデル

道路交通網のメカニズムと電力系統のメカニズムという異なる 2 つのインフラシステムが存在し，EV を介して影響することを考える場合，これを連成現象として捉えることは自然である．本来，連成現象とは複数の場の方程式によって表現される現象が互いに相互作用するより複雑な現象のことであり，物理シミュレーションの分野において一般的な概念である．本研究において，道路交通のメカニズムは車両挙動に関わる意思決定と相互作用による社会的なふるまいのモデルであることから，系の挙動を陽に記述することは困難であり，マルチエージェントシミュレーションにより可能解・近似解を得る．一方電力系統のメカニズムは系統の潮流分布を電力方程式を解くことで解析するものであり，手法の適用範囲内においては支配方程式の厳密解が得られる．

道路交通のメカニズムを表現する交通シミュレーションには ADVENTURE_Mates を採用し，入力データとしては地図データと車両発生に関わる OD データが与えられる．このうち地図データには配置される CS の座標情報や普通・急速充電の種別が追加される．OD データには EV の発生を定義する必要がある．これらの結果として車両の走行ログや排出ガスデータの他に，EV の充電イベントが発生する．この充電イベントが負荷として電力シミュレーションに連成境界条件として与えられる．

電力系統のメカニズムを表現する電力シミュレーションには潮流計算を採用する．入力データとしては系統構成・設備定数・運用条件が与えられる．ここで道路交通網との連成境界となる系統上の CS の位置を指定する必要がある．また，動的運用条件として EV の充電需要と PV の出力を取得する．このうち，EV の充電需要は電力シミュレーション内の 1 ステップ毎に交通シミュレーション側の出力を取得する．これらを基に潮流計算を実行し，出力として送電線の電力・ノード電圧・位相角を得る．モデルの詳細を図 2 に示す．

4. 数値実験

4.1 実験設定

連成シミュレータを利用し，道路交通網のメカニズムが電力系統に与える影響として電圧不安定現象の解析を実施する．

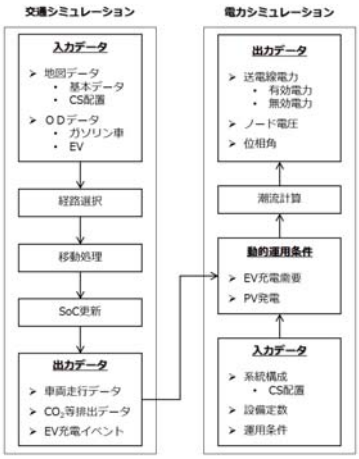


図 2: 連成モデルの詳細

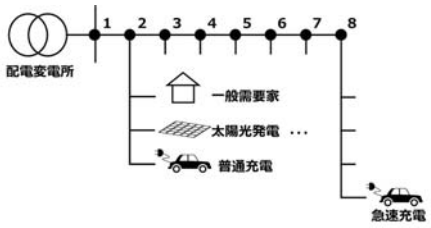


図 3: 配電系統モデル

道路交通網は和歌山市中心部のネットワークとし，図 5 に示すとおり 2017 年 1 月現在の急速充電器配置と任意の普通充電器を追加した．ノード数 1470・リンク数 1346，急速充電器の設置された CS は 13 箇所であり，収容台数は各 5 台，出力は全て 150kW である．普通充電器の設置された CS は 21 箇所であり，収容台数を無制限，出力は全て 3kW である．また，車両発生台数は交通量調査の結果を基に推定しており，普及率に応じて EV に置き換えることとする．本実験では 10%刻みで 10%～50%の 5 通りとする．EV の充電残量（State of Charge： SoC）は 30%～80%の範囲でランダムである．

また，電力系統は図 3 に示す配電系統を仮定する．ここでは電圧・電流などの不平衡は考慮せず，全て単相回路と仮定し解析を行う．無限大母線から 101V 相当の電力が送り出される潮流条件とし，世帯ごとの負荷のプロファイルと PV の出力は図 4 とする．PV の普及率は 10%刻みで 10%～30%の 4 通りとし，力率 0.95 で全てのノードに均等に分布するものとする．

連成境界条件として，CS での充電負荷を配電系統にマッピングする．本実験では特に EV 等の影響が大きいと考えられる市街地として図 5 に示すエリア A と B に着目し，各エリア内の普通充電器の負荷と PV は配電系統の全てのノードに均等に，急速充電器の負荷は末端のノード 8 に集中して分布するものとした．

CS での負荷は事前に指定された充電器種別や出力の他に，EV エージェントの SoC に応じて変動する定電圧定電流（constant voltage constant current: CVCC）方式 [10] に基づいて決定される．EV の電池として登載されるリチウムイオン電池には充電電流及び電圧に関して制限があり，充電初期には電流，終期には電圧の制約が卓越する．従って，これらを一定

表 1: インピーダンスマップ

from	to	R [p.u.]	X [p.u.]	Y/2 [p.u]
1	2	0.00324	0.00393	0.0001
2	3	0.02579	0.04413	0
3	4	0.02579	0.04413	0
4	5	0.02579	0.04413	0
5	6	0.02579	0.04413	0
6	7	0.02579	0.04413	0
7	8	0.02579	0.04413	0

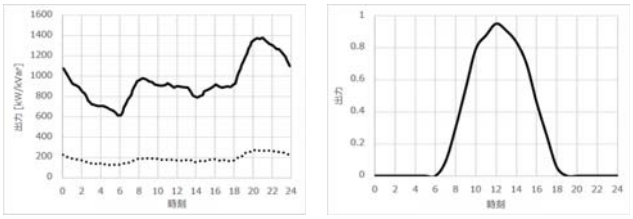


図 4: 世帯の日負荷曲線モデル（実線：有効電力，破線：無効電力）と晴天時の PV 出力モデル

値以下とするために充電による SoC の増加量は時間変化する．また、ここで決定された負荷には充電器の力率として 0.95 が考慮され電力系統に対する運用条件が定まる．

以上より，シミュレーション条件は EV 普及率（5 通り）× PV 普及率（4 通り）の 20 ケースとなる．11 時～21 時までの 10 時間を対象とし，交通シミュレーションは $\Delta t = 0.1$ 秒，電力系統シミュレーションは $\Delta t = 1$ 分の設定とした．電力シミュレーションは充電器の負荷と PV の発電出力を 1 分毎に更新し，逐次潮流計算を実行する．

4.2 実験結果

図 6～8 に実験結果の一部を示す．各図中の縦軸は電圧，横軸はノード番号であり，12 時～21 時の各時間断面における電圧分布をプロットしている．電気事業法により定められた 100V 系の基準電圧は 101 ± 6V の範囲である．両エリア内に目的地を持ち普通充電器によって目的地充電を行う EV エージェント数は概ね同程度だが，エリア B には 2 箇所の急速充電器が存在し，エリア内の交通量も大きいため，経路充電の頻度は相対的に高い．

普通充電器による影響

交通シミュレーションにおいては，EV の普及率の上昇に合わせて充電イベントの発生回数も増加する．普通充電器の出力

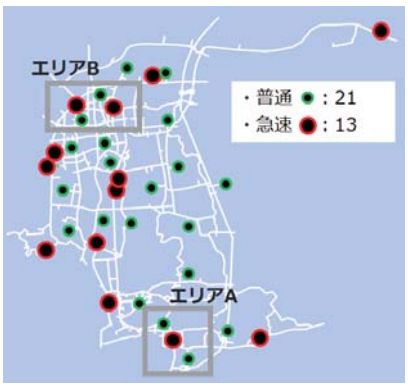


図 5: 和歌山市中心部の道路ネットワーク

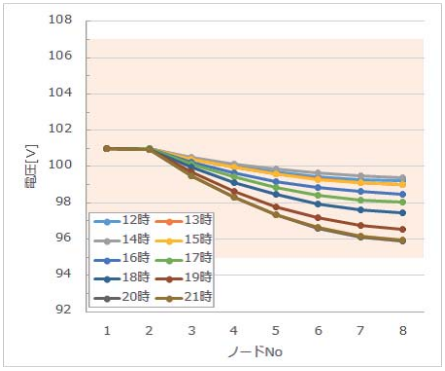


図 6: エリア A：EV10%/PV10%

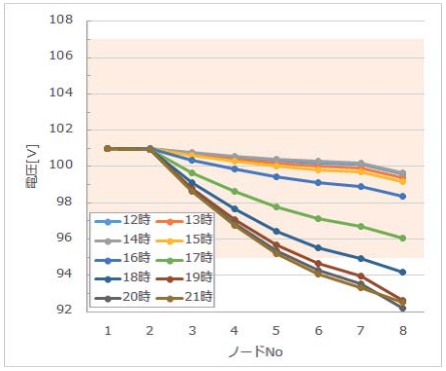


図 7: エリア B：EV50%/PV20%

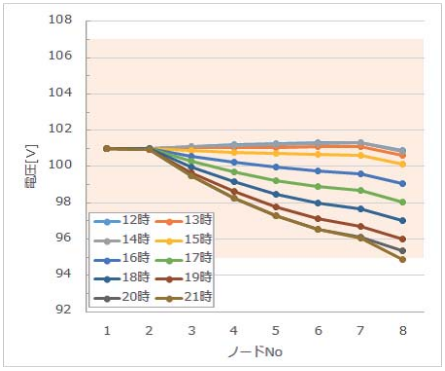


図 8: エリア B：EV10%/PV30%

は 3kW と図 4 に示す平均的家庭の 1 日の最大出力に対して 2 倍程度であるものの，長時間の充電により同一エリア内で次々と充電イベントが重なった結果として，大きな電圧降下の要因となっている．図 6 において，帰宅時間帯と夕方の電力使用ピークが重なることで影響がより大きくなっていることがわかる．

急速充電器による影響

普通充電器と同様，EV の普及率が高まることによって充電イベントの発生回数は増加するが，150kW という高出力であることから充電時間はごく短く，結果として任意の時間断面において同一エリア内で充電イベントが重複する可能性は高くない．ただしエリア B においては近接して 2 箇所の急速充電器が存在する上，どちらも周辺交通量が大きく，従って時間帯によってはノード 8 に顕著な電圧低下がみられ，しばしば基準電圧を逸脱する結果となった．図 7 においては 20 時のノード 8 の電圧が 92V まで低下していることが観察できる．

PV の普及による影響

全体的な傾向として日射量が多く発電出力の高い 12 時において，逆潮流による電圧上昇が確認できる．図 8 において顕著である．ただしこの影響は基準電圧を逸脱するほどのものではない．また，ここまで述べた通り EV の充電需要集中により発生する電圧低下は，帰宅時間帯と夕方の電力使用ピークが重なることによって発生しているが，PV 出力の多い昼間とはかい離があり互いに打ち消しあうような現象は発生しないことがわかる．

5. まとめ

本研究では，低炭素社会の実現に向けた流れとして EV の普及を背景とした交通網と電力系統間の相互作用に着目し，両システムにまたがる課題を一元的に扱う連成シミュレーションモデルを開発した．著者らの開発した ADVENTURE_Mates と電力系統モデルを接続し，EV が電力系統に与える影響として電圧不安定現象の解析を実施した．

既存研究においては EV の挙動を均一に扱い，道路交通網のメカニズムを考慮しなかったため，本研究では現実の道路ネットワークと配電系統を模擬した連成シミュレーションを実施し，EV の充電行動がどのような影響を及ぼすか複数のケースについてパラメトリックスタディを行うことが可能となった．今後は制御機器の導入されたより現実的な配電系統を対象とし，系統及び EV の充電行動を制御することによるリスク回避の可能性について検討することが重要である．

謝辞

本研究は JSPS 科研費 15H01785 の助成を受けたものである．ここに記して謝意を表する．

参考文献

[1] International Energy Agency: Global EV Outlook 2017, 2017.

[2] Bloomberg New Energy Finance: New Energy Outlook 2017, 2017.

[3] H. Fujii, H. Uchida, and S. Yoshimura: Agent-based Simulation Framework for Mixed Traffic of Cars, Pedestrians and Trams, Transportation Research Part C, Vol. 85, pp. 234-248, 2017.

[4] 4. 内田 英明, 藤井 秀樹, 吉村 忍: マルチエージェント交通シミュレーションにおける充電を考慮した EV の経路選択, 人工知能学会論文誌, Vol. 32, No. 5, pp.AG16-I_1-9, 2017.

[5] International Energy Agency: Energy Technology Perspectives 2017, 2017.

[6] W. F. Tinney, and C. E. Hart: Power flow solution by Newton's method, IEEE Transactions on Power Apparatus and systems, Vol. 11, pp. 1449-1460, 1967.

[7] B. Stott, and O. Alsac: Fast decoupled load flow, IEEE transactions on power apparatus and systems, Vol. 3, pp. 859-869, 1974.

[8] D. Shirmohammadi, H. W. Hong, A. Semlyen,and G. X. Luo: A compensation-based power flow method for weakly meshed distribution and transmission networks, IEEE Transactions on power systems, Vol. 3, No. 2, pp. 753-762, 1988.

[9] G. X. Luo, and A. Semlyen: Efficient load flow for large weakly meshed networks, IEEE Transactions on Power Systems, Vol. 5, No. 4, pp. 1309-1316, 1990.

[10] C. C. Hua, and M. Y. Lin: A study of charging control of lead-acid battery for electric vehicles, Proceedings of the 2000 IEEE International Symposium on Industrial Electronics, Vol. 1, pp. 135-140, 2000.

[3L2] [General Session] 2. Machine Learning

座長:木村 昭悟（NTT）

Thu. Jun 7, 2018 3:50 PM - 5:30 PM Room L (3F Sapphire Hall Asuka)

[3L2-01] Fast point set registration using a statistical shape model

○Osamu Hirose[1] （1. Kanazawa University）

3:50 PM - 4:10 PM

[3L2-02] Depth Image Prediction for Transparent Objects and its Application to Home Assistant Robot Based on Automatic Training Data Generation Using Mesh Model

○Yuto Uchimi[1], Kentaro Wada[1], Kei Okada[1], Masayuki Inaba[1] （1. The University of Tokyo）

4:10 PM - 4:30 PM

[3L2-03] Image Reconstruction for Super Resolution Microscope Using Recursive Bayesian Computation

○Shunsuke Kido[1], Takashi Washio[1], Tetsuichi Wazawa[1], Takeharu Nagai[1] （1. The Institute of Scientic and Industrial Research, Osaka University）

4:30 PM - 4:50 PM

[3L2-04] Examination of object tracking method for space-temporal data based on greedy EM algorithm

○Ryo Hayashi[1], Rie Honda[1] （1. Kochi University）

4:50 PM - 5:10 PM

[3L2-05] Embedding and retrieval of images and text data using probability distribution

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

5:10 PM - 5:30 PM

©The Japanese Society for Artificial Intelligence

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

形状事前分布を利用した高速な点群マッチング手法の開発

Fast point set registration using prior shape information

広瀬 修
Osamu Hirose

金沢大学 理工研究域
Institute of Science and Technology, Kanazawa University

The goal of point set registration is to find point-by-point correspondences between point sets, each of which characterizes the shape of an object. Because local preservation of object geometry is assumed, prevalent algorithms in the area can often elegantly solve the problems without using geometric information specific to the objects. This means that registration performance can be further improved by using prior knowledge of object geometry. In this paper, we propose a novel point set registration method using the Gaussian mixture model with prior shape information encoded as a statistical shape model. The proposed method works effectively if the target point set includes outliers and missing regions, or if it is rotated. The computational cost can be reduced to linear, and therefore the method is scalable to large point sets.

1. はじめに

点群マッチング問題は物体の形状を表現する 2 つの点集合間の対応関係を見つける問題である．点群マッチング問題の中で点群間の対応関係に加え，点群をもう一方の点群に移す写像を求める問題は点群レジストレーション問題と呼ばれる．点群レジストレーション問題は想定する写像の種類に応じて剛体変換と非剛体変換のものに分類され，最近では非剛体変換に基づいた点群レジストレーションが，その柔軟さのため非常に活発に研究されている．

Coherent point drift (CPD) は非剛体変換に基づいた点群マッチング手法の代表的な手法である [Myronenko 10]．CPD の成功の要因としてまず挙げられるのが，外れ値への耐性である．ここで，外れ値とは，点群によって表現される形状とは無関係に存在する点とする．CPD は点群レジストレーション問題を混合分布を基礎とした確率分布の推定問題として定義する．その際，混合分布の構成分布の 1 つとして外れ値の分布を明示的に与えることが，外れ値への耐性の主要な要因である．CPD のもう 1 つの成功要因として挙げられるのが，非剛体変換される点群に対する「変位場の滑らかさ」である．変位場の滑らかさとは，非剛体変換される点群を構成する任意の点の変位と，その他の点の変位が，その距離が近ければ近いほど相関するとした仮定である．この仮定は非常に自然な仮定であるため，CPD は多くの点群レジストレーション問題において精度の高いレジストレーション結果を与える．一方で，変位場の滑らかさの仮定が適切ではない場合，CPD は容易にレジストレーションに失敗する．例えば，人間の手の形状マッチングを行う場合，人差し指と中指を構成する点は比較的近くに位置するが，その動きは逆相関する傾向があり，このような場合には変位場の滑らかさの仮定が不適切であるためである．

この問題を克服する方法の 1 つとして挙げられるのが，教師あり学習に基づくアプローチである．もし人差し指と中指の動きが逆相関する傾向にあることを事前に知っていれば，その知識をレジストレーションアルゴリズムに組み込むことにより，高精度のレジストレーションが期待できるからである．今回，昨年度に開発した，教師あり学習法に基づいた点群レジストレーション手法に対する拡張および高速化について報告する．開発手法は外れ値の分布を構成分布の 1 つとして持つ混合分布に基づいているため，外れ値への優れた耐性を有する．また，物体の形状変化モデルを，訓練データから得られる事前知識である統計的形状モデルとして定義するため，変位場の滑らかさの問題を自然に解決することができる．

連絡先: 広瀬 修，金沢大学理工研究域，920-1192 石川県金沢市角間，hirose@se.kanazawa-u.ac.jp

2. 実験

開発した手法を SCAPE データに適用した．SCAPE データは 71 種類の姿勢での人間の形状をスキャンし，12,500 個の三角形で構成される 3D メッシュ として表現したものである．各々の三角形には座標情報があり，点群マッチングの性能評価のため，この座標情報のみを利用した．今回，形状の欠損のへの耐性を評価するため，姿勢データ 1 から頭部および両足を構成する 4000 点を取り除いた点群データを作成した．同様に，外れ点への耐性を 評価するため，姿勢データ 1 から外れ点 3750 点を加えた点群データを作成した．このデータへの開発アルゴリズムの適用結果を図 1 に示す．欠損データへの適用結果が上段に，外れ点データへの適用結果が下段に示されている．同様に，最も左の列が最適化の初期状態を示し，最適化の途中経過が右方向に向かって順に示されている．欠損データへの適用結果から，欠損部分の形状が自然に復元されていることが見てとれる．また，外れ点データへの適用結果から，外れ点に影響されず正しく点群マッチングを行えていることが示唆される．

参考文献

[Myronenko 10] Myronenko, A., and Song, X.: Point set registration: Coherent point drift (2010), IEEE Transactions on Pattern Analysis and Machine Inteligence 32(12), 2262-2275.

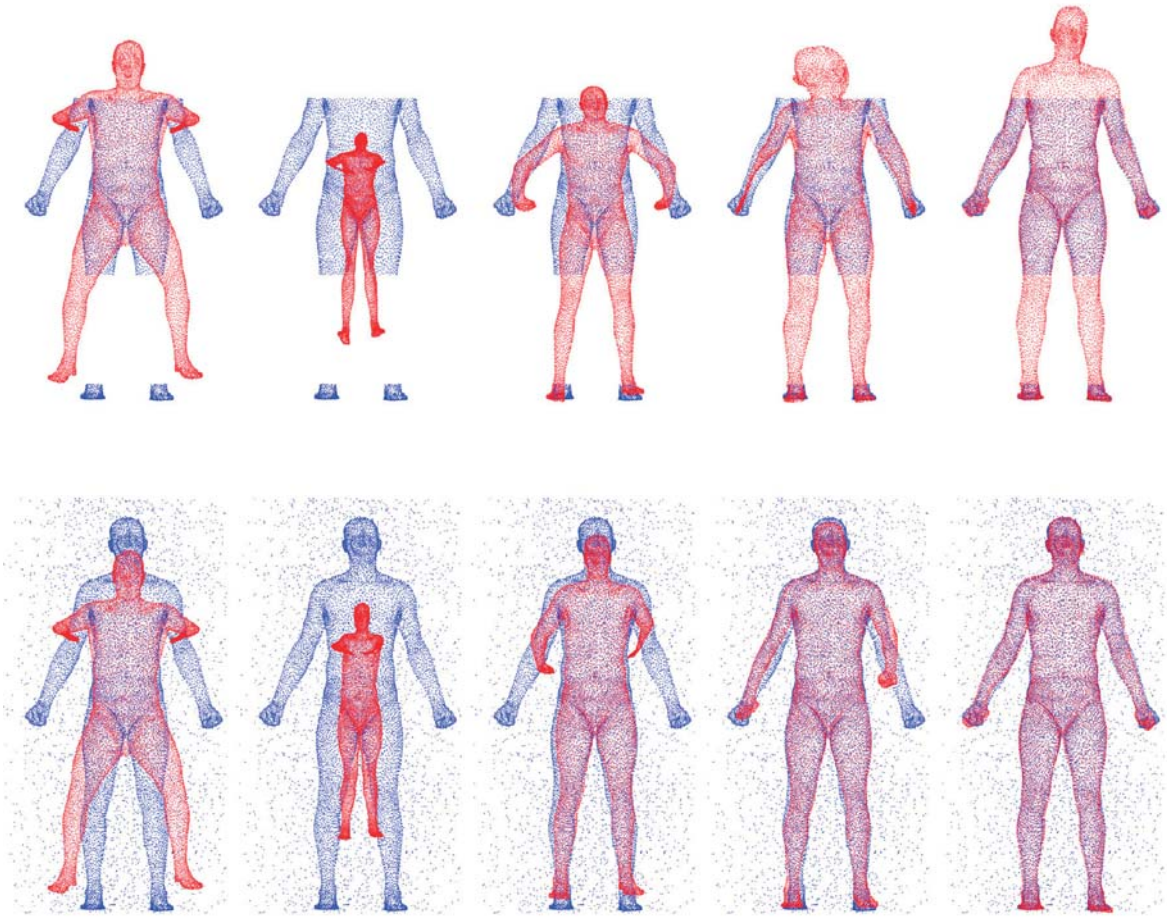


図 1: 提案手法の欠損データ（上段）および外れ点データ（下段）への適用結果．青色の点群がレジストレーションの目標となる点群を示し，赤色の点群がレジストレーションを行うために形状変化される点群を示す．最も左の列が最適化の初期状態を示し，右に向かって最適化が進行することを示している．

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

物体メッシュモデルを用いた学習データ自動生成に基づく透明物体の深度画像予測と家事支援ロボットへの応用

Depth Image Prediction for Transparent Objects and its Application to Home Assistant Robot Based on Automatic Training Data Generation Using Mesh Model

内海 佑斗 Yuto Uchimi　和田 健太郎 Kentaro Wada　岡田 慧 Kei Okada　稲葉 雅幸 Masayuki Inaba

東京大学大学院情報理工学系研究科
The University of Tokyo, Graduate School of Information Science and Technology

Home assistant robots deal with various objects in the home. However, transparent objects such as wine glasses are difficult for robots to estimate 3D position, therefore they have trouble in manipulating such objects. This paper proposes a method of semantic segmentation and depth image prediction using CNN, which enables robots to get depth of transparent objects and reconstruct them three dimensionally. It also proposes a method of collecting training data, by which a person no longer has to annotate objects in 3D space. By using our depth prediction method, robots can handle PET bottles as well as non-transparent objects.

1. はじめに

家事支援ロボットには家庭内にある多種多様な物体を扱うことが求められるが、その中でもペットボトルやワイングラスなど透明物体の認識と操作は未だ解決されていない課題の一つである。これらは光を反射・吸収・透過するなどの性質を持つためセンシングによる三次元的な位置推定が困難であり，家事支援を遂行するための環境認識に際して大きな課題である．

近年，透明物体の三次元位置推定として，条件付き確率場や多層畳み込みネットワークを利用した機械学習による深度画像予測の手法の有効性が明らかになってきた [Eigen 14] [Liu 15] [Wang 15]．物体の特性を検知する手法 [Eren 09] [Rantoson 10] に対し，機械学習による手法の多くはシステムの入力としてカメラから取得した単一の色画像のみを用いることで，透明物体の認識のために特別な装置を要することなく深度予測を実現可能であるほか，画像中の各領域がどのような物体であるかの分類も可能である．

ところがロボットに搭載されるカメラセンサについてはRGB-D の計測が可能なカメラが既に広く用いられているため，透明物体以外の深度取得にはセンサ値を採用すればよい．本研究では，多層畳み込みネットワークを用いてラベル画像予測と深度画像予測を同時に行い，センサから取得される深度画像のうち，ネットワークにより透明だと判定された領域のみを予測深度画像で置換した深度画像を出力して三次元位置推定を行うことを提案する．

しかしながら，教師あり学習を行うためには透明物体の正しい深度情報を持つ画像を収集する必要がある．NYU Depth [Silberman 12] などのデータセットは、深度情報を取得するための投射光が正常に帰ってこないという透明物体の性質のため、これらの正しい深度情報を含んでいない。この解決策として人間による三次元空間上でのアノテーションが挙げられるが，物体数が増えるに従って人間の負担も増加するため，効率的とは言えない．そこで本研究では，透明物体の三次元メッシュモデルを利用してタスク環境を仮想的に再現し，人間による三次元アノテーションの不要な効率的な学習データ生成を行うことを提案する．

連絡先: 内海佑斗，東京大学工学部情報システム工学研究室，113-8656 東京都文京区本郷 7-3-1 工学部 2 号館 7 階 73B2，03-5841-7416，uchimi@jsk.imi.i.u-tokyo.ac.jp

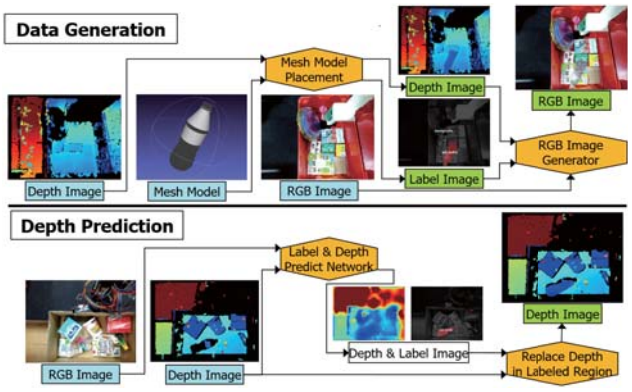


図 1: 学習データ生成 (上) と深度予測システム (下) の概観

本研究の提案手法の有用性を示すため，ロボットが家事支援において透明物体を扱うタスクに提案システムを適用する実験を行う．

2. 物体モデル配置による学習画像生成

機械学習による深度予測を行うために，透明物体の教師ラベル画像と教師深度画像を取得する必要がある．本研究では，まず実際の様々なタスク環境について，ロボットが各シーンにつき複数視点から撮影することで，透明物体の置かれていない画像データを収集する．次に，環境の点群上に透明物体の CAD モデルを仮想的に自動配置することで，教師画像を生成する．また，自動収集した教師画像に対応する色画像を生成するため，本研究では光の反射・物体に生じる陰・半透明性による曇りを再現するアルゴリズムと，GAN を組み合わせることで色画像を自動生成することを提案する．さらに，ラベル画像予測の精度向上のために，タスク環境上で実際の透明物体の色画像を撮影して，二次元アノテーションを行うことで教師信号としてラベル画像のみを持つ少数の学習データセットを用意する．

2.1 データ収集

ロボットに搭載された RGB-D カメラセンサを用いて，タスク環境に透明物体の置かれていない色画像 I_{obj-} および深度

画像 $D_{obj\_}$ を撮影する．撮影の際には色画像と深度画像の他にも，カメラ内部パラメータ K とロボットのベースリンクからカメラへの座標変換 R_{cam}^{base} も同時に保存しておく．

2.2 深度画像およびラベル画像の生成

透明物体の写っていない色画像 $I_{obj\_}$ に対し，物体メッシュモデルを置くことのできる領域 (これを可配置領域とする) を二次元アノテーションにより与える．続いて深度画像 $D_{obj\_}$ のうち可配置領域以外を N/A として，点群を生成する領域を限定する．これにより作られた深度画像と，収集済みのカメラパラメータ K および座標変換 R_{cam}^{base} を用いて，ロボットのベースリンク座標系での点群を生成し，その点群上に物体メッシュモデルを仮想的に配置する．

配置の際の物体モデルの姿勢は，モデルを直方体に近似して上を向く面を 6 面からランダムに決定し，その後鉛直軸周りにランダムな角度だけ回転させることで決定される．またモデルの位置に関しては，水平方向には可配置領域内でランダムに決定され，鉛直方向には重力に従って可配置領域内の面に接するように決定される．

メッシュモデルを仮想配置した後にレイキャスティングを行ってカメラ視点での物体モデルの深度画像とラベル画像 L_{obj_g} を取得し，そしてこの深度画像を収集済みの深度画像 $D_{obj\_}$ に重ねて，学習に用いる深度画像 D_{obj_g} を生成する．

2.3 色画像の生成

ここでは，学習時に用いるため自動生成された深度画像およびラベル画像に対応するタスク環境の色画像を自動生成する．

2.3.1 光の反射・物体の陰・半透明による曇りの再現

色画像生成の第一段階として，光の反射・物体に生じる陰・物体の半透明性による曇りを人工的に再現した画像 I_{obj_g} を生成する．この段階には透明物体の写っていない色画像 $I_{obj\_}$，生成された深度画像 D_{obj_g} およびラベル画像 D_{obj_g} を用いる．

再現アルゴリズムは以下のように説明される．まず最初に，色画像 $I_{obj\_}$ とラベル画像 L_{obj_g} を用いて，色画像のうち透明物体の背景に相当する部分を抽出する．第二に，深度画像 D_{obj_g} に Canny アルゴリズムを適用してエッジを抽出し，各画素のエッジからの L2 距離を計算した画像を用意する．これと並行して，ラベル画像を透明か否かによって二値化したマスク画像に水平右方向の Sobel フィルタを半時計回りに 45° だけ傾けたフィルタを適用し，さらに平滑化して物体左下部のエッジ付近が抽出された画像を用意する．

第三の工程では物体に陰をつける．第二の工程で作成したエッジからの距離画像の画素 i の画素値 x_i に対し，式 (1) の第 2 式を用いて明度を決定する係数 v_i を計算する．ただし，第二の工程で作成したエッジ付近の抽出された画像の画素値 y_i が閾値 $thre$ 以上ならば式 (1) の第 1 式を用いて v_i を計算する．

$$v_i = \begin{cases} \dfrac{1}{(1+\exp(-\beta(x_i+\theta)))^2} & (if\ y_i > thre) \\ \dfrac{1}{1+\exp(-\beta(x_i+\theta))} & (otherwise) \end{cases} \quad (1)$$

この係数 v_i を最初の工程で抽出した色画像の R，G，B 各チャンネルに乗じることで物体に陰をつけ，その後陰をつけた画像で入力色画像 $I_{obj\_}$ のマスク領域を置き換える．

第四の工程では透明物体の曇り，すなわち半透明性を表現する．第三の工程で生成された画像のうちマスク領域について，各画素 i の R，G，B 各チャンネルの画素値 x_i に不透明度 $opacity$ を考慮した式 (2) を適用して，画素値 y_i を得る．

$$y_i = (1 - opacity) \cdot x_i + opacity \cdot 255 \quad (2)$$

第五の工程では光源が画像上方向に存在すると仮定した時の白色光源からの光の反射を表現する．垂直上方向の Sobel フィルタを深度画像 D_{obj_g} に適用し，さらに平滑化を行って光が反射して見える領域を抽出する．物体マスク領域に関して，これにより得られる画像の各画素 i の画素値 x_i にパラメータ $reflect$ を乗じた上で，第四の工程で生成した色画像の R，G，B 各チャンネルの画素値 y_i を加えることで，出力色画像 I_{obj_g} の R，G，B 各チャンネルの画素値 z_i を得る．

2.3.2 敵対的生成ネットワークを用いた人工色画像の変換

色画像生成の第二段階として，CycleGAN [Zhu 17] を用いて色画像 I_{obj_g} を変換し，変換後の色画像 I_{obj_g2} を訓練データセットの色画像として採用する．

本研究では，人工画像ドメインとして透明物体再現アルゴリズムにより生成された色画像 I_{obj_g} から透明物体に注目して切り出した ROI 画像を用いる．一方，実在画像ドメインには実在する透明物体に注目した色画像群 I_{obj+} を用意する．これらを用いて学習したネットワークによって色画像 I_{obj_g} を変換し，物体マスク領域のみを変換された画像で置き換えることで，訓練データセットに用いる色画像 I_{obj_g2} を得る．

以上により得られる色画像 I_{obj_g2}，ラベル画像 L_{obj_g}，深度画像 D_{obj_g} の例を図 2 に示す．



色画像 I_{obj_g2}　ラベル画像 L_{obj_g}　深度画像 D_{obj_g}

図 2: 自動生成されたデータセットの例

3. ラベル画像予測と深度画像予測

生成された学習データセットを用いて，透明物体のラベル画像予測および深度画像予測を行う多層畳みこみネットワーク (CNN) に学習させる．本研究の提案ネットワークは，図 3 に示すようにセンサから取得できる色画像と深度画像の 2 つを入力とし，透明物体のラベル画像と深度画像を出力する．

3.1 ラベル画像予測

本項および次項では，本研究で提案するネットワーク構造について説明する．

ネットワークモデルのうちラベル画像予測を行う部分については，生成された色画像 I_{obj_g2} を入力として学習させ，FCN-8s at-once [Shelhamer 17] を用いてフォワーディングを行う．なお各層の重みやバイアスについては，事前学習された VGG16 モデル [Simonyan 14] を用いて初期化することとする．

最終層の出力 y を用いて計算を行うセグメンテーションに対する損失関数 $Loss_{seg}$ は，式 (3) に示すようにラベル画像 L_{obj_g} を教師信号とする Softmax Cross Entropy を用いる．$I(L_{obj\_g}^{i,\,j})$ は指示関数で，教師ラベル画像の i 番目の画素にラベル $j \in \{0, 1, \cdots, cls-1\}$ が付されていれば 1，それ以外なら 0 を返す．また $y^{i,\,j}$ は最終層の出力 y の i 番目の画素の第

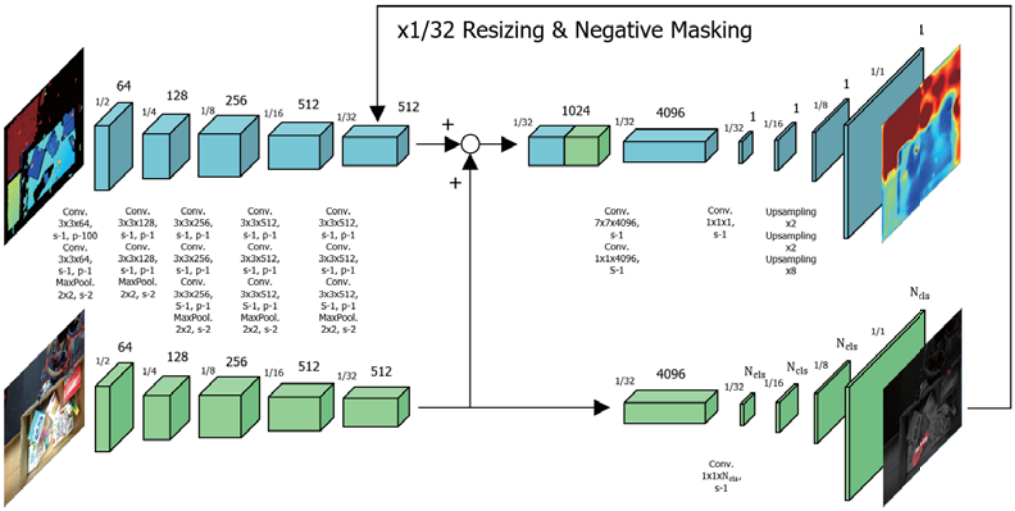


図 3: 提案ネットワークモデル．左上：入力深度画像，左下：入力色画像，右上：出力深度画像，右下：出力ラベル画像

j チャンネルの値を表す．

$$Loss_{seg} = -\frac{1}{n_{pix}} \sum_{i=0}^{n_{pix}-1} \sum_{j=0}^{cls-1} I(L_{obj\_g}^{i,\ j}) \log(Softmax(y^{i,\ j})) \tag{3}$$

3.2 深度画像予測

深度画像予測を行う部分については，生成された色画像 I_{obj_g2} と透明物体の置かれていない深度画像 $D_{obj\_}$ を入力として学習させる．入力深度画像 $D_{obj\_}$ は JET カラーマップを用いて 3 チャンネルの色画像に変換しておく．この画像に畳み込みを行って得られる 512 チャンネルの特徴量画像 $pool5_{depth}$ を得た後に，教師ラベル画像 L_{obj_g}(テスト時は予測ラベル画像 L_{pred}) をこれと同じサイズになるよう 1/32 にリサイズする．そして予測ラベルが 0(背景) の画素のみを残してそれ以外の画素値を 0 とするよう，$pool5_{depth}$ の各チャンネルごとにマスキングを行う．その後，入力色画像に畳み込みおよび最大プーリングを順次施して画像サイズ 1/32 になった段階で最大プーリングを行った後の 512 チャンネル特徴量画像とマスキングされた画像を連結させて，1024 チャンネル特徴量画像を生成し，この特徴量画像から深度画像予測を行う．

深度画像予測の損失関数は，式 (4) に示す画像全領域の損失関数 $Loss_{depth}^{all}$ と，式 (5) に示す教師マスク領域の損失関数 $Loss_{depth}^{mask}$ からなる．D_{pred}^{i} および $D_{obj\_g}^{i}$ はそれぞれ予測深度画像，教師深度画像の i 番目の画素を表す．また M^i は教師ラベルが 1 以上 (透明物体) ならば画素値 1，それ以外 (背景) ならば 0 となる教師マスク画像の i 番目の画素を表す．

$$Loss_{depth}^{all} = \frac{1}{n_{pix}} \sum_{i=0}^{n_{pix}-1} (D_{obj\_g}^{i} - D_{pred}^{i})^2 \tag{4}$$

$$Loss_{depth}^{mask} = \frac{1}{sum(M^i)} \sum_{i=0}^{n_{pix}-1} (D_{obj\_g}^{i} - D_{pred}^{i})^2 M^i \tag{5}$$

3.3 ネットワークの重み更新

ネットワーク全体の損失関数として，式 (6) に示すように損失関数 $Loss_{total}$ を設計する．

$$Loss_{total} = Loss_{seg} + \lambda_1 (Loss_{depth}^{all} + \lambda_2 Loss_{depth}^{mask}) \tag{6}$$

本研究ではパラメータ $\lambda_1 = \lambda_2 = 10$ とする．この損失関数を用いて誤差逆伝播を行い，ネットワークの重みを更新する．ただし，本研究ではラベル予測精度の向上のため，自動生成した主データセットと実環境を二次元アノテーションして用意した少数の副データセットを交互に学習する．副データセットは教師深度画像を持たないので，これの学習時は $\lambda_1 = \lambda_2 = 0$ として深度予測ネットワークの誤差逆伝播を行わないことにする．

深度画像予測ネットワークのマスキング処理に対しては誤差逆伝播を行わないこととするが，特徴量の連結処理については誤差逆伝播を行う．従って，ラベル予測ネットワークでは教師ラベル画像と教師深度画像を用いた特徴量抽出が可能となる．

4. 検証実験

検証実験では，透明物体としてペットボトルを用いる．生成したデータセットおよびネットワークモデルの有用性を検証する実験を行い，さらに透明物体のピッキング実験を行う．

4.1 生成色画像データの検証実験

自動生成した色画像での学習が実環境画像を用いたテスト時にも有効であることを検証する．本検証実験では，主データセット (Main)1610 組，副データセット (Sub)120 組を用意する．これらのデータを既存の FCN-8s at-once [Shelhamer 17] ネットワークモデルに学習させ，実環境画像を三次元アノテーションして用意した 130 組のテストデータに対してラベル画像予測を行った結果を表 1 に示す．なお，ここでは有色と無色を分けて結果を記載している．130 組のテストデータの内訳は，(A) 有色透明物体 22 組，(B) 無色透明物体 108 組となっている．

表 1: FCN-8s at-once による主データセットと副データセットのラベル画像予測結果．(A) 有色透明物体，(B) 無色透明物体．

Dataset	Mean IU		
	(A)	(B)	(A) + (B)
Main	0.582	0.511	0.523
Sub	0.796	0.713	0.727
Main + Sub	0.793	0.673	0.693

表 1 から，有色透明・無色透明のいずれの場合においても，生成した主データセットと少数の副データセットを交互に学習することで，実環境画像である副データセットのみの学習時に近い Mean IU を得られたと言える．

4.2 ラベルと深度を予測するネットワークの検証実験

本研究の提案ネットワークとの比較対象として，色画像からラベル画像を予測する CNN および深度画像とラベル画像から深度画像を予測する CNN の二つを用意する．これら二つのネットワークが予測したラベル画像および深度画像の精度と，本研究の提案ネットワークが予測したラベルおよび深度画像の精度を比較することで評価を行う．比較対象のうち深度予測ネットワークの学習時には提案手法同様にマスキング処理を行うが，特徴量画像の連結処理については行わないこととする．

表 2 に，比較対象の二段階ネットワークと提案ネットワークによるラベル予測の Mean IU と深度画像予測の精度を評価した実験の結果を示す．深度画像予測精度は，ネットワークの出力深度画像のうち教師マスク領域について，教師深度画像との誤差の絶対値が x 未満である画素数の割合を表している．

表 2: 二段階予測ネットワークと提案ネットワークのラベル画像および深度画像予測結果

Network	Mean IU	Depth accuracy ($\|error\| < x$)		
		x = 1cm	x = 2cm	x = 5cm
Staged	0.693	0.264	0.487	0.850
Ours	0.670	0.242	0.454	0.850

表 2 から二段階予測ネットワークを用いても本研究の提案手法を用いても精度に大きな差はないと言える．しかし，二段階予測のうち深度予測ネットワークの学習はラベル予測の学習が終わってからでないと進行できないため，提案ネットワークは二段階予測に比べ学習時間を低減できるという長所がある．

4.3 透明物体の把持への適用実験

最後に，ロボットによる物体把持行動および把持収納行動に対し本研究で提案した深度画像予測システムを適用する実験を行う．透明物体の代表としてペットボトルを家庭用冷蔵庫から取り出すタスクを実現し，5 回中 4 回成功した．また，ペットボトルを含む 5 つの家庭内物体を連続して籠から荷箱へ移し替えるタスクを実現した．図 4 および図 5 にそれぞれペットボトルを取り出している様子，移し替えている様子を示す．



図 4: 冷蔵庫からペットボトルを取り出す様子



図 5: 籠からペットボトルを取り出し，荷箱へ収納する様子

5. 結論

本研究では透明物体のピッキング動作を行うための物体三次元位置推定として，CNN を用いてラベル画像と深度画像を同時に予測し，センサの深度画像のうち透明領域のみを予測された深度画像で置換して出力することを提案した．また学習データを効率的に収集するため，透明物体の三次元メッシュモデルを用いてタスク環境を再現し，さらに光の反射・陰・物体の曇りの再現アルゴリズムと GAN を組み合わせることで，人間による三次元アノテーションの不要なデータセット生成手法を提案した．検証として，透明物体であるペットボトルを家庭用冷蔵庫から取り出す実験を行い，5 回中 4 回成功した．また，ペットボトルを含む 5 つの家庭内物体を連続して籠から荷箱へ移し替える実験を行い，成功した．

透明なショーケースの中にある物体のマニピュレーションには，ショーケースと内部の物体の両方の位置を認識することが必要となる．今後は本研究を応用して，これらの三次元位置推定を実現することを目指す．

参考文献

[Eigen 14] Eigen, D., et al.: Depth Map Prediction from a Single Image using a Multi-Scale Deep Network, in *Advances in Neural Information Processing Systems 27*, pp. 2366–2374, Curran Associates, Inc. (2014)

[Eren 09] Eren, G., et al.: Scanning from heating: 3D shape estimation of transparent objects from local surface heating, *Opt. Express*, Vol. 17, No. 14, pp. 11457–11468 (2009)

[Liu 15] Liu, F., et al.: Deep Convolutional Neural Fields for Depth Estimation From a Single Image, in *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (2015)

[Rantoson 10] Rantoson, R., et al.: 3D reconstruction of transparent objects exploiting surface fluorescence caused by UV irradiation, in *2010 IEEE International Conference on Image Processing*, pp. 2965–2968 (2010)

[Shelhamer 17] Shelhamer, E., et al.: Fully Convolutional Networks for Semantic Segmentation, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 39, No. 4, pp. 640–651 (2017)

[Silberman 12] Silberman, N., et al.: Indoor Segmentation and Support Inference from RGBD Images, in *ECCV* (2012)

[Simonyan 14] Simonyan, K., et al.: Very Deep Convolutional Networks for Large-Scale Image Recognition, *CoRR*, Vol. abs/1409.1556, (2014)

[Wang 15] Wang, P., et al.: Towards Unified Depth and Semantic Prediction From a Single Image, in *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (2015)

[Zhu 17] Zhu, J., et al.: Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks, *CoRR*, Vol. abs/1703.10593, (2017)

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

Recursive BC を用いた超解像顕微鏡の画像推定手法

Image Reconstruction for Super Resolution Microscope Using Recursive Bayesian Computation

木戸 俊輔 *1　鷲尾 隆 *1　和沢　鉄一 *1　永井　健治 *1
Shunsuke Kido　Takashi Washio　Tetsuichi Wazawa　Takeharu Nagai

*1大阪大学 産業科学研究所
The Institute of Scientific and Industrial Research, Osaka University

We propose to apply Recursive Bayesian Computation to image estimation of SPoD-ExPAN microscopy. The method does not need derivatives of the optimality measure and is supposed to derive images globally better than those of gradient dissent based approaches. In this paper, we present an implementation of the Recursive Bayesian Computation by using Kernel density estimation. Moreover, we introduce regularization to the estimation, and experimentally compare its performance with the case without the regularization.

1. はじめに

光の波長よりさらに細かい分解能で物体を観測可能な顕微鏡を超解像顕微鏡と呼ぶ．超解像顕微鏡は幅広い分野での需要を有し，様々な技術が研究されてきた．例として，Stochastic Optical Reconstruction Microscopy（STORM）[1] や Structured Illumination Microscopy（SIM）[2]，Stimulated Emission Depletion Microscopy（STED）[3]，Two Photon Excitation Microscopy（TPE）[4] などが存在する．本研究ではその 1 つである，Super Resolution By Polarization Demodulation - Excitation Polarization Angle Narrowing（SPoD-ExPAN）[5] について取り上げる．SPoD-ExPAN では観測対象に直線偏光を回転照射し，放たれる蛍光を連続して撮影する．撮影される各画像は波長限界によるぼやけやノイズを含み，それらを低減させるため複数枚画像を合成処理し超解像な分子分布画像を得る．従来手法では SPoD-ExPAN の画像推定に勾配法の一種である Fast Iterative Shrinkage-Thresholding Algorithm（FISTA）[6] を用いているが，局所解を推定してしまう可能性がある，微分不可能な条件下で適用できない，という問題を有する．そこで本研究では SPoD-ExPAN の画像推定に，このような問題を補うと考えられる反復ベイズ計算（Recursive Bayesian Computation: Recursive BC）[7] の利用を検討する．また，過学習や推定ノイズの影響を低減させるために正則化推定を行った場合との推定精度の比較検証を行う．

2. 問題設定と Recursive BC の原理

撮影された複数枚の画像を入力 $\boldsymbol{X}$，推定すべき 1 枚の分子分布画像を出力 $\boldsymbol{Y}$ とする．$\boldsymbol{Y}$ の下での $\boldsymbol{X}$ の確率 $P(\boldsymbol{X}|\boldsymbol{Y})$ が，$\boldsymbol{X}$ と $\boldsymbol{Y}$ が決まれば計算可能である時，$\boldsymbol{X}$ に対して尤度 $P(\boldsymbol{X}|\boldsymbol{Y})$ を最大化する $\boldsymbol{Y}$ を推定することで，元の分子分布を推定する．

Recursive BC では，まず確率分布 $P^{(k)}(\boldsymbol{Y}|\boldsymbol{X})$（$k$: 反復回数を表す整数）を次のように定義する．

$$P^{(0)}(\boldsymbol{Y}|\boldsymbol{X}) = P(\boldsymbol{Y}) \tag{1}$$

連絡先: 木戸俊輔，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
kido.lab@ar.sanken.osaka-u.ac.jp

$$P^{(k)}(\boldsymbol{Y}|\boldsymbol{X}) = P(\boldsymbol{X}|\boldsymbol{Y})P^{(k-1)}(\boldsymbol{Y}|\boldsymbol{X}) \tag{2}$$

ここで，$\boldsymbol{Y}$ の事前分布 $P(\boldsymbol{Y})$ は，$\boldsymbol{Y}$ の一様分布とする．定義式より，

$$P^{(k)}(\boldsymbol{Y}|\boldsymbol{X}) = P(\boldsymbol{X}|\boldsymbol{Y})^k P(\boldsymbol{Y}) \tag{3}$$

が導かれる．推定すべき最尤な画像の集合を $\boldsymbol{Y}_T$ と表す時，$\boldsymbol{Y}_T$ に属する任意の画像 $\boldsymbol{y}_T$ と $\boldsymbol{Y}_T$ に属さない任意の $\boldsymbol{Y}$ の画像 $\boldsymbol{y}_N$ に対し，

$$P(\boldsymbol{X}|\boldsymbol{y}_T) > P(\boldsymbol{X}|\boldsymbol{y}_N) \tag{4}$$

が成り立つので，確率分布 $P^{(k)}(\boldsymbol{Y}|\boldsymbol{X})$ に関して，

$$\lim_{k\to\infty} \frac{P^{(k)}(\boldsymbol{y}_N|\boldsymbol{X})}{P^{(k)}(\boldsymbol{y}_T|\boldsymbol{X})} = \lim_{k\to\infty} \frac{P(\boldsymbol{X}|\boldsymbol{y}_N)^k P(\boldsymbol{y}_N)}{P(\boldsymbol{X}|\boldsymbol{y}_T)^k P(\boldsymbol{y}_T)} = 0 \tag{5}$$

となる．つまり，反復回数 k が増えるにつれ，$\boldsymbol{X}$ に対し最尤でない $\boldsymbol{Y}$ の確率は最尤なものと比べ相対的に 0 に収束する．Recursive BC では以上のように，$\boldsymbol{Y}$ の事前分布 $P(\boldsymbol{Y})$ に尤度関数 $P(\boldsymbol{X}|\boldsymbol{Y})$ を反復的にかけ，計算される確率分布 $P^{(k)}(\boldsymbol{Y}|\boldsymbol{X})$ に従って標本 $\boldsymbol{y}$ を生成することで，$\boldsymbol{X}$ に対し最尤な $\boldsymbol{Y}$ を推定する．本手法では，最尤でない $\boldsymbol{Y}$ の確率は全て 0 に収束すると期待されるので局所解に陥りにくく，微分を用いないので微分不可能な条件下でも適用できる．

3. 提案手法

3.1 Recursive BC の実現方法

本研究ではカーネル密度推定 [8] を用いて，$P^{(k-1)}(\boldsymbol{Y}|\boldsymbol{X})$ に従う一定数 N 個の標本 $\boldsymbol{y}_i^{(k-1)}$ $(i = 1, 2, \cdots, N)$ が与えられたとき，各標本 $\boldsymbol{y}_i^{(k-1)}$ に $P(\boldsymbol{X}|\boldsymbol{y}_i^{(k-1)})$ に従う尤度をかけて平滑化する事で $P^{(k)}(\boldsymbol{Y}|\boldsymbol{X})$ を計算する．h を平滑化パラメータ，K を多次元正規分布 $N(0, h^2)$ であるカーネル関数とし，$P^{(k)}(\boldsymbol{Y}|\boldsymbol{X})$ を次式，

$$P^{(k)}(\boldsymbol{Y}|\boldsymbol{X}) = \sum_{i=1}^{N} \frac{P(\boldsymbol{X}|\boldsymbol{y}_i^{(k-1)})}{\sum_{i=1}^{N} P(\boldsymbol{X}|\boldsymbol{y}_i^{(k-1)})} K\left(\frac{\boldsymbol{Y} - \boldsymbol{y}_i^{(k-1)}}{h}\right) \tag{6}$$

を用いて計算する．なお，分母項 $\sum_{i=1}^{N} P(\boldsymbol{X}|\boldsymbol{y}_i^{(k-1)})$ は全確率を 1 に規格化するためのものである．

さて，（6）式で計算される確率分布 $P^{(k)}(\boldsymbol{Y}|\boldsymbol{X})$ は平均を $\boldsymbol{y}_i^{(k-1)}$ とする多次元正規分布の重み付き足し合わせである．こ

れより，「確率分布 $P^{(k)}(\boldsymbol{Y}|\boldsymbol{X})$ に従う標本 $\boldsymbol{y}_i^{(k)}$ を抽出する」ことと「尤度 $P(\boldsymbol{X}|\boldsymbol{y}_i^{(k-1)})$ の大きさに従って標本 $\boldsymbol{y}_i^{(k-1)}$ を確率的に選択し，それに平均 0，分散 h^2 の多次元正規分布に従って生成されるノイズを加えることで標本 $\boldsymbol{y}_i^{(k)}$ とする」ことは等価である．後者の原理で標本抽出を行うために次のような手順をとる．

まず，標本 $\boldsymbol{y}_1^{(k-1)}$ から標本 $\boldsymbol{y}_j^{(k-1)}$ $(j = 1, 2, \cdots, N)$ までの尤度 $P(\boldsymbol{X}|\boldsymbol{y}_i)$ の和を規格化したものを累積確率 $S_j^{(k-1)}(\boldsymbol{X})$，

$$S_j^{(k-1)}(\boldsymbol{X}) = \sum_{i=1}^{j} \frac{P(\boldsymbol{X}|\boldsymbol{y}_i^{(k-1)})}{\sum_{i=1}^{N} P(\boldsymbol{X}|\boldsymbol{y}_i^{(k-1)})} \tag{7}$$

とおく．0 から 1 の一様乱数 r を生成し，

$$S_{j-1}^{(k-1)}(\boldsymbol{X}) \leq r \leq S_j^{(k-1)}(\boldsymbol{X}) \tag{8}$$

の条件を満たす整数 j を j' とおく．標本 $\boldsymbol{y}_{j'}^{(k-1)}$ に，平均 0，分散 h^2 の多次元正規分布 $N(0, h^2)$ に従って生成されるノイズ $\boldsymbol{\varepsilon}$ $(\sim N(0, h^2))$ を加えることで，次ステップの標本 $\boldsymbol{y}_i^{(k)}$ とする．

$$\boldsymbol{y}_i^{(k)} = \boldsymbol{y}_{j'}^{(k-1)} + \boldsymbol{\varepsilon} \tag{9}$$

以上のような手順を N 回行うことにより，$P^{(k-1)}(\boldsymbol{Y}|\boldsymbol{X})$ に従う N 個の標本 $\boldsymbol{y}_i^{(k-1)}$ から，$P^{(k)}(\boldsymbol{Y}|\boldsymbol{X})$ に従う N 個の標本 $\boldsymbol{y}_i^{(k)}$ を生成する．

標本生成を繰り返し行うことで，Recursive BC の原理より，生成される標本 $\boldsymbol{y}_i^{(k)}$ は最尤な出力 $\boldsymbol{Y}$ に収束していくことが期待される．

3.2 正則化推定

過学習や推定ノイズの影響を低減させるために，Recursive BC を用いた画像推定に正則化を導入する．正則化推定を行う場合は，条件付き確率 $P(\boldsymbol{X}|\boldsymbol{Y})$ を最大化する $\boldsymbol{Y}$ を推定する代わりに，

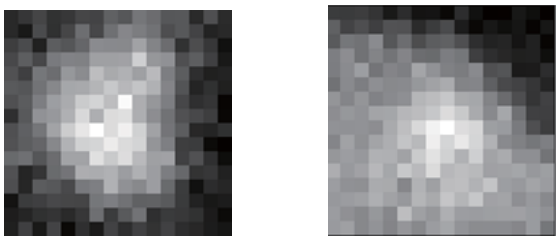
$$P_R(\boldsymbol{X}|\boldsymbol{Y}) = P(\boldsymbol{X}|\boldsymbol{Y}) \times e^{-\lambda\ ||\boldsymbol{Y}||_{L1}} \tag{10}$$

で計算される $P_R(\boldsymbol{X}|\boldsymbol{Y})$ を最大化の目的関数とする．なお，λ は正則化パラメータである．

4. 評価実験

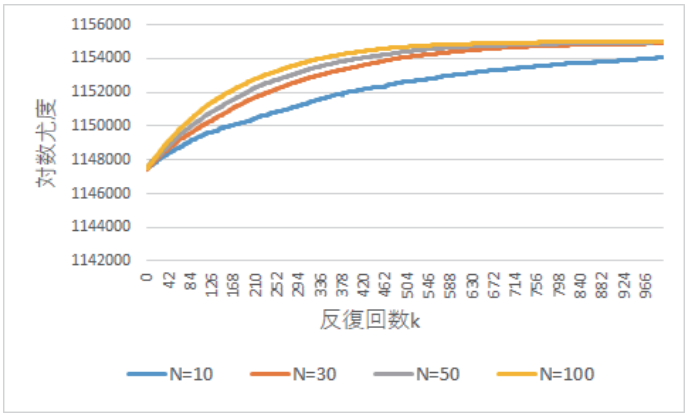
4.1 実験概要

SPoD-ExPAN で撮影されたテスト画像を入力として，分子分布画像を提案手法を用いて推定した．テスト画像は互いに形状が大きく異ると思われる 16×16 ピクセルの画像を図 1 のように 2 ケース用意した．ケース 1 の画像は蛍光が中心部に集まった形状，ケース 2 の画像は右上領域をのぞいて広域に蛍光が分布しているような形状である．正則化パラメータ λ の値は従来研究で知られている適切な値 $\lambda = 0.5$ を用い，まず，正則化なしとありの場合で，k に対する尤度の収束性がよい最小の標本数 N を調査した．次に，その結果を踏まえ，正則化なしとありの場合で Recursive BC を用いて分子分布の推定を行い，さらに，従来手法で推定された画像を手本に，各条件で推定した画像と手本画像とのピクセル毎の二乗誤差の平均 MSE を計算した．ピクセル位置を $\boldsymbol{r} = [(1,1), \cdots, (16,16)]$ を用いて表し，手本とする画像を $g(\boldsymbol{r})$，本手法で推定された画像を $\hat{g}(\boldsymbol{r})$ とすると，MSE は以下式，

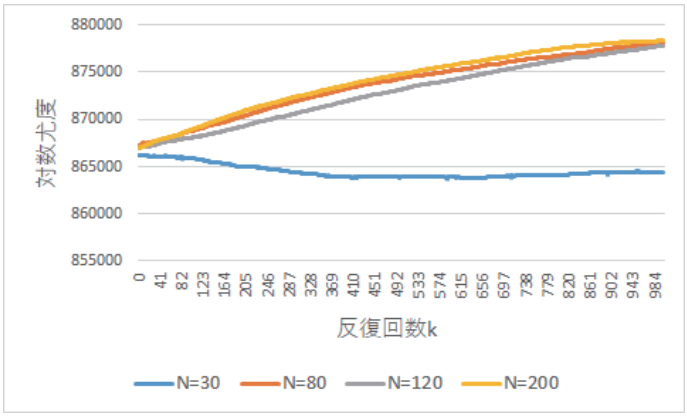


(a) ケース 1　　(b) ケース 2

図 1: 入力画像



正則化なしの場合



正則化ありの場合

図 2: 反復回数に対する対数尤度遷移

$$MSE = \frac{1}{16 \times 16} \sum_{\boldsymbol{r}=(1,1)}^{(16,16)} (g(\boldsymbol{r}) - \hat{g}(\boldsymbol{r}))^2 \tag{11}$$

で計算される．

4.2 標本数の調査

ケース 1 を用いて，Recursive BC の反復計算の収束に必要なおおよその標本数 N を評価した．正則化を導入しないものと導入するもの双方について，撮影画像 $\boldsymbol{X}$ から計算される推定画像 $\boldsymbol{Y}$ の尤度 $P(\boldsymbol{X}|\boldsymbol{Y})$，$P_R(\boldsymbol{X}|\boldsymbol{Y})$ の自然対数値の遷移から，標本数 N の評価を行った．正則化なしの場合は $N = [10, 30, 50, 100]$ に対して，正則化ありの場合は $N = [30, 80, 120, 200]$ に対して，両条件とも $k = 1000$ までで実験を行った．

図 2 に示される結果より，正則化なしの場合では N が 30 以上の時，正則化ありの場合では N が 80 以上の時に，尤度の収束性が良いと言える．そこで，推定される画像 $\boldsymbol{Y}$ を入力 $\boldsymbol{X}$ に対し効率的に最尤な値へと収束させるために，標本数の余裕と計算時間の抑制も考慮して，$N = 120$ を本実験で用いる標本数とする．

4.3 推定精度比較

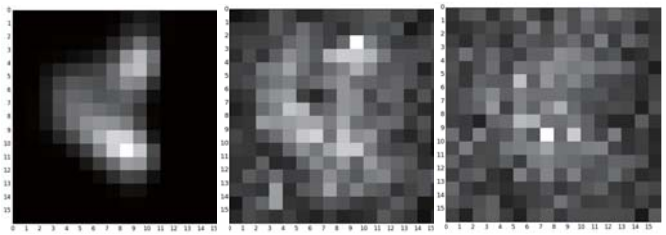
1 ケース目のテスト画像を入力として推定を行った結果を図 3，図 4 に，2 ケース目の結果を図 5，図 6 に示す．図 3，図 5 は左から順に，従来手法で推定された手本画像，Recursive BC を用いて正則化なしの推定を行った場合の推定画像，さらにそれに正則化を行い推定した場合の推定画像である．また，図 4，図 6 に示すグラフは上から順に，k に対する MSE の遷移，撮影画像 $\boldsymbol{X}$ から計算される推定画像 Y の対数尤度 $P(\boldsymbol{X}|\boldsymbol{Y})$，$P_R(\boldsymbol{X}|\boldsymbol{Y})$ の変化を表す．なお，反復試行は 100000 回行った．

図 3，図 5 に見られるように，両ケースとも十分には手本画像を推定できておらず，図 4 -(a) や図 6 -(a) のように正則化なしとありの場合とでも，MSE に見た推定精度に現状大きな差は見られない．しかし，図 4 -(b)(c)，図 6 -(b)(c) から読み取れるように，正則化なしの場合は尤度がほぼ一定の値に収束しているのに対し，正則化ありの場合では尤度がさらに上昇するような傾向がみられた．従って，正則化推定では反復試行をさらに行うことで，より尤度の高い推定ができる可能性がある．

さらに，各条件下での全所要計算時間と全反復ステップ k に亘る推定誤差 MSE の最小値を表 1 に示す．なお，3．2 節で述べたように正則化なしとありの場合とで最大化する尤度関数 $P(\boldsymbol{X}|\boldsymbol{Y})$，$P_R(\boldsymbol{X}|\boldsymbol{Y})$ が大きく異なるので，対数尤度遷移の比較は示さない．表より，推定に必要な計算時間はどのケースにおいても大きい．正則化推定では反復回数を増やすことでより尤度の高い出力を推定できると述べたが，100000 回を超えた反復試行にかかる計算時間はさらに莫大となることが予想されるので，計算時間をより低減させた計算原理やアルゴリズムが求められる．

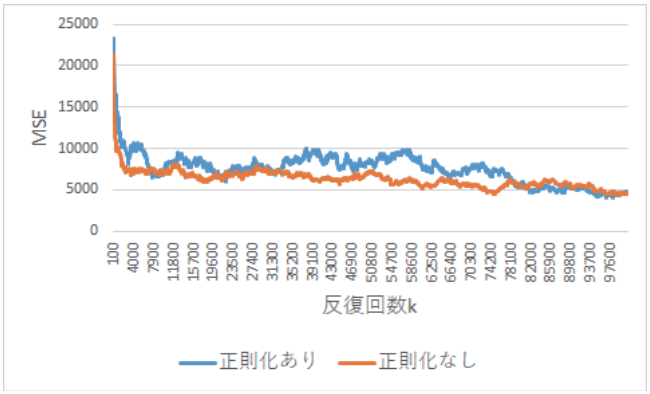
5. まとめ

本研究では SPoD-ExPAN 超解像顕微鏡の画像推定に，従来の手法の欠点を補うと考えられる推定手法 Recursive BC を導入した．さらに，過学習やノイズの影響を低減させるため正則化を行い，推定精度の比較検証を行った．今後解決すべき問題としては，計算時間の削減や推定精度の向上が挙げられる．

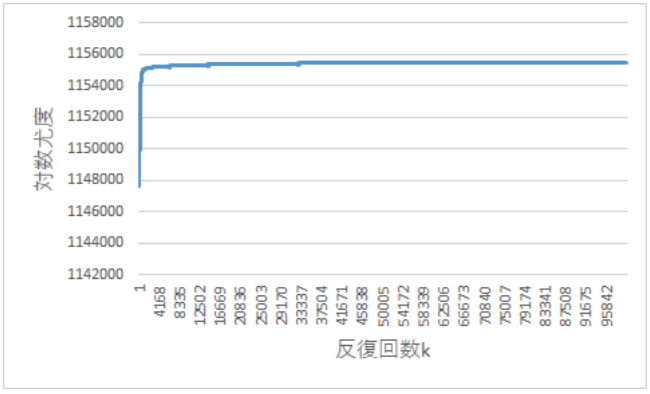


(a) 手本画像　(b) 正則化なし画像　(c) 正則化あり画像

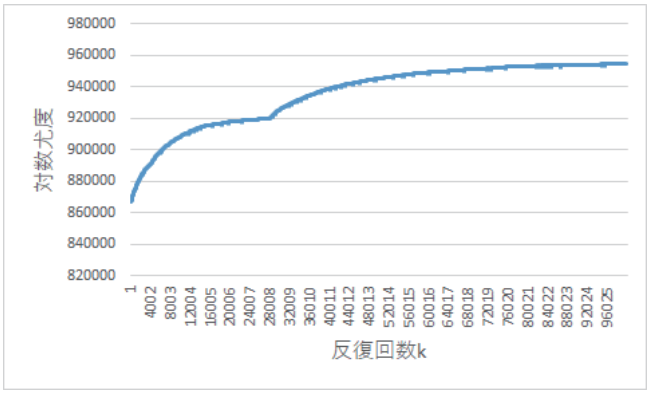
図 3: ケース 1 推定画像



(a)MSE 遷移

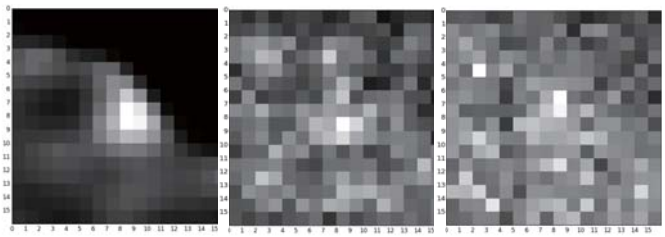


(b) 正則化なし対数尤度遷移



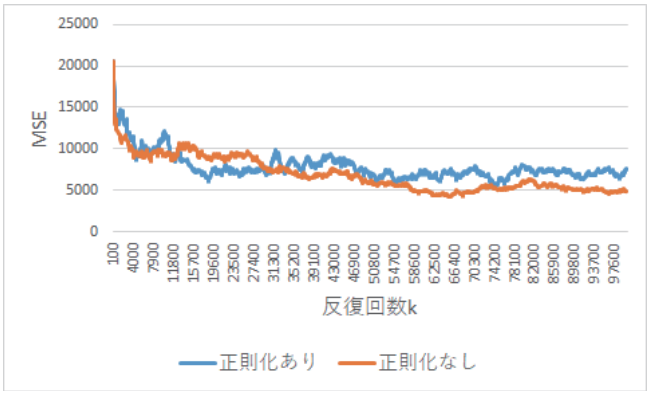
(c) 正則化あり対数尤度遷移

図 4: ケース 1 における MSE 遷移と対数尤度遷移

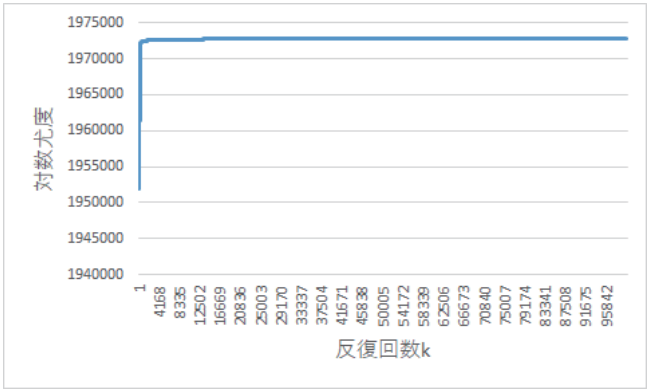


(a) 手本画像　(b) 正則化なし画像　(c) 正則化あり画像

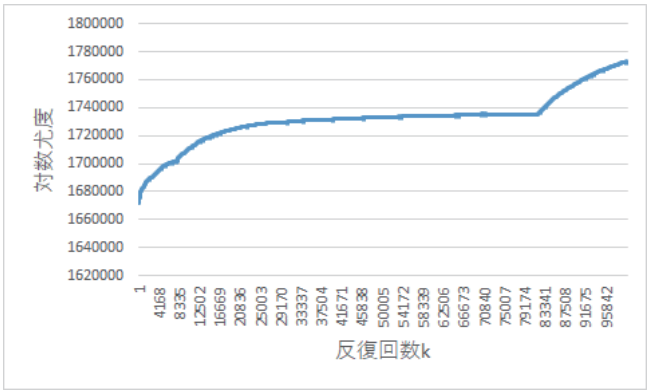
図 5: ケース 2 推定画像



(a)MSE 遷移



(b) 正則化なし対数尤度遷移



(c) 正則化あり対数尤度遷移

図 6: ケース 2 における MSE 遷移と対数尤度遷移

表 1: 計算時間と推定誤差

	所要計算時間（s）	MSE 最小値
ケース 1（正則化なし）	833985.82	4332.626
ケース 1（正則化あり）	584655.14	4172.619
ケース 2（正則化なし）	835626.05	5241.061
ケース 2（正則化あり）	592821.13	5529.234

参考文献

[1] Adish Dani, Bo Huang, Joseph Bergan, Catherine Dulac, Xiaowei Zhuang . Superresolution Imaging of Chemical Synapses in the Brain . Neuron . Volume.68, Issue.5 . 9 December 2010 . Pages 843-856

[2] Dejan Karadagli, Tony Wilson . Image formation in structured illumination wide-field fluorescence microscopy . Micron . Volume.39, Issue.7 . October 2008 . Pages 808-818

[3] Stefan W Hell, Jan Wichmann . Breaking the diffraction resolution limit by stimulated emission: stimulated-emission-depletion fluorescence microscopy . OPTICS LETTERS . Vol.19, No.11 . 1 June 1994

[4] Richard K P Benninger, David W Piston . Two Photon Excitation Microscopy for the Study of Living Cells and Tissues . Current Protocols in Cell Biology. Unit 4.11 . June 2013

[5] Nour Hafi, Matthias Grunwald, Laura S van den Heuvel, Timo Aspelmeier, Jian-Hua Chen, Marta Zagrebelsky, Ole M Schtte, Claudia Steinem, Martin Korte, Axel Munk, Peter J Walla . Fluorescence nanoscopy by polarization modulation and polarization angle narrowing . NATURE METHODS, vol.11, NO.5 . MAY 2014

[6] Amir Beck, Marc Teboulle . A Fast Iterative Shrinkage-Thresholding Algorithm for Linear Inverse Problems . SIAM Journal on Imaging Sciences, Vol.2, Issue 1 . 2009 . Pages 183202

[7] Subhash R LELE, Khurram NADEEM, Byron SCHMULAND . Estimability and Likelihood Inference for Generalized Linear Mixed Models Using Data Cloning . Journal of the American Statistical Association . December 2010

[8] Christopher M Bishop . PATTERN RECOGNITION AND MACHINE LEARNING . Springer . 2009 . Pages 122-124

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

時空間オブジェクトの混合分布によるモデリングと追跡

-greedy EM 法に基づく発生・消滅を考慮した追跡手法の検討 -

Examination of object tracking method for space-temporal data based on greedy EM algorithm

林 諒[*1]
Ryo Hayashi

本田 理恵[*1]
Rie Honda

[*1] 高知大学
Kochi University

Extracting objects such as clouds in weather images in the spatiotemporal data and tracing the changes of the shape, the position, the interaction between objects and events such as generation, extinction are important tasks in spatio-temporal data mining. The method of object extraction and tracking using mixture of multivariate normal distribution applying greedy EM algorithm is proposed. Experiments using artificial data showed effectiveness of the proposed method.

1. はじめに

地球観測衛星や気象レーダなどの時空間データのリアルタイム収集やアーカイブ化が進んでいる. 具体的な例には, 気象衛星ひまわり 8 号の取得画像や, 3次元フェーズドアレイレーダデータによる降水コア発生のモニタリングなどがある. このようなデータから時空間変動のパターンを抽出することができれば, 関連のある自然現象のメカニズムの理解や, 極端な事象の発現の予測を予測に活用する事ができる.

我々は, 気象画像やレーダ画像などの時系列2次元, 3次元データから, 気象画像における雲やレーダデータの降水コア(反射強度の高い部分)のような, 周囲とは異なる特徴をもつ不定形の領域をオブジェクトとして抽出し, 発生, 成長, 吸収, 分裂, 消滅などのオブジェクトの変遷を記載することで時空間変動のパターンを記載することを検討してきた[Matsunaga 2015] [Hayashi 2017]. 特に, オブジェクトの抽出には多変量正規分布の混合分布によるモデリングに基づく手法を検討してきたが, 時間断面で取り出したオブジェクトの時間方向への連結については, 前の時間の初期値を次の時間の初期値とするとともに, 解の削除や2重化を行う事によって, 出現や消滅を扱う手法を提案してきた. しかし, 実際には, 分裂と出現の区別がつかない, オブジェクトの識別ラベルが入れ替わる, といった事象が起こっており, オブジェクトの追跡や, 発生, 吸収, 分裂, 消滅などの変遷を正しくに把握する事には問題が残っていた.

本研究では, 逐次的に成分を追加する greedy EM アルゴリズムを改良して取り入れることによって, オブジェクトの識別の精度を向上させる手法について検討する. また人工データを用いたその効果についての予備的な実験結果について報告する.

2. 手法

2.1 多変量正規分布の混合分布と EM アルゴリズムによるオブジェクトモデリング

まず基本的なモデリング手法について概観する. 対象とする2次元, 3次元データ中に, 観測点が存在し, その分布が多変量正規分布の混合分布で表現できるものとする. 簡単のため画像等の場合は閾値処理によって, 閾値をこえた座標をもとめ, 輝度値そのものはここでは使用しないものとする. このように塊状に分布する M 次元のデータ集合 X の塊をオブジェクトとして表現する事を考える.

$$\boldsymbol{X} = \{\boldsymbol{x}_i \in R^M \mid i = 1,2,3,\cdots,n\} \tag{1}$$

ここでデータ$\boldsymbol{x}$を観測する確率密度分布が下記の通りの 1 つのオブジェクトの存在を表す多変量正規分布でモデル化できるものとする.

$$\phi(\boldsymbol{x}|\boldsymbol{\mu}, S) = \frac{1}{(\sqrt{2\pi})^M \sqrt{|\boldsymbol{S}|}} \exp\left\{-\frac{1}{2}(\boldsymbol{x}-\boldsymbol{\mu})^T \boldsymbol{S}^{-1}(\boldsymbol{x}-\boldsymbol{\mu})\right\} \tag{2}$$

$\boldsymbol{\mu} \in \boldsymbol{R}^M$ は多変量正規分布の中心ベクトル(平均値), $\boldsymbol{S}$は $M \times M$の分散共分散行列とする. $\boldsymbol{\mu}$はオブジェクトの中心, $\boldsymbol{S}$はオブジェクトの広がりを表す. 複数のオブジェクトが存在する時, 座標$\boldsymbol{x}$においてオブジェクトを観測する確率密度分布は複数成分からなる多変量正規分布の重み付きの平均で表される.

$$\boldsymbol{f_K}(\boldsymbol{x}) = \sum \omega_j \, p(\boldsymbol{x}|\ \boldsymbol{\mu_j}, \boldsymbol{S_j}) \tag{3}$$

ω_jは重み係数($\sum_{j=1}^{K} \omega_j = 1$), Kは成分数を表す. パラメータを以下の通りまとめるものとする.

$$\boldsymbol{\theta} = \{(\boldsymbol{\mu_j}, \boldsymbol{S}_j, \omega_j) \mid j = 1, \ldots . K\} \tag{4}$$

ここで観測値$\boldsymbol{X}$はどの多変量正規分布から発生したものかを知ることができないいわゆる不完全データであり, 最尤推定などの手法で直接パラメータを求めることができない. よって, EM (Expectation and Maximization)アルゴリズム[Dempster 1997]でパラメータを求める. EM アルゴリズムは, 仮に与えたパラメータ$\boldsymbol{\theta}$からモデルを計算し, さらにモデルの対数尤度を増加させるような新しいパラメータ$\boldsymbol{\theta'}$を推定するという操作を繰り返すことによって対数尤度$\boldsymbol{L(\theta)}$を最大化するパラメータ$\boldsymbol{\theta'}$を求めるものである.

連絡先:林諒, 高知大学総合人間自然科学科研究科, 高知県高知市曙町 2-5-1, rhayashi@is.kochi-u.ac.jp

$$L(\boldsymbol{\theta}) = \log\left(\prod_{i=1}^{n} P(\boldsymbol{x}_i|\boldsymbol{\theta})\right) \tag{5}$$

$$\boldsymbol{\theta}' = \underset{\boldsymbol{\theta}}{\operatorname{argmax}}\, L(\boldsymbol{\theta}) \tag{6}$$

EMアルゴリズムによるパラメータの計算手順を示す．E ステップで寄与率を推定し，これをもとに M ステップで対数尤度を最大化するパラメータを推定し，この値を用いて寄与率を推定するというプロセスを収束するまで続ける．ここで寄与率$z(i,j)$は，観測値$\boldsymbol{x}_i$がj番目の多変量正規分布（オブジェクト）から発生したことを示す推定量である．

1. $\boldsymbol{\theta} = \{(\boldsymbol{\mu}_j, S_j, \omega_j)|j = 1,2,\cdots,K\}$に初期値を与える．

2. E-Step：寄与率$z(i,j)$を計算する．このとき変化$z(i,j) - z'(i,j)$ が小さければ終了．そうでない場合 3 を実行する．

$$z'(i,j) = \frac{\omega_j p(\boldsymbol{x}_i|\ \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)}{\sum_{k=1}^{\mathrm{K}} \omega_k p(\boldsymbol{x}_i|\ \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)} \tag{7}$$

3. M-Step：対数尤度を最大化させるようモデルパラメータを更新し，$z(i,j) \leftarrow z'(i,j)$として2 に戻る．

$$\omega_j{}' = \frac{\sum_{i=1}^{n} z'(i,j)}{n} \tag{8}$$

$$\boldsymbol{\mu}_j{}' = \frac{\sum_{i=1}^{n} z'(i,j)\,\boldsymbol{x}_i}{\sum_{i=1}^{n} z'(i,j)} \tag{9}$$

$$\boldsymbol{S}_j{}' = \frac{\sum_{i=1}^{n} z'(i,j)\,(\boldsymbol{x}_i - \boldsymbol{\mu}_j)(\boldsymbol{x}_i - \boldsymbol{\mu}_j)^T}{\sum_{i=1}^{n} z'(i,j)} \tag{10}$$

なお成分数Kについては総当たりで上記の手法でもとめたモデルパラメータに対してベイズの情報量基準(BIC) [Schwarz 1978]を用いて，最適な(すなわちこれを最小化する)Kを求める．Fは自由度である．

$$\mathrm{BIC} = -2nL(\boldsymbol{\theta}) + F\log n \tag{11}$$

2.2 先行研究での成分の追跡手法

2.1 の手法で求めたモデリングの結果を次の時間のモデリングに継承し，かつ計算時間を削減するため，先行研究[Matsunaga 2015] [Hayashi 2017]では以下のような手法を使用した．

(1) 前の時刻 t の解，$\boldsymbol{\theta}_t = \{(\boldsymbol{\mu}_{j,t}, \boldsymbol{\Sigma}_{j,t}, \omega_{j,t} l_j)|\, j = 1, \ldots. K\}$を$\omega_{j,t}$値順にソートしたものを

$$\boldsymbol{\theta}_{t+1,K} = \{(\boldsymbol{\mu}_{j,t+1}, \boldsymbol{\Sigma}_{j,t+1}, \omega_{j,t+1}, l_{j,t+1})|\, j = 1, \ldots. K\}$$

とする．ここで成分の追跡のためモデルパラメータにラベルl_jを追加している．

(2) 次の時間の初期値は以下のものとする

$$\boldsymbol{\theta}_{t+1,K-N}, \ldots\ldots, \boldsymbol{\theta}_{t+1,K-1}, \boldsymbol{\theta}_{t+1,K}, \boldsymbol{\theta}_{t+1,K}, \ldots\ldots$$

ここで$\boldsymbol{\theta}_{t+1,K-k}$は重み係数の小さい順に解候補を消去したもの$\boldsymbol{\theta}_{t+1,K-k} = \{(\boldsymbol{\mu}_{j,t+1}, \boldsymbol{\Sigma}_{j,t+1}, \omega_{j,t+1}, l_{j,t+1})|\, j = \mathrm{k}, \ldots. K\}$とする．一方$\boldsymbol{\theta}_{t+1,K+k}$は重み係数の大きい順に解を複製して，新たに発生する解を扱えるようにしたもので，$\boldsymbol{\theta}_{t+1,K+k} = [\{\boldsymbol{\theta}_{t+1,K+k}, \{(\boldsymbol{\mu}_{j,t+1}, \boldsymbol{S}_{j,t+1}, \omega_{j,t+1}, l_{j,t+1})|\, j = \mathrm{K} - \mathrm{k}, \ldots. K\}$で表されるものとする．

(3) これらの初期値候補について EM アルゴリズムによりモデルパラメータを求め，BIC を最小にするものを選択する．

この手法を実際に気象画像等に適用すると，初期値が不適当でも EM アルゴリズムによるパラメータ決定の過程で柔軟に解の乗り換えを起こして，もっともらしいモデルを成分数の増減にも対応しながら求める事ができることを実験より確認している．しかし，特にオブジェクトの追跡に着目すると以下の問題点がある．

A) 分裂が重みの大きいもので起こることを前提としているが必ずしも正しいとは限らない
B) 消滅が重みの小さいもので起こることを前提としているが必ずしも正しいとは限らない
C) A), B)の理由により，同一の成分を同じラベルで追跡する事ができない可能性がある
D) 新規発生と分裂を識別する事ができない
E) 消滅と吸収を識別することができない

特に A), B), C)の問題により，ラベル付けによって，追跡，発生，消滅，分裂，吸収等のオブジェクト間の相互作用を把握する事は困難である．本研究ではまず B), C)の問題を解決することを目的として，新規発生，消滅に対応した初期値設定に greedy EM アルゴリズムの考えを採用した手法を提案する．

2.3 greedy EM アルゴリズム

greedy EM アルゴリズム【Nikos 2002】は Nikos らによって提案された逐次的に成分を追加することによって多変量正規分布の混合分布を学習するために開発された手法である．greedy EM アルゴリズムでは，K 成分からなる混合分布$f_K(x)$に対して成分$\emptyset(\boldsymbol{x}|\boldsymbol{\mu}, \Sigma)$を追加した$f_{K+1}(x)$は以下の式で表されるものとする．

$$f_{K+1}(x) = (1-\alpha) f_K(x) + \alpha\emptyset(\boldsymbol{x}|\boldsymbol{\mu}, S) \tag{12}$$

ここでαは 0 から1の範囲の実数である．αと$\boldsymbol{\mu}, S$は新しい対数尤度L_{K+1}を最大化するように決定される．

$$\begin{aligned} L_{K+1} &= \sum_{i=1}^{n} log\, f_{K+1}(\boldsymbol{x}_i) \\ &= \sum_{i=1}^{n} log[(1-\alpha) f_K(\boldsymbol{x}_i) + \alpha\emptyset(\boldsymbol{x}_i|\boldsymbol{\mu}, S)] \end{aligned} \tag{13}$$

この手法では本来はまず成分数 K=1 からスタートして，仮のパラメータを求めて，ここから1成分ずつ追加しながらパラメータを決定していく．次の成分に進む際には，すべてのデータ$\boldsymbol{x}_i$について，L_{K+1}のローカルな推測値を最大化する点を見つけ，これを新しい成分の重心$\boldsymbol{\mu}$として，部分的な EM アルゴリズムを実行し，$L_{K+1} \leq L_K$となるまで，成分の追加を繰り返す．

この手法を，生成消滅しながら時間変化する多変量正規分布の混合モデルに適用するには，$f_K(x)$を前の時刻の解として，次の時刻に発生した新規成分$\emptyset(\boldsymbol{x}|\boldsymbol{\mu}, \Sigma)$を追加する過程をおなじフレームワークで使用することが可能であることが予想できる．

2.4 時間変化する成分の追跡への対応

ここでは時間とともに生成・消滅する多変量正規分布の追跡に逐次的に成分を追加する greedy EM アルゴリズムを適用する際の変更点について述べる. 大まかには, 前の時間の解を既存の成分のパラメータとして仮置きして, greedy EM による成分数の増加の処理を行い, その後, 不要になった成分を除去するというアプローチをとる.

(1) 成分増加時の処理

本来の greedy EM アルゴリズムでは, 成分追加時に既存の成分のパラメータも決定し直すが, これによって解の乗り移りなどが発生して追跡が困難になることが予想される. よって既存の成分で一旦決定されたパラメータは, 適切な成分数の追加が終わるまで変化させないものとする. また, 成分数増加の判定では greedy EM では尤度を用いていたが, 成分数が異なって自由度が異なるため, 評価指標は BIC に変更する.

(2) 成分削減時の処理

次に消滅等によって不要になった成分を削除する. 各成分を順番に削除して尤度が最大になる成分を削除候補成分とする. 成分を削除した後に EM アルゴリズムを実行し, その後 BIC による判定を行う.

(3) 増加・削減をまとめた一連の処理

全体の手順を図 1 に示す. 手順 2 の成分増加と手順 3 の成分削減処理の間に手順 3 として EM アルゴリズムによる全パラメータ調整を追加している. これは, greedy EM 中のパラメータの修正を追跡のために意図的に行っていないためである.

1 前の時間の解の k 成分のパラメータを用いて初期化
2 発生した成分の追加
  2.1 すべてのデータ点$\boldsymbol{x}_i$を探索し, この値を新たな成分の平均$\boldsymbol{\mu}$として追加した時に尤度を最大化するデータ点$\boldsymbol{x}_i$を$\boldsymbol{\mu}$に設定
  2.2 S,$\hat{a}$を初期化.
  2.3 $|L_{k+1}^n/L_{k+1}-1| \leq (10^{-6})$を収束条件として EM アルゴリズムにより追加パラメータを推定
  2.4 $\mathrm{BIC}_{k+1} \leq \mathrm{BIC}_k$の場合は追加せずに終了, そうでない場合は追加のうえ 2. 1 へ戻る
3 すべてのパラメータに対して EM アルゴリズムでパラメータを決定し直す.
4 消滅した成分の除去
  4.1 すべての成分を探索し, 成分削減時に尤度を最大化する成分を選択
  4.2 $|L_{k+1}^n/L_{k+1}-1| \leq (10^{-6})$を収束条件として EM アルゴリズムにより全パラメータ推定
  4.3 $\mathrm{BIC}_{k+1} \leq \mathrm{BIC}_k$の場合は削除せず終了, そうでない場合は当該成分を削除して, 4.1 へ戻る

図 1 Greedy EM を応用した時間変化する多変量正規分布の混合モデルのパラメータ導出アルゴリズム

3. 実験

この追跡アルゴリズムの精度検証のために 2 次元の人工データを用いた 2 種類の検証実験を行った. 実験内容は(1)時間移動による追跡性能の評価, (2)時間経過中に起こる新規発生, 消滅等のイベントを適切にとらえられるかの検証を行った.

図 2 に (2)の実験結果の一例を示す. 図中の青十字がデータ点で, 3 から 5 程度の成分が時間とともに移動しながら, 新規発生, 消滅などを起こしている. 本研究の手法によって求められた成分の平均, 標準偏差がそれぞれ赤丸, 青い円で, 各成分につけられた数字は成分のラベルを表す. 求められた成分は概ね画像中の成分の移動を正しく追跡しながらモデリングし, 新規発生, 消滅の際のラベル付にも対応していることが観察できる. また, 時間 6 では発生と消滅の両方を正しく補足することができている. しかし時間 4 では本来 2 つになるべき成分を 1 つの成分(5)として捉えてしまっている. この問題に関しては, 本研究では対象外としているが観測値の強度による重み付け【Hayashi 2017】を用いることで改善できると考えられる. その他詳細な実験結果に基づいた効果と問題に対する対策の考察については発表で述べる.

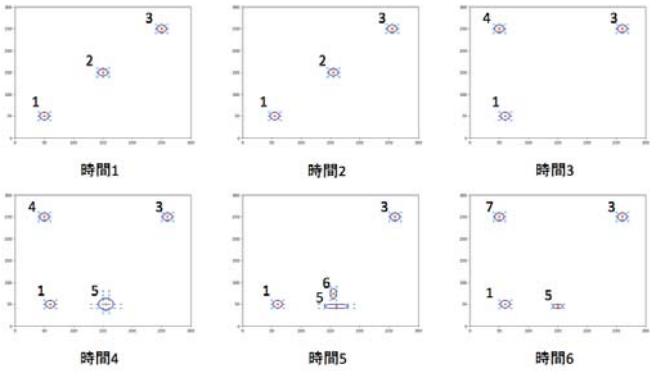


図 2. 実験による成分の移動, 発生, 消滅の補足の検証結果. 青十字がデータ点, 求められた成分の平均, 標準偏差がそれぞれ赤丸, 青い円が分散, 各成分につけられた数字は成分のラベルを表す.

4. おわりに

greedy EM アルゴリズムの考えをオブジェクトの時間追跡に応用することによって, 発生, 消滅しながら時間変化するオブジェクトの追跡の精度を高める手法を考案した. また人工的データに対して予備実験を行い, その効果を確認した. 今後はさらに残された"発生と分裂", "消滅と吸収"の識別法についての検討をすすめて, フェーズドアレイレーダデータや気象画像の実画像についての検討を進める予定である.

謝辞

本研究は科研費 17K00158 補助により進められました. ここにお礼申し上げます.

参考文献

[Matsunaga 2015] 松永知也: 時系列画像からのオブジェクトデータベースマイニング-オブジェクト抽出とデータベース化-, DEIM2015,2015

[Hayashi 2017] 林諒:時系列 3 次元グリッドデータからのホットスポットの自動抽出・追跡法の開発-フェーズドアレイ気象レーダデータによる局地的大雨解析への適用-, DEIM2017,2017

[Dempster 1997] A. P. Dempster et al., Maximum Likelihood from Imcomplete Data via EM Algorithm, Journal of the Royal Statistical Society, series B, vol. 39, no. 1,1-38, 1977.

[Schwarz 1978] Schwarz, G., Estimating the dimension of a model, Annals of Statistics 6, 461-464, 1978

[Nikos 2002] Nikos Vlassis: A Greedy EM Algorithm for Gaussian Mixture Learning, Neural Processing Letters 15, Kluwer Academic Publishers , 2002.

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

確率分布を用いた画像テキストデータの埋め込みと検索

Embedding and retrieval of images and text data using probability distribution

濱 健太 *1　松原 崇 *1　上原 邦昭 *1
Kenta Hama　Takashi Matsubara　Kuniaki Uehara

*1 神戸大学 大学院システム情報学研究科計算科学専攻
Graduate School of System Infomatics, Kobe University

Multimodal data including images, sounds, texts is accumulated on the Internet. We can expect general-purpose data representation to perform tasks such as data discrimination, generation, and retrieval on various modalities datasets. The key idea for acquiring the representation is embedding a point from a data space of each modality in a point of common space. However, if data is embedded in a point, it becomes difficult to interpret the ambiguity of the data's meaning and the inclusive relation among the data. Of course, representation of data point does not necessarily need to be a point. In this study, we embed image and text into a normal distribution in a common space. This improves the performance of image retrieval.

1. はじめに

マルチモーダルデータの蓄積が進み, モダリティの異なるデータ間で, 相互の検索や変換を行い, 情報の理解, 要約をサポートするシステムの研究が盛んに行われている [Wang 16]. 複数のモダリティの異なるデータを扱う上では, 各モダリティを横断するデータの分類, 生成, 検索といったタスクに転用が可能な, 汎用的なデータ表現を獲得することが重要である. その表現獲得の核となるアイデアとして, 各モダリティのデータからそれら共通の表現空間上の点への埋め込みがある. 埋め込みとは, あるデータ x をある関数 f によって, データの意味を表現する空間上のベクトル $f(x)$ に写像することである. さらに, 埋め込まれた空間上で類似度を定義すれば, マルチモーダルデータ間の意味の近さの測定が可能になる. この空間上では意味の近いデータ同士の類似度が高いことが望ましいが, データ間の類似度を正しく定義されているか評価するのは困難である. そのため, 埋め込まれた空間の評価に, 共通空間上でのデータ間の検索の精度を利用することが提案されている [Kiros 14]. これは, 検索精度の良い共通空間は, 意味の近いデータを, 適切な類似度の点に埋め込んでいるという考え方に基づいている.

このようなマルチモーダル表現の獲得を目的として, 現在, 盛んに研究されている対象として, 画像とテキストデータ間の検索が挙げられる. 画像, テキストデータはインターネット上から容易に収集でき, 画像処理や自然言語処理の分野における研究結果も多く存在するため, 研究対象として選び易い.

画像とテキストデータ間の検索では, まず各データの特徴抽出を行い, その特徴量を何らかの基準で共通空間上のベクトルに変換する. 例えば, 画像の特徴抽出には ImageNet [Deng 09] で学習済みの CNN (Convolutional Neural Network) の中間層の出力を用いるものや, テキストの特徴抽出には word2vec [Mikolov 13] や LSTM (Long Short-Term Memory) の出力が用いられる. そして, これらの特徴量を rank-loss と呼ばれるマージンを用いた関数を使い, クエリーに対する望ましい出力ほど類似度が高くなるように埋め込むことが多い [Kiros 14]. しかし, 画像とテキストデータを共通空間上の点へ埋め込むと, 入力データの持つ意味の曖昧さや, データ間の意味の包含関係といった概念の解釈が困難になる. そのため, データが埋め込まれるべき箇所が複数あるような状況で問題が発生しやすい.

例えば, 単語の埋め込みを考える場合, “rock” という単語は “stone”,“river” などの自然を意味する単語と近い関係にあるのと同時に, “pop”, “jazz” などの音楽を意味する単語との意味も近いはずである. もしもデータを点へ埋め込む場合, “rock” という単語を挟んで, 自然を意味する単語全体と音楽を意味する単語全体が近くの点へ埋め込まれてしまうという問題が生じる. しかし, データの持つ意味の曖昧さを表現できる埋め込み手法があれば, “rock” という単語の曖昧さを上手く捉え, 周囲の単語に対する影響を軽減することが期待される.

本研究では, テキストと画像の両方を点ではなく, 確率分布へ埋め込む方法を提案する. テキストと画像を確率分布へと埋め込むことができれば, テキストと画像の持つ意味の曖昧さや, マルチモーダルデータ間の意味の包含関係や共通部分といった概念を考えることも可能となる. 本研究ではこの確率分布への埋め込みを行う提案手法を, 検索タスクの state-of-the-art である VSE++ [Faghri 17] と組み合わせて比較し, 類似度の定義として望ましいことを示す.

2. 関連研究

2.1 VSE (Visual Semantic Embeddings)

ニューラルネットを用いて得られた特徴量から, 共通空間上の点へ埋め込むモデルとして, VSE [Kiros 14] について説明する. VSE は, 画像から説明文を生成するタスク (Image Captioning) を行うためのモデルである. 画像の特徴抽出には ImageNet で学習済みの AlexNet [Krizhevsky 12], テキストの特徴抽出には LSTM を用いて, 得られた特徴量は線形変換によって共通空間上のベクトルへ変換される.

まず, 画像データ x, 画像の特徴量 h, テキストデータ y, テキストの特徴量 t とする. 画像の特徴量は CNN の最終層から 1 層前の出力で, テキストの特徴量は LSTM の中間層の出力とし, $h = \mathrm{CNN}(x)$, $t = \mathrm{LSTM}$ と表すことにする. 次に, これらの特徴量を線形変換し, 共通の表現空間に埋め込む. この埋め込みに用いる行列を各データに対して M_x, M_y とすると, 埋め込まれた共通空間上のベクトルは $z_h = M_x h$, $z_t = M_y t$ と表される. もし, これらのデータ x, y が関連するデータであ

連絡先: 濱健太, 神戸大学大学院システム情報学研究科計算科学専攻, hamaken@ai.cs.kobe-u.ac.jp

れば, 共通空間上のベクトル z_h, z_t の類似度も高くなることが望ましい. VSE では類似度の定義に cos 類似度を用いている. cos 類似度は

$$\mathrm{sim}(x, y) = \frac{z_h \cdot z_t}{\|z_h\|_2 \|z_t\|_2}$$

ただし, $z_h = M_x \mathrm{CNN}(x), z_t = M_y \mathrm{LSTM}(y)$ と定義される. 関連するデータ対 z_h, z_t に関して, $\mathrm{sim}(x, y)$ が大きくなるように埋め込むために, VSE では rank-loss と呼ばれる以下の式を用いている.

$$r(x, y) = \sum_{\hat{y}} \max\{0, \alpha - \mathrm{sim}(x, y) + \mathrm{sim}(x, \hat{y})\} + \sum_{\hat{x}} \max\{0, \alpha - \mathrm{sim}(x, y) + \mathrm{sim}(\hat{x}, y)\}$$

$\hat{y}, \hat{x}$ はそれぞれ x, y に関連しないデータを表すものとする. α はマージンと呼ばれるハイパーパラメータであり, 関連するデータ対の類似度と, 関連しないデータ対の類似度の差をどの程度大きくするかを調節する役割を担っている. データ全体における損失関数は rank-loss を用いて,

$$L = \frac{1}{N} \sum_{n=1}^{N} r(x_n, y_n)$$

と定義する. ただし, N はデータ数を表すものとする. 定義した損失関数を最小化するように学習を行えば, 共通空間への埋め込みが実現される.

2.2 VSE++

VSE++ (Improved Visual Semantic Embeddings) [Faghri 17] は VSE の改良として, 提案されたものである. VSE の rank-loss を以下のように変更している.

$$r(x, y) = \max_{\hat{y}} \max\{0, \alpha - \mathrm{sim}(x, y) + \mathrm{sim}(x, \hat{y})\} + \max_{\hat{x}} \max\{0, \alpha - \mathrm{sim}(x, y) + \mathrm{sim}(\hat{x}, y)\}$$

VSE では関連しないデータ点全てにおいての和をとっていた箇所が, 各データ点における損失の中でも最大の値となるデータ点のみを全体の損失に含めている. シンプルな変更であるが, VGG [Simonyan 14], ResNet [He 16] など画像の特徴抽出に使うモデルによらず精度が向上し, 別の埋め込み手法との併用も可能である. 本研究ではこの VSE++を基本モデルとし, 確率分布への埋め込みが可能となる改良を加える.

3. 提案手法

本研究では, 各入力画像, テキストデータを多変量正規分布に変換する. その際, 計算を簡単にするために, 正規分布の各次元に独立性を仮定し, 分散共分散行列は対角成分のみ持つことにしている. 提案手法のモデル全体は図 1 のようになっている.

まず入力データを VSE++と同様に, 画像は ImageNet で事前学習済みの CNN (VGG, ResNet) に入力し, テキストは LSTM に入力する. なお本研究における実装には GRU [Cho 14] を用いている. 各ニューラルネットワークを通して得られた特徴量は, 線形変換によって正規分布のパラメータである平均と分散に変換される. 埋め込みは $M_{x_\mu}, M_{x_\sigma}, M_{y_\mu}, M_{y_\sigma}$ の 4 つの行列を用いて行われる. これらの行列を用いて, 図 1 の入力画像データとテキストデータの平均と分散は, $\mu_i = M_{x_\mu} i, \sigma_i = \mathrm{diag}(M_{x_\sigma} i), \mu_t = M_{y_\mu} t, \sigma_t = \mathrm{diag}(M_{y_\sigma} t)$ と表される. よって, 画像 x の特徴量 i とテキスト y の特徴量 t の埋め込みは, $z_i = \mathcal{N}(\mu_i, \sigma_i)$, $z_t = \mathcal{N}(\mu_t, \sigma_t)$ という正規分布の形で表現される. 以上の操作と VSE++は, CNN, LSTM を用いて特徴抽出を行うところまでは同じで, その後, 特徴量を 1 つの点ではなく, 2 つの平均と, 分散を表現する点へ変換するように埋め込み行列を 2 つずつ用意する点で異なっている.

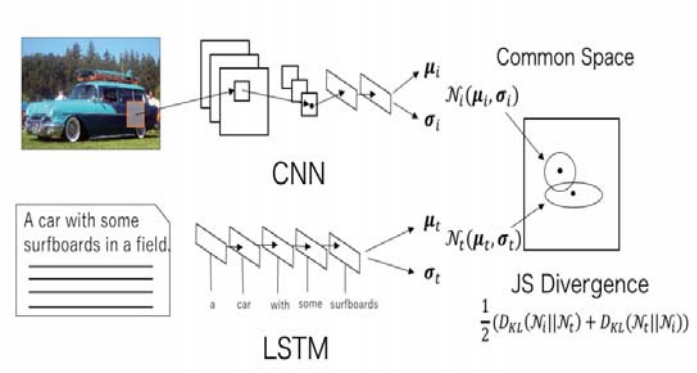


図 1: The whole model of the proposed method.

この埋め込みは, 画像, テキストの特徴量を n 次元実数空間上の点 $x \in R^n$ ではなく, 多変量正規分布の平均 $\mu \in R^n$, 分散共分散行列 $\Sigma \in R^{(n,n)}$(ただし $\Sigma = \mathrm{diag}(\sigma), \sigma \in R^n$) へと変換すれば, 関数空間上の点 $f \in \{\mathcal{N}(\mu, \Sigma) | \mu \in R^n, \Sigma = \mathrm{diag}(\sigma), \sigma \in R^n\}$ への埋め込みを行なっていると解釈できる. よって, VSE++の共通空間である R^n と空間そのものが異なるため, cos 類似度をそのまま利用することはできない. そこで, 確率分布間の類似度を定義するため, 確率分布間の差異を計算する際に用いられることの多い, JS ダイバージェンスを利用する.

JS ダイバージェンスは, KL ダイバージェンスを用いて定義される. 二つの確率分布を p, q とすると, KL ダイバージェンスは $D_{KL}(p||q) = \int p \log \frac{p}{q} dx$ で定義される. p,q は正規分布なので, $D_{KL}(p||q)$ は代数計算によって求めることができ, さらに各次元の独立性を仮定しているので, 計算も容易である. JS ダイバージェンスは KL ダイバージェンスを用いて

$$D_{JS}(p||q) = \frac{1}{2}(D_{KL}(p||q) + D_{KL}(q||p))$$

と定義される. ここで類似度は符号を反転し, $\mathrm{sim}(x, y) = -D_{JS}(p||q)$ と定義する. もちろん, 類似度の定義に KL ダイバージェンスを用いることも考えられる. しかし, 事前実験により, 類似度に KL ダイバージェンスより JS ダイバージェンスを用いた方が精度が良かったため, 本研究では JS ダイバージェンスによる埋め込みを行っている.

モデルの学習は二段階で行う. まず第一段階として, 画像データ, テキストデータの平均に対して, 通常の VSE++と同様に, cos 類似度を用いて埋め込みを行う. その後, 第二段階として, 各データの分散を学習する. この際, 一段階目で学習したテキストデータの平均を固定して学習を行う. これは, 事前実験によりデータの平均を固定すると, 固定せず学習した場合より精度の向上が見られたためである. また, 第二段階の分散の学習では先ほど定義した JS ダイバージェンスを用いた類似度を使う.

表 1: Effect of feature and fine-tuning.

	Caption Retrieval					Image Retrieval				
Model	R@1	R@5	R@10	Med r	Mean r	R@1	R@5	R@10	Med r	Mean r
VSE++(VGG)	52.0	82.0	89.9	**1.0**	5.3	39.6	74.5	85.7	**2.0**	9.6
Ours(VGG)	**52.6**	**82.3**	**90.5**	**1.0**	**5.2**	**40.5**	**75.0**	**86.2**	**2.0**	**8.5**
VSE++(ResNet)	59.2	86.1	93.2	**1.0**	4.0	43.8	78.0	88.2	**2.0**	7.6
Ours(ResNet)	**59.4**	**86.7**	**93.8**	**1.0**	**3.8**	**44.9**	**78.9**	**88.9**	**2.0**	**6.7**
VSE++(VGG, finetune)	57.6	86.0	93.0	**1.0**	**4.1**	45.2	79.1	**88.9**	**2.0**	8.3
Ours(VGG, finetune)	**58.4**	**86.5**	**93.6**	**1.0**	**4.1**	**45.4**	**79.3**	**88.9**	**2.0**	**7.5**
VSE++(ResNet, finetune)	**64.3**	89.5	95.9	**1.0**	**3.1**	50.0	**83.3**	**91.4**	1.6	6.0
Ours(ResNet, finetune)	**64.3**	**90**	**96.3**	**1.0**	**3.1**	**50.5**	**83.3**	**91.4**	**1.4**	**5.4**

4. 実験及び結果

学習データセットとして, Image Caption Retrieval で一般に用いられる, Microsoft COCO データセット [Lin 14](以下 MS COCO) を使用し, 画像テキスト間の双方向の検索を評価する. MS COCO は, 物体検知, セグメンテーション, キャプショニングのための大規模な画像とテキストのデータセットである. Image Caption Retrieval では, キャプショニング用のデータを用いる. キャプショニング用のデータは, 1 枚の画像に対して, その説明を行うテキスト (キャプション) が 5 つ与えられている. データの分割は, VSE++の論文と同様に, 訓練データに 113,287 枚, 検証データに 5000 枚, 評価データに 5000 枚の画像を使用している. 画像データは, CNN への入力時に画像全体からランダムに 224×224 の大きさで切り出している.

パラメータの最適化アルゴリズムには, Adam [Kingma 14] を用いている. ハイパーパラメータは, 一段階目のエポック数を 30, 学習率は最初の 15 エポックを 2.0×10^{-4}, 残りの 15 エポックを 2.0×10^{-5} に設定している. 二段階目の学習はエポック数を 30, 学習率は最初の 15 エポックを 2.0×10^{-5}, 残りの 15 エポックを 2.0×10^{-6} に設定している. 学習率が一段階目に対して 0.1 倍されているのは, 画像の平均の固定を行なっていないため, 一段階目で学習された平均の局所解を抜け出して, 別の局所解へ向かうことを防ぐためである.

また, 本研究では CNN の fine-tuning と提案手法を組み合わせた実験も行なっている. CNN の fine-tuning は, 一段階目が終了した後に CNN のパラメータの固定をはずし, エポック数を 15, 学習率 2.0×10^{-6} に設定している. その後, CNN のパラメータを固定して, 先述した二段階目の学習と同様の設定で分散を学習させている. これらの学習の rank-loss のマージンは, fine-tuning を行わない場合は 0.2 を, 行う場合は 0.15 を使用している. 検索結果の評価指標には一般に Image Caption Retrieval で用いられる R@k, Med r, Mean r を用いている. 評価データ 5000 枚は 1000 枚ずつに対して検索を行い, 5 つの評価値の平均を評価結果としている.

実験では, 4 つの条件設定において既存手法である VSE++と提案手法である正規分布への埋め込みを比較する. 4 つの条件とは, CNN に VGG か ResNet を用いた場合を, それぞれ fine-tuning ありの場合となしの場合の 4 パターンに対応している. これらの比較は, VGG や ResNet の出力といった異なる特徴量を用いた場合にも本手法が適用できること, fine-tuning と組み合わせることが可能であることを示すために行っている. 結果を表 1 に示す.

表 1 の上から, VGG, ResNet, VGG + fine-tuning, ResNet + fine-tuning の場合における既存手法 (上) と提案手法 (下) の比較である. R@1,R@5,R@10,Med r, Mean r 全ての指標において, 提案手法の精度が向上している. また画像検索 (Image Retrieval) とテキスト検索 (Caption Retrieval) を比較すると, 評価値の改善は画像検索の mean r が顕著である. 特に, VGG, ResNet, VGG + fine-tuning, ResNet + fine-tuning の各条件で Caption Retrieval の Mean r は平均 0.075 の改善であるのに対して, Image Retrieval の Mean r は平均 0.85 ほど小さくなっている. 以上のことから, 提案手法が画像検索側の Mean r に対して, 大きく影響を及ぼしていることが分かる.

5. 考察

表 1 より, VGG, ResNet の中間層の出力どちらを用いた場合においても, 精度の向上が見られていることから, 提案手法が画像特徴量によらず適用可能であると考えられる. この事実から, 画像の分類タスクにおける CNN モデルの改良が進んだ場合, そのモデルに提案手法を適用すれば, 検索精度のさらなる向上が期待できる.

次に, Mean r の精度が向上した理由について考察を行う. 図 2 は, 画像検索において Mean r を大きく改善させた例の一つである. 図 2 下の表における Rank は, クエリーとなるテキストに対して正解となる上の画像の出力順位を示している. 上から 4 番目のテキストの Rank を見ると, VSE++は 665 と他と比較してかなり大きい値を取っている. テキストの内容に注目すると, このテキストのみ “bus” という単語が含まれていない. これは, VSE++が LSTM の学習において, テキスト内の “bus” という単語の有無のみで, 画像とテキストを類似度の高い点へ埋め込んでしまっていると考えられる. しかし, 分布への埋め込みを行う提案手法の Rank は 282 であり, 大きく改善している. これは図 2 上のバスの画像の分散を大きくとるか, “bus” という単語の含まれていない, 上から 4 番目のテキストの分散を大きくとるように, 提案手法が学習したからだと考えられる. このことから, 提案手法は各データの持つ意味の曖昧さを捉えていると考えられる.



Caption	Rank VSE++	Rank Ours
Passenger bus stationary in traffic on city street.	3	**2**
A modern city commuter bus in traffic during the day	2	**1**
A bus parked on the side of the road while in traffic	**5**	6
a modern train is parked against the sidewalk curb	665	**282**
A bus stops at a curb in a busy city street.	6	**3**

図 2: An example of greatly improving Mean r.

表 1 の fine-tuning ありとの比較を見ると, 評価値の向上が小さいものも見られる. これは, fine-tuning することによって, モデルの表現力が大きくなっていることが関係すると考えられる. ImageNet での事前学習に用いる画像の枚数は 120 万枚ほどなのに対して, MS COCO の訓練データ数は 11 万枚ほどしかないので, fine-tuning によって, 平均の学習で過学習を起こしている可能性がある. そのため, その後の分散の学習による精度の向上が困難になったと考えられる. しかし, 画像検索の mean r に関しては大きく改善しているため, 提案手法による改善が, 誤差の影響によるものとは考えにくい.

6. 結論

本研究では VSE++の埋め込みの出力を正規分布の平均と分散に変更し, rank-loss の類似度を JS ダイバージェンスを用いて定義するという変更を加えて, 画像データとテキストデータの共通空間上の点への埋め込みから, 確率分布への埋め込みに拡張する方法を提案した. 提案手法は学習を行う際, 通常の VSE++と同様に学習を行うのではなく, 平均のみを事前に VSE++で学習した上で, 平均を固定して追加で分散の学習を行うために, 分散を上手く学習することが可能となり, 検索精度が向上された. この結果から, 提案手法が共通空間上で望ましい類似度を定義していることの傍証が得られた.

本研究の今後の課題について述べる. まず埋め込みに用いる確率分布を変更するといった工夫が可能である. 本研究で正規分布に仮定した各次元の独立性を外すか, 多峰性の混合正規分布に埋め込むことも考えられる. また, 分布への埋め込みを行っていることから, 新たな正則化の導入も考えられる. 例として, KL ダイバージェンスを用いて分布間の包含関係を表現すれば, ランダムクロップされた画像の分布が切り出される前の画像に包含されるといった仮定を, 正則化条件として加えることができる. このような点への埋め込みでは導入できない, 分布への埋め込みのための正則化によって, モデルの汎化能力が向上することが期待される.

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

[Cho 14] Cho, K., Merrienboer, van B., Gülçehre, Ç., Bahdanau, D., Bougares, F., Schwenk, H., and Bengio, Y.: Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation, in *Proceedings of the Conference on Empirical Methods in Natural Language Processing(EMNLP)*, pp. 1724–1734 (2014)

[Deng 09] Deng, J., Dong, W., Socher, R., Li, L., Li, K., and Li, F.: ImageNet: A large-scale hierarchical image database, in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition(CVPR)*, pp. 248–255 (2009)

[Faghri 17] Faghri, F., Fleet, D. J., Kiros, R., and Fidler, S.: VSE++: Improved Visual-Semantic Embeddings, *arXiv*, pp. 1–11 (2017)

[He 16] He, K., Zhang, X., Ren, S., and Sun, J.: Deep Residual Learning for Image Recognition, in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, pp. 770–778 (2016)

[Kingma 14] Kingma, D. P. and Ba, J.: Adam: A Method for Stochastic Optimization, *arXiv*, pp. 1–15 (2014)

[Kiros 14] Kiros, R., Salakhutdinov, R., and Zemel, R. S.: Unifying Visual-Semantic Embeddings with Multimodal Neural Language Models, *arXiv*, pp. 1–13 (2014)

[Krizhevsky 12] Krizhevsky, A., Sutskever, I., and Hinton, G. E.: ImageNet Classification with Deep Convolutional Neural Networks, in *Proceedings of the 26th Annual Conference on Neural Information Processing Systems(NIPS)*, pp. 1106–1114 (2012)

[Lin 14] Lin, T., Maire, M., Belongie, S. J., Hays, J., Perona, P., Ramanan, D., Dollár, P., and Zitnick, C. L.: Microsoft COCO: Common Objects in Context, in *Proceedings of the 13th European Conference of Computer Vision(ECCV)*, pp. 740–755 (2014)

[Mikolov 13] Mikolov, T., Chen, K., Corrado, G., and Dean, J.: Efficient Estimation of Word Representations in Vector Space, *arXiv*, pp. 1–12 (2013)

[Simonyan 14] Simonyan, K. and Zisserman, A.: Very Deep Convolutional Networks for Large-Scale Image Recognition, *arXiv*, pp. 1–14 (2014)

[Wang 16] Wang, W., Yang, X., Ooi, B. C., Zhang, D., and Zhuang, Y.: Effective deep learning-based multimodal retrieval, *Very Large Data Bases Journal(VLDB J)*, Vol. 25, No. 1, pp. 79–101 (2016)

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

[3L1] [General Session] 3. Data Mining

座長:大澤 昇平（東京大学）

Thu. Jun 7, 2018 1:50 PM - 3:30 PM Room L (3F Sapphire Hall Asuka)

[3L1-01] Trip Prediction in Bike Sharing Systems

○Maya Okawa[1], Takeshi Kurashima[1], Yusuke Tanaka[1], Hiroyuki Toda[1] （1. NTT）

1:50 PM - 2:10 PM

[3L1-02] Autoregressive Tensor Factorization for Spatio-temporal Predictions

○Koh Takeuchi[1,2], Hisashi Kashima[2,3], Naonori Ueda[1,3] （1. NTT Communication Science Laboratories, 2. Graduate School of Informatics, Kyoto University, 3. RIKEN Center for Advanced Intelligence Project）

2:10 PM - 2:30 PM

[3L1-03] Online prediction of self-adaptive memory over data stream

○Akihiro Yamaguchi[1], Shigeru Maya[1], Tatsuya Inagi[1], Ken Ueno[1] （1. Toshiba Corporation）

2:30 PM - 2:50 PM

[3L1-04] Improve Sales Forecasting with Customer Behavior Analysis

○Yusuke Yamaura[1], Yusuke Yamaura[1], Takeshi Onishi[1] （1. Fuji Xerox Co., Ltd. Japan）

2:50 PM - 3:10 PM

[3L1-05] Embedding special-day effects for demand prediction

○Takuji Tahara[1], Yiou Wang[1], Keiichi Nemoto[1] （1. Fuji Xerox Co., Ltd.）

3:10 PM - 3:30 PM

©The Japanese Society for Artificial Intelligence

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

バイクシェアシステムにおけるトリップ予測

Trip Prediction in Bike Sharing Systems

大川 真耶 *1 Maya Okawa　倉島 健 *1 Takeshi Kurashima　田中 佑典 *1 Yusuke Tanaka　戸田 浩之 *1 Hiroyuki Toda

*1日本電信電話株式会社
NTT Service Evolution Laboratories

Trip demand prediction plays a crucial role in bike-sharing systems. Predicting trip demand is a highly challenging problem because it is influenced by multiple factors, such as periodic changes, correlation between stations, weather and types of users. Although several recent studies successfully address some of these factors, no framework exists that can consider all of them simultaneously. To this end, we develop a novel form of the point process that jointly incorporates all the above factors to predict trip demand, i.e., predicting the number of pick-up and drop-off events in the future and when over-demand is likely to occur. Our extensive experiments on real-world bike sharing systems demonstrate the superiority of our trip demand prediction method over five existing methods.

1. はじめに

シェアリングエコノミーの拡大に伴って, 自転車シェアリングサービス (以下,「バイクシェアシステム」) が世界各国で増加している. バイクシェアシステムは自転車をユーザ同士でシェアし, 必要な時に自由に使うシステムである. ユーザは街中に設置されている自転車駐輪ポート (以下,「ステーション」) から任意のタイミングで自転車を借り, 任意のステーションに返却することができる. これらのシステムは市民にとってのアクセシビリティの向上, 自動車交通からの転換による混雑・環境問題の緩和が見込めるという利点から従来の公共交通サービスに代わる新たな短距離移動手段として期待を集めている [2]. 複数の都市でバイクシェアシステムにおけるトリップデータをオープンデータとして公開する試みが始まっている [9]. トリップデータは出発ステーション, 出発時刻と到着ステーション, 到着時刻の情報に加え, 会員種別 (会員・非会員), 年齢, 性別, 住所等ユーザに関する情報を含む. トリップデータの分析・予測はシステムの最適化を行う上で非常に重要な役割を持つ. 例えば, いつどこで何台の自転車が必要になるかを予測できれば, 事前に適切な配置を行うことで自転車の供給不足を防ぐことができる.

バイクシェアシステムにおけるトリップ予測手法は多数存在する. 初期の研究では, ARMA [5] 等の時系列モデル, 隠れマルコフモデル [10], ベイジアンネットワーク [4] 等直近の需要の変化に基づいて未来のトリップ需要を予測する手法が用いられてきた. 最近の研究では周期性を考慮した手法が高い予測性能を示すことが確かめられている [1]. 例えば周期性に基づく非一様点過程モデルが Ramon ら [1] によって提案されている. 天気がトリップ需要の変化に大きな影響を与えるという結果も複数の研究で報告されている [11, 13, 7]. Yang ら [13] や Liu ら [7] は周期と天気に加え出発ステーションと到着ステーションの関係を考慮した手法を構築した. しかし, これらの手法は個々のトリップに付随するユーザ属性を考慮できないという大きな問題がある. これらの要素によってトリップ需要の変動の仕方が大きく異なるということが基礎分析で確かめられている [14]. これらのユーザ属性の適切な利用は, 予測精度の向上やトリップ需要変動のさらなる理解に資すると考えられる.

連絡先: 大川真耶, NTT, okawa.maya@lab.ntt.co.jp

そこで本研究では, バイクシェアシステムにおけるトリップデータを対象として, 従来手法で考慮していた周期性, 天気, 出発ステーションと到着ステーションの関係に加え, 会員種別等のユーザ属性を考慮し将来の需要予測を行う確率モデルを構築する. 具体的には, 都市の各ステーションにおける出発・到着を不定時間間隔で起こるイベントとみなし, マーク付き点過程を拡張した手法を用いてこれらのデータを記述する. マーク付き点過程はイベントの系列からなるデータをモデル化するための確率過程の一種であり, 購買等の人間行動や地震等の自然現象の統計分析・予測に広く用いられてきた. 近年は, point-of-interest (POI) への訪問履歴 [6, 3] や地理空間上のある地点から別の地点への移動を表すトリップデータ [12] 等移動に関するデータへの適用も広がっている. Wang ら [12] は点過程の混合モデルを用いてトリップの目的を推定する技術を提案した. しかし, これらの手法は周期のような長期的な需要変動のパターンや, 天気等の行動データに表れない情報を考慮することができない. 前節で述べた通り, トリップ需要はこれらの要素の影響で大きく変動する. 本稿では, これらの要素の複合的な効果を考慮する新たなマーク付き点過程モデルを構築する.

本研究の貢献は以下の通りである.

- トリップ需要予測のための新たな手法を構築した. 提案手法は周期, 天気, 出発ステーションと到着ステーションの関係に加え会員種別等のユーザ属性を考慮することができる (3 章).
- 3 都市で収集されたバイクシェアシステムのトリップデータを用いて実験を行なった. 提案手法が既存手法に比べて良い予測性能を持つことを示した (4 章).

2. 問題設定

トリップは出発ステーション u, 到着ステーション v, 出発時刻 t, トリップ時間 (出発から到着までにかかった時間) Δ とユーザ属性 (例えば会員種別や年齢, 性別) m の 5 つの要素からなるタプル (u, v, t, Δ, m) で表される. ステーションの集合を $\mathcal{S} = \{s_1, ..., s_K\}$, ユーザ属性の集合を $\mathcal{M}$ とおく. ここで K はステーションの個数である. あるバイクシェアシステムにおけるトリップの系列 $\mathcal{D} = \{(u_i, v_i, t_i, \Delta_i, m_i)\}_{i=1}^{n}$ が与え

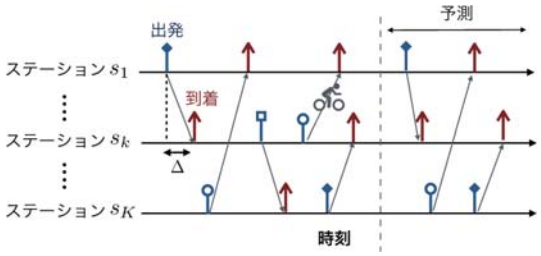


図 1: トリップデータの例. 横軸は各々のステーションにおけるイベントの時間軸を表す.

られたとする. ここで n はトリップ数である. ここで $\mathcal{D}$ の各要素は出発ステーション $u_i \in \mathcal{S}$, 到着ステーション $v_i \in \mathcal{S}$, 出発時刻 $t_i \in \mathbb{R}^+$, トリップ時間 $\Delta_i \in \mathbb{R}^+$ とユーザ属性 m_i からなるイベントとみなすことができる. 図 1 にトリップデータの例を示す. 図 1 中の青線が各ステーションにおける出発イベント, 赤線が到着イベントを表している. 出発イベントのマークは到着ステーションに対応している.

本研究ではトリップデータに加え, 天気データ $\mathcal{W} = \{F_t, H_t, D_t, V_t, R_t\}_{t\in\mathbb{R}^+}$ を用いる. $\mathcal{W}$ の各要素は時刻 t における気温 F_t, 湿度 H_t, 風速 D_t, 視程 V_t, 降水量 R_t からなるタプルである.

本研究ではトリップデータと天気データが与えられた下で未来の任意の時間帯におけるトリップ需要を予測する問題に取り組む. ここでトリップ需要を任意の時間窓における出発イベント数, 到着イベント数で定義する.

3. モデル

3.1 マーク付き点過程

提案手法の導入の前に, まずベースとなるマーク付き点過程について概要を説明する. マーク付き点過程は不等時間間隔で起こる現象 (イベント) をモデル化する確率過程の一種である. 時刻 t とマーク (例えば到着ステーション等) v からなるイベントを (t, v) とおく. マーク付き点過程はマーク v のイベントが生じる確率的な頻度を表す関数 (以下, 「強度関数」) $\lambda(t, v)$ を用いて記述される. 強度関数が $\lambda(t, v) = \lambda(t)f(v|t)$ の形に分解できると仮定する. ここで $f(v|t)$ は時刻 t においてマーク v が発生する条件付き確率, $\lambda(t)$ は単位時間ごとのイベントの発生回数の期待値を表す関数である. N_H 個のイベントからなるイベント履歴 $\mathcal{H} = \{(t_i, v_i)\}_{i=1}^{N_H}$ が与えられた下で, 尤度関数は次式で書き下せる.

$$p(\mathcal{H}|\lambda(t, v)) = \left[\prod_{(t_i,v_i)\in\mathcal{H}} \lambda(t_i)f(v_i|t_i)\right] \exp\left(-\int_0^T \lambda(t)dt\right). \tag{1}$$

3.2 提案手法

本稿では, 過去のトリップデータと天気の情報を用いて未来のトリップ需要を予測する手法を構築する. 具体的には, 各ステーションを出発するトリップの系列と各ステーションペア間のトリップ時間を各々独立な確率過程を用いてモデル化する. ステーション u を出発するトリップの系列 $\mathcal{D}^u = \{(t_i, v_i, m_i, \Delta_i)|u_i = u\}_{i=1}^n$ と各時刻における天気情報 $W_t = (F_t, H_t, D_t, V_t, R_t)$ の集合が与えられたとする. 提案手法の枠組みでは, ステーション u を出発地点とするトリップの集合 $\{(t_i, v_i, m_i)|u_i = u\}_{i=1}^n$ とトリップ時間の系列 $\{\Delta_i|u_i = u\}_{i=1}^n$ を独立にモデル化し, 二つのモデルの推定結果を合わせてトリップ需要 (任意の時間窓における出発イベント数と到着イベント数) の予測を行う. 各々のモデルについて以下に述べる.

3.2.1 出発イベントのモデル化

1 章で述べた背景を踏まえ, マーク付き点過程モデルに周期と天気等の外部情報を導入して拡張したモデルを構築する. ステーション u において v を目的地とする出発イベントが時刻 t に起きる率を表す強度関数 $\lambda_u(t, v)$ を時刻 t における天気情報 W_t を使って次式の通りモデル化する.

$$\lambda_u(t, v|W_t) = f_u(v|t)\lambda_u(t|W_t). \tag{2}$$

ここで $\lambda_u(t|W_t)$ はステーション u, 時刻 t における出発イベントの発生率を表す関数, $f_u(v|t)$ はある時刻 t, ステーション u において行き先としてステーション v が選ばれる条件付き確率である.

ステーション v が到着ステーションとして選ばれる確率が曜日や時刻によって周期的に変化するという仮定に基づき $f_u(v|t)$ をモデル化する. まず, 各時刻 t について各週の始めから数えた相対時刻 $d \in [0, 7)$ 日を導入する. 相対時刻 d において行き先としてステーション v が選ばれる確率 $p_u(v|d)$ を Gaussian Naive Bayes (GNB) [8] でモデル化する. 具体的には, ベイズの定理を使って $p_u(v|d)$ を事前分布と尤度の積 $p_u(v|d) \propto p_u(d|v)p_u(v)$ で書き換える. $p_u(d|v)$ のモデル化にはガウス分布, $p_u(v)$ のモデル化には多項分布を用いる. これにより, 曜日と時間帯によるステーション v の行き先としての選ばれやすさの違いを考慮することができる.

$\lambda_u(t|W_t)$ を周期性 (**要素 1**) を表す因子 $\lambda_{u,m}(t)$ と天気 (**要素 2**) の影響を表す因子 $\alpha_{u,m}(W_t)$ の積でモデル化する.

$$\lambda_u(t|W_t) = \sum_{m\in\mathcal{M}} \alpha_{u,m}(W_t)\lambda_{u,m}(t). \tag{3}$$

ここで出発イベントの起こりやすさと天気の変化に対する反応がマーク (会員種別や属性等の付加要素) によって異なるという仮定に基づき, マーク m ごとの関数を導入した.

(要素 1) 周期性 1 週間の周期性を考慮するため, $\lambda_{u,m}(t)$ を J 個のガウシアンカーネルの和で定義する.

$$\lambda_{u,m}(t) = \sum_{j=1}^{J} x_j^{u,m} \exp\left(-\sin^2\left(\pi\frac{t-\omega_j}{l}\right)/h^2\right). \tag{4}$$

ここで ω_j は j 番目のガウシアンカーネルの平均, h は標準偏差, l は周期を表すハイパーパラメータである. 本研究では, $J = 168$, $l = 7$ 日, $h = 60$ 分, $\omega_j = j \times 60$ 分とした. $x_j^{u,m}$ はステーション u, m 番目のマークに対応する j 番目のカーネルの重みである. この定式化により, 曜日と時刻ごとの周期性を取り入れることができる.

(要素 2) 天気 天気の変化に対するトリップ需要の非線形な変動を捉えるため, 多項式を用いて $\alpha_{u,m}(W_t)$ をモデル化する.

$$\alpha_{u,m}(W_t) = \exp\left(\mathbf{a}_{u,m}W_t^T W_t + \mathbf{b}_{u,m}W_t + \epsilon_{u,m}\right). \tag{5}$$

本稿では簡単のため, 二項式の指数関数でモデル化した. $\mathbf{a}_{u,m}$ と $\mathbf{b}_{u,m}$ は 5 種類の天気情報 (気温, 湿度, 風速, 視程, 降水量) に対応する 5 次元の回帰係数のベクトル, $\epsilon_{u,m}$ は切片である.

出発イベントモデルのパラメータセットを $\Psi = \{\{\{x_j^{u,m}\}_{j=1}^J, \beta, \gamma, \mathbf{a}_{u,m}, \mathbf{b}_{u,m}, \epsilon_{u,m}\}\}_{u\in\mathcal{S}, m\in\mathcal{M}}$ とおく.

3.2.2 トリップ時刻のモデル化

ステーション u, v 間のトリップ時間 Δ を対数正規分布でモデル化する. 対数正規分布はトリップ時間のモデル化に一般的に用いられる.

$$p_{u,v}^m(\Delta) = \frac{1}{\Delta\sigma_{uv}^m\sqrt{2\pi}} \exp\left(-\frac{(\log\Delta - \mu_{uv}^m)^2}{2{\sigma_{uv}^m}^2}\right). \tag{6}$$

ここで $\{\mu_{uv}^m, \sigma_{uv}^m\}_{m\in\mathcal{M},u\in\mathcal{S},v\in\mathcal{S}}$ はモデルパラメータである.

3.3 学習

出発イベントモデルの対数尤度は次式で書き下せる.

$$\mathcal{L}(\Psi) = \sum_{i=1}^{n} \log \lambda_{u_i,m_i}(t_i|W_{t_i}) - \sum_{u\in\mathcal{S}}\sum_{m\in\mathcal{M}} \int_0^T \lambda_{u,m}(t|W_t)dt + \sum_{i=1}^{n} \log f_{u_i}(v_i|t_i) + \sum_{i=1}^{n} \log \alpha_{u_i,m_i}(W_{t_i}). \quad (7)$$

尤度関数からわかる通り, 本モデルの最適化問題は $\lambda_{u,m}(t|W_t)$, $f_u(t,v)$, $\alpha_{u,m}(W_t)$ 各々についての独立な最適化問題に帰結する. $\lambda_{u,m}(t|W_t)$, $\alpha_{u,m}(W_t)$ に関する項は全てのモデルパラメータ Ψ について微分可能なため, 勾配を用いた最適化手法を適用することができる. 本研究では確率的勾配降下法 (SGD) を用いた. $f_u(v|t)$ について GNB [8] のパラメータ学習手順に従い, 閉形式で解を得ることができる. トリップ時間のモデルに関しても対数正規分布のパラメータ推定の手続きに従い, 閉形解を導出することができる. スペースの都合上, パラメータ更新の手順は省略する.

3.4 予測

学習済みの強度関数 $\lambda_{u,m}(t,v|W_t)$ とトリップ時間の分布が与えられた条件の下で未来の任意の時間窓, 任意のステーション u におけるトリップ需要 (任意の時間窓における出発イベント数と到着イベント数の期待値) を予測する.

未来の時間窓 $[t_{start}, t_{end}]$ における出発イベント数の期待値は強度関数の積分により得られる.

$$\sum_{m\in\mathcal{M}} \int_{t_{start}}^{t_{end}} \lambda_{u,m}(t|W_t)dt. \quad (8)$$

また, ステーション v における到着イベント数の期待値は次式で定義される到着イベントの強度関数 $\lambda'_v(t|W_t)$ の積分 $\int_{t_{start}}^{t_{end}} \lambda'_v(t|W_t)dt$ で求めることができる.

$$\lambda'_v(t|W_t) = \sum_{u\in\mathcal{S}}\sum_{m\in\mathcal{M}} \int \lambda_{u,m}(t',v|W_t)p_{uv}^m(t-t')dt'. \quad (9)$$

上式の積分は解析的に解くことができないため, 数値積分を行う.

4. 実験

4.1 データセット

本研究では 2015 年の 9 月から 2016 年の 8 月にニューヨーク *1, ワシントン D.C. *2, サンフランシスコ *3 の 3 都市で観測されたバイクシェアシステムのトリップデータを用いて実験を行う. 各々のトリップデータは出発時刻, 出発ステーション, 到着時刻, 到着ステーション, 会員種別の系列からなる. 実験では, 会員種別 (会員・非会員) をユーザ属性として用いる. 本研究では, トリップデータに加え weather underground API*4 から取得した天気情報を用いた. 表 1 に本研究で用いたデータの統計量を示す.

∗1 https:// www.citibikenyc.com/system-data
∗2 http://www.capitalbikeshare.com/system-data
∗3 https://www.fordgobike.com/system-data
∗4 https://www.wunderground.com/weather/api/

表 1: 実験で用いたデータの基本統計量

データ		NY	D.C.	SF
トリップデータ	ステーション数	633	402	74
	トリップ数	12,906,339	3,252,709	313,685
	(会員)	11,367,000	2,581,413	280,091
天気データ	気温 (°C)	[-18, 35]	[-5, 36]	[0, 33]
	湿度 (%)	[0, 100]	[0, 100]	[0, 100]
	視程 (km)	[0, 137]	[0, 48]	[0, 390]
	風速 (mph)	[0, 16]	[0, 16]	[0, 16]
	降水量 (mm)	[0, 19]	[0, 9]	[0, 11]
期間		9/1/2015 - 8/31/2016		

4.2 比較手法

以下の 5 手法を既存手法とし, 提案手法との比較を行った. 移動平均 *(HM)* [4] は同じ曜日, 時間帯の過去のデータの平均値を予測値とする手法である. *Auto-Regressive and Moving Average (ARMA)* [5] は時系列データの一手法であり, 直近のデータに基づいて予測を行う. *Inhomogeneous Poisson Process Inference (IPPI)* [1] は点過程ベースの手法であり, 出発イベントと到着イベントを独立にモデル化する. その際, 時間帯と曜日ごとの周期性を考慮している. *Multi-similarity-weighted k-NN (MSWK)* [7] は天気と曜日, 時間帯の類似性を考慮する k-NN ベースの手法である. *Random-forest-based method (RF)* [13] は曜日, 時間帯と天気を入力として未来のトリップ数を予測する.

4.3 評価指標

予測精度の評価指標として次式で定義される Mean Absolute Error (MAE) を用いた.

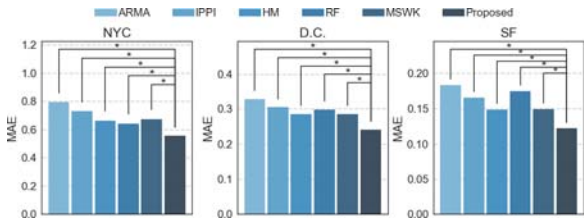
$$\mathrm{MAE} = \frac{\sum_{u\in\mathcal{S},t\in\mathcal{T}}\sum_t |\hat{y}_{u,t} - y_{u,t}|}{|\mathcal{T}||\mathcal{S}|} \quad (10)$$

ここで $\hat{y}_{u,t}$ はステーション u, 時間幅 t における出発・到着イベント数の予測値, $y_{u,t}$ は観測値である. $\mathcal{T}$ は予測を行う時間窓の集合, $\mathcal{S}$ はステーションの集合である. $|\mathcal{T}|$ は時間窓の個数, $|\mathcal{S}|$ はステーション数を表す.

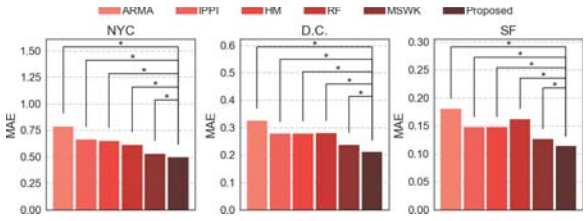
年単位の季節性によるバイアスを取り除くため, 1 年間のデータ期間を 3ヶ月ごとに区切り, 2015 年 9 月から 11 月, 2015 年 12 月から 2016 年 2 月, 2016 年 3 月から 5 月, 2016 年 6 月から 8 月の 4 つのデータセット各々について学習と予測を行なった. 各 3ヶ月間のデータのうち, 各々の最後の 7 日をテストデータ, 残りを学習データとして用いた.

4.4 実験結果

図 2 は 6 つの異なる手法に対する MAE を示す. 図 2(a) が出発イベント数の予測結果, 図 2(b) が到着イベント数の予測結果である. 左がニューヨーク, 中央がワシントン D.C., 右がサンフランシスコのデータセットに対応している. 全てのケースで提案手法が既存手法の予測性能を上回っている. t 検定の結果, これらの予測精度結果の間に統計的に有意な差があることが示された ($p < 0.01$). このことから, 提案手法はトリップ需要に影響を与える複数の要素 (天気, 周期性, 出発イベントと到着イベントの関係, 会員情報) を適切に考慮していると結論づけることができる. 全体として, ARMA は他の手法に比べて精度が低い. これは周期性を考慮していないためと考えられる. 出発イベント数の予測においては, 天気の情報を考慮する RF, MSWK が過去の履歴のみを用いる HM と同程度の予測精度を出している. 特にデータ量が少ないワシントン D.C. とサンフランシスコの 2 つのデータセットでは RF が HM よ



(a) 出発イベント数予測



(b) 到着イベント数予測

図 2: 出発イベント予測, 到着イベント予測に対する Mean absolute error (MAE). 値が小さいほど良い予測性能を示す.

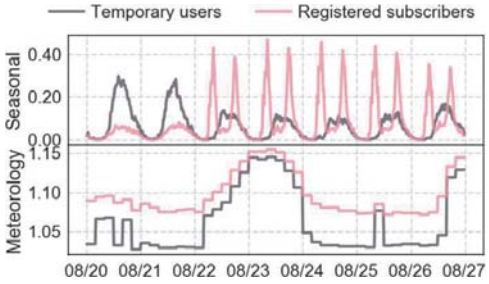


図 3: 学習された強度関数. 上の行が周期性を表す項, 下の行が天気の影響を表す項に対応する.

り低い性能を示している. 提案手法はトリップ需要が時間, 天気に対して連続的に変化するという仮定を置いているため限られた量のデータに対しても頑健に働く. 到着イベントの予測については, MSWK, RF と提案手法が他の比較手法より良い予測精度を示している. これは出発イベントと到着イベントの関係を考慮しているためと考えられる. 他の評価指標 (Mean Averaged Percentage Error) も用いて評価を行い, 類似の結果を得た.

図 3 にワシントン D.C. で最も貸出数の多いステーションで学習された 2016 年 8 月 20 日から 8 月 27 日までの強度関数を示す. 一番上の行は周期性を表す項, 上段のプロットは天気の影響を表す項である. この図ではピンクの線が非会員, 黒の線が会員の強度関数に対応している. 会員は主に平日にバイクシェアシステムを利用している. 9:00 と 18:00 に通勤需要に対応するピークがある. 非会員は主に日中バイクシェアシステムを利用している. また, 下段のプロットから非会員の需要は天気によって大きく変動しているのに対し, 会員の需要は比較的緩やかに変化している. これらの結果から, 会員は非会員に比べて天気の変化の影響を受けにくいということがわかる. 提案手法はユーザのタイプによる需要変化の違いについて新たな知見を与える. このような知見は, 例えばユーザに対するインセンティブを用いた需要の平準化を行う上で有用である.

5. 結論

本研究では, バイクシェアシステムにおけるトリップ需要の予測に取り組んだ. 具体的には, マーク付き点過程を拡張することで (1) 周期 (2) 天気 (3) 出発ステーションと到着ステーションの関係に加え (4) トリップに付随する情報 (会員種別, 属性等) を考慮できる新たな手法を構築した. ニューヨーク, ワシントン D.C., サンフランシスコの 3 都市で取得されたバイクシェアシステムのトリップデータを用い, 5 つの既存手法と比較することで提案手法の優位性を示した. 提案手法は既存手法に比べ, トリップ需要を精度良く予測することができる. また, 要素 (1)-(4) のトリップ需要への複合的な影響についてより深い知見を与える.

参考文献

[1] Ramon Alvarez-valdes, Jose M Belenguer, Enrique Benavent, Jose D Bermudez, Enriqueta Vercher, and Francisco Verdejo. Optimizing the level of service quality of a bike-sharing system. *Omega*, 2015.

[2] U C Davis. Bikesharing in Europe, the Americas, and Asia: Past, Present, and Future. *Europe*, 2010.

[3] Nan Du, Hanjun Dai, Rakshit Trivedi, Utkarsh Upadhyay, Manuel Gomez-Rodriguez, and Le Song. Recurrent Marked Temporal Point Processes: Embedding Event History to Vector. *KDD*, pages 1555–1564, 2016.

[4] Jon Froehlich, Joachim Neumann, and Nuria Oliver. Sensing and predicting the pulse of the city through shared bicycling. *IJCAI*, pages 1420–1426, 2009.

[5] Andreas Kaltenbrunner, Rodrigo Meza, Jens Grivolla, Joan Codina, and Rafael Banchs. Urban cycles and mobility patterns: Exploring and predicting trends in a bicycle-based public transport system. *Pervasive and Mobile Computing*, 6(4):455–466, 2010.

[6] Hideaki Kim, Tomoharu Iwata, Yasuhiro Fujiwara, and Naonori Ueda. Read the Silence: Well-timed Recommendation via Admixture Marked Point Processes. *AAAI*, pages 132–139, 2017.

[7] Junming Liu, Leilei Sun, Weiwei Chen, and Hui Xiong. Rebalancing Bike Sharing Systems: A Multi-source Data Smart Optimization. *KDD*, pages 1005–1014, 2016.

[8] Tom M Mitchell et al. Machine learning. 1997. *Burr Ridge, IL: McGraw Hill*, 45(37):870–877, 1997.

[9] Gustavo Romanillos, Martin Zaltz Austwick, Dick Ettema, and Joost De Kruijf. Big data and cycling. *Transport Reviews*, 36(1):114–133, 2016.

[10] Jasper Schuijbroek, R. C. Hampshire, and W. J. van Hoeve. Inventory rebalancing and vehicle routing in bike sharing systems. *European Journal of Operational Research*, 257(3):992–1004, 2017.

[11] Adish Singla, Marco Santoni, Gabor Bartok, Pratik Mukerji, Moritz Meenen, and Andreas Krause. Incentivizing Users for Balancing Bike Sharing Systems. *AAAI*, pages 723–729, 2015.

[12] Pengfei Wang. Human Mobility Synchronization and Trip Purpose Detection with Mixture of Hawkes Processes. *KDD*, pages 495–503, 2017.

[13] Zidong Yang, Ji Hu, Yuanchao Shu, Peng Cheng, Jiming Chen, and Thomas Moscibroda. Mobility Modeling and Prediction in Bike-Sharing Systems. *MobiSys*, pages 165–178, 2016.

[14] Jiawei Zhang, Xiao Pan, Moyin Li, and Philip S. Yu. Bicycle-sharing system analysis and trip prediction. *MDM*, pages 174–179, 2016.

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

自己回帰テンソル分解による時空間データ予測

Autoregressive Tensor Factorization for Spatio-temporal Predictions

竹内 孝 *1*2 Koh Takeuchi
鹿島 久嗣 *2*3 Hisashi Kashima
上田 修功 *1*3 Naonori Ueda

*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 Laboratories

*2京都大学大学院 情報学研究科 Graduate School of Informatics, Kyoto University
*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

Spatio-temporal data analysis is a common research topic that requires interpolations of unknown locations and predictions of future observations by utilizing information about where and when data were observed. Tensor factorization methods are popular in this field because of their capability of handling multiple types of spatio-temporal data, dealing with missing values, and providing computationally efficient parameter estimation procedures. However, any methods have been proposed to address the most difficult problems, predicting future observations of unknown locations. In this paper, we propose a new tensor factorization method that estimates low-rank latent factors by simultaneously learning the spatial and temporal autocorrelations. We introduce new spatial autoregressive regularizers based on existing spatial autoregressive models and provide an efficient estimation procedure.

1. はじめに

高機能センシングデバイスと高速移動通信網の普及に伴い，センサーネットワークを介した都市の広範囲リアルタイムモニタリングシステムが実現されつつある．システムを通して観測される人の行動やモノの移動，大気環境など多種多様な時空間データを解析し，都市のマネジメントや企画に役立てようとする試みが注目を集めており，データ解析技術は今後ますます重要になると考えられる．

時空間データの解析は，空間統計学，空間経済学，気候学，リモートセンシング [1, 2] などの分野で盛んに行われてきた．これらの研究は，センサー未設置場所の観測データの推定 (空間内挿) あるいはセンサー設置場所での将来観測値の予測 (時間外挿) を目的とする場合が多い．その中でもセンサー未設置場所での将来観測値の予測問題は，空間内挿と時間外挿を同時に行うため，最も難度の高い問題の 1 つとされている．この問題が解決されれば時空間的な需要予測が可能となるため，タクシー配車やライドシェアの効率化，バイクシェアサービスの車両再配置，宿泊施設の宿泊数予測などへの応用が期待される．

現在的なモニタリングシステムは，数百から数千のセンシングデバイスから構成され，複数種類のデータを観測する場合が多い．例えばニューヨーク市のあるバイクシェアサービスでは，344 個のバイクステーションから 30 分毎に返却あるいは貸出された自転車数が送信される．ただ，システム構築に大量のセンシングデバイスを必要とするため，安価だが安定性の低い機器が利用される場合が多く，デバイス故障，データ転送エラー，ストレージ故障などによるデータ欠損が発生しやすい [3]．そのため，データ欠損を扱いつつ大規模多種類の時空間データを処理するための技術が必要となる．

多変量時系列データの予測問題では，多変量自己回帰 (VAR) やガウス過程 (GP) [4] などが広く利用されている．これらの手法は，変数間の線形あるいは非線形の相関情報を利用し高い予測精度を示すが，パラメータ推定の計算量がデータ次元やデータ点数に対して指数的に増加するため，大規模データの解析には適さない [5]．

連絡先: koh.t@acm.org

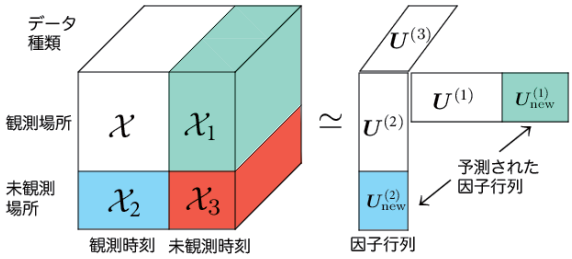


図 1: 時空間データ解析のためのテンソル分解モデル．$\mathcal{X}_1$，$\mathcal{X}_2$，$\mathcal{X}_3$ の推定は，センサー設置場所のデータ予測，センサー未設置場所のデータ補完と予測の問題に対応する．

大規模な時空間データの解析を行うための手法として，行列分解やその一般化であるテンソル分解が提案されている [5–7]．テンソル分解は，時空間データを高次元配列のテンソル $\mathcal{X}$ として扱い，テンソルを少数の因子に分解することでデータに含まれる重要な情報を抽出する手法である．テンソル分解の計算量はデータの観測時刻数，観測場所数，データ種類数に対して線形にスケールし，さらに欠損データが存在しても因子推定が可能なため，欠損値の復元に広く利用されてきた．図 1 に，時空間データを観測時刻，観測場所，データ種類数の 3 つのモードからなる 3 階テンソルとして扱い分解する例を示す．例えばタクシーの降車履歴データから新たなサービス提供場所での需要を予測する問題に取り組むとする．観測済みのデータを $\mathcal{X}$(白色ブロック) とすると，サービス提供場所での将来需要予測，サービス未提供場所の過去需要補完，将来需要予測の問題は，因子行列を用いて 3 つの異なるブロック $\mathcal{X}_1$(緑)，$\mathcal{X}_2$(青)，$\mathcal{X}_3$(赤) を推定する問題として扱える．

テンソル分解に時空間的な相関情報を取り入れるために，グラフ正則化技術を使用したテンソル分解が提案されている [7]．グラフ正則化は，因子内のパラメータが空間的に隣接する場所であったり前後する時刻に対応する場合，両者が類似した推定

値をもつように促すため，時空間的に滑らかな因子の抽出を可能にする．このようなアイディアは空間経済学の分野などで利用されているが，どのようなデータにも適用可能なグラフ構築方法は存在しないとされている [8]．また，既存のグラフ正則化では，グラフラプラシアンを使用するため，パラメータ間の正と負の相関を区別して使用できない．

これらの問題を解決するために，時間方向のグラフ正則化に自己回帰モデルの回帰係数を用いる Temporal regularized matrix factorization (TRMF) [6] が提案されている．TRMF は因子の推定と因子毎のパラメータ間の自己相関の学習を交互に行うことで，事前にグラフを構築する問題を回避した．さらに学習された自己回帰モデルを用いて将来の因子行列 $\boldsymbol{U}^{(1)}_{\mathrm{new}}$ の予測を行うことで，観測値の予測において既存法よりも大幅な性能改善を示した．しかし，TRMF は空間に対応する因子の学習ではグラフ正則化を用いるのみで，空間的な自己相関を学習する問題は扱っていない．

本研究では，センサーの未設置場所でのデータ補完と予測の問題を解決するために，空間上と時間方向のそれぞれの因子おいて自己回帰モデルの学習を行いつつ，因子の推定を行う新たなテンソル分解を提案する．まず，コンピュータビジョンの分野で提案された 2 次元自己回帰モデル [9] を拡張し，空間情報を用いた有向グラフ自己回帰正則化を提案し，これを TRMF を組み合わせることで自己回帰テンソル分解を提案する．さらに時空間データは観測値が非負値となる場合があるため，因子パラメータを非負に制約する非負自己回帰テンソル分解の提案も行う．次に，提案したテンソル分解が因子の推定を行うための効率的なアルゴリズムの導出を行う．実世界で観測されたタクシー履歴データおよびバイクシェアリングのデータを用いた実験を行い提案手法の優位性を示す．

2. テンソル分解

T 個の観測時刻，P 個の観測場所，M 種類のデータからなる時空間データの 3 階テンソルを $\mathcal{X} \in \mathbb{R}^{T\times P\times M}$ とし，データ内の観測要素の集合を $\Omega = \{(t,p,m) \mid x_{t,p,m} \text{ is observed.}\}$ とする．K ($\ll \min(T,P,M)$) 個の因子ベクトルからなる因子行列を $\boldsymbol{U}^{(1)} \in \mathbb{R}^{P\times K}$，$\boldsymbol{U}^{(2)} \in \mathbb{R}^{T\times K}$，$\boldsymbol{U}^{(3)} \in \mathbb{R}^{M\times K}$ とする．本研究では，テンソル分解モデルのなかで最もシンプルな CP 分解を用いる．正則化テンソル分解の経験損失関数 $\mathcal{L}(\boldsymbol{U}^{(1)},\boldsymbol{U}^{(2)},\boldsymbol{U}^{(3)})$ は，以下のように定義される．

$$\sum_{(t,p,m)\in\Omega} \Big(x_{p,t,r} - \sum_{k=1}^{K} u^{(1)}_{t,k} u^{(2)}_{p,k} u^{(3)}_{m,k}\Big)^2 + \sum_{n=1}^{3} \lambda_n g_n(\boldsymbol{U}^{(n)}). \tag{1}$$

なお，g_n，λ_n は正則化関数，正則化重みとした．(1) の第 1 項は観測値 $x_{t,p,m}$ を因子ベクトルの線形和 $\hat{x}_{t,p,m} = \sum_{k=1}^{K} u^{(1)}_{t,k} u^{(2)}_{p,k} u^{(3)}_{r,k}$ で近似した際の二乗誤差，第 2 項は正則化関数である．テンソル分解は，式 (1) の最小化問題を解き，局所最小解 $\{\boldsymbol{U}^{(1)^*},\boldsymbol{U}^{(2)^*},\boldsymbol{U}^{(3)^*}\}$ を求める．

テンソル分解では様々な正則化関数が利用されているが，非負領域への指示関数 $P_{\geq 0}(\boldsymbol{U}^{(n)}) = 0$ (if $u^{(n)}_{i,k} \geq 0, \forall(i,k)$), or $+\infty$ (otherwize) を用いるものは，非負テンソル分解 (Non-negatie Tensor Factorization: NTF) として知られている．NTF は因子ベクトルを非負に制約することで，非負観測値のみからなるテンソルの欠損値補完において高い精度を示し，また解釈の容易な因子を抽出するとされている [10, 11].

グラフラプラシアン正則化は，モードの特徴量をノード，特徴量間の類似度を重み付きエッジとするグラフを用いて，因子ベクトルがグラフ構造に対して滑らかとなるよう制約する技術である．n 番目のモードに対応する重み付き隣接行列を $\boldsymbol{W}^{(n)} \in \mathbb{R}^{I_n\times I_n}$ とすると，ラプラシアン行列 $\boldsymbol{L}^{(n)}$ は次のように定められる．$\boldsymbol{L}^{(n)} = \boldsymbol{D}^{(n)} - \boldsymbol{W}^{(n)}$, この時，$\boldsymbol{D}^{(n)}$ は $\boldsymbol{W}^{(n)}$ の行毎の要素和を対角成分にもつ対角行列とする．するとグラフラプラシアン正則化の正則化関数は $g_n(\boldsymbol{U}^{(n)}) = \sum_{k=1}^{K} \boldsymbol{u}^{(n)\top}_k \boldsymbol{L}^{(n)} \boldsymbol{u}^{(n)}_k$ となる．グラフラプラシアン正則化は，特徴量の時間や空間の構造を表現したグラフを利用することで時空間データの欠損値補完に高い精度を示すが，重みを事前に設定する必要がある．

2.1 自己回帰モデルと正則化

VAR は，多変量時系列の相関をもちいて将来の観測値を予測する手法である．時刻 t に対応する因子行列の行ベクトルを $\boldsymbol{u}^{(1)}_t \in \mathbb{R}^K$, ラグセットを L, 回帰係数を $A = \{\boldsymbol{A}_l \in \mathbb{R}^{K\times K} \mid l \in L\}$ とする．VAR は $\boldsymbol{u}^{(1)}_t$ を過去の列ベクトルの重み付き線形和と多変量ガウス分布からサンプリングしたノイズベクトル $\boldsymbol{\epsilon}_t$ を用いて，次のように近似する．$\boldsymbol{u}^{(1)}_t = \sum_{l\in L} \boldsymbol{A}_l \boldsymbol{u}^{(1)}_{t-l} + \boldsymbol{\epsilon}_t$. TRMF [6] は，VAR の回帰係数を時刻モードのグラフラプラシアンの重みに用いた正則化関数を用いることで，グラフの重みの事前設計を回避し，さらに将来の因子ベクトルの予測を行う技術である．

$$\frac{1}{2}\sum_{t=\bar{L}}^{T} \Big\|\boldsymbol{u}^{(1)}_t - \sum_{l\in L} \boldsymbol{A}_l \boldsymbol{u}^{(1)}_{t-l}\Big\|_2^2 + \frac{\eta}{2}\sum_{t=1}^{T} \|\boldsymbol{u}^{(1)}_t\|_2^2, \tag{2}$$

なお，$\bar{L} = 1 + \max(L)$ とし，η は重みパラメータとした．

2 次元自己回帰モデル (2D-AR) [9] は，コンピュータビジョンで提案された画像の欠損値補完のための技術である．ある画像に対応するベクトルを $\boldsymbol{y} \in \mathbb{R}^P$ とし，ベクトルの要素 y_p は (i,j) 番目のピクセルの観測値とする．L 階の空間ラグの集合を $E = \{(r,s) \mid 1 \leq r < L \cup 1 \leq s < L\}$，回帰係数を $B = \{b_{r,s} \mid (r,s) \in E\}$ と定める．2D-AR は $\boldsymbol{y}$ の観測値を近傍の観測値の線形和と多変量ガウス分布からサンプリングしたノイズベクトルを用いて $y_{i,j} = \sum_{(r,s)\in E} b_{r,s} y_{i+r,j+s} + \epsilon$ として定められる．画像欠損値の補完において 2D-AR は優れた性能を示すことが知られているが，このモデルは観測場所が格子状に並ぶことを前提としており，非格子状のデータ解析には適用できない．

3. 自己回帰テンソル分解

テンソル分解の空間モードと時間モードの因子ベクトルに自己回帰正則化を導入した自己回帰テンソル分解を提案する．提案手法の損失関数 $\mathcal{L}(\boldsymbol{U}^{(1)},\boldsymbol{U}^{(2)},\boldsymbol{U}^{(3)},A,B)$ を次のように定める．

$$\begin{aligned}&\|P_\Omega(\mathcal{X} - \mathcal{C}\times_1 \boldsymbol{U}^{(1)} \times_2 \boldsymbol{U}^{(2)} \times_3 \boldsymbol{U}^{(3)})\|_2^2 \\ &+ \lambda_1 g_1(\boldsymbol{U}^{(1)}, A) + \lambda_2 g_2(\boldsymbol{U}^{(2)}, B),\end{aligned} \tag{3}$$

このとき，$g_1, g_2, P_\Omega(\cdot)$ は，それぞれ，自己回帰正則化関数 [6], 次節で提案する空間自己回帰正則化関数, 観測値と推定値の誤差関数である．A および B は，自己回帰正則化関数および空間自己回帰正則化関数の回帰係数である．$\mathcal{X}$ の観測値が非負の場合には, 非負制約関数 $\sum_{n=1}^{3} P_{\geq 0}(\boldsymbol{U}^{(n)})$ を加え，非負自己回帰テンソル分解とする．自己回帰テンソル分解は式 (3.2) を最小化する $\arg\min_{\boldsymbol{U}^{(1)},\boldsymbol{U}^{(2)},\boldsymbol{U}^{(3)},A,B} \mathcal{L}$ を求めるものとする．

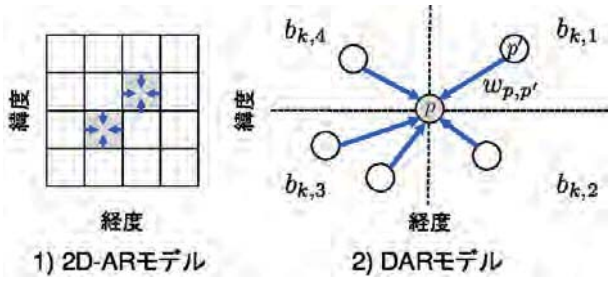


図 2: 2 次元自己回帰モデルと空間自己回帰正則化モデル

3.1 空間自己回帰正則化

時空間データの観測場所は，行政区分や都市構造の影響を受けるため，格子状になるとは限らない．そこで観測場所が格子状・非格子状にいずれの場合にも対応可能な自己回帰モデルとして，有向自己回帰正則化 (DAR: directed autoregressive regularizer) を提案する．DAR の仮定は非常にシンプルなものである，つまり，回帰係数は観測場所間の方角によって定まり，ある観測値は周囲の観測値を回帰係数と距離重みで線形和によって近似できるとする．DAR と 2DAR を図 2 に示す．DAR は 2π の角度を N 個の区分に分割し，区分ごとに回帰係数を定める．

DAR の回帰係数を $B = \{b_{k,n} \mid \forall(k,n)\}$，$p$ 番目の観測場所とリンクを持つ観測場所の集合を E_p，p 番目と p' 番目の観測場所の正規化距離重みを $w_{p,p'} \in \mathbb{R}_{\geq 0}$ where $\sum_{p' \in E_p} w_{p,p'} = 1$ とする．DAR 正則化関数 $g^{\mathrm{DAR}}(\boldsymbol{U}^{(2)}, B)$ を次のように定める．

$$\sum_{k=1}^{K}\sum_{p=1}^{P}\left(u^{(2)}_{p,k} - \sum_{p' \in E_p} b_{k,n_{p'}} w_{p,p'} u^{(2)}_{p',k}\right)^2 + \frac{\eta}{2}\|\boldsymbol{u}^{(2)}_k\|_2^2, \quad (4)$$

このとき，$n_{p'}$ は p 番目の観測場所から p' 番目の観測場所への角度区分とする．上式は，行列 $\bar{\boldsymbol{B}}_k \in \mathbb{R}^{P \times P}$

$$\bar{b}_{k,p,p'} = \begin{cases} b_{n_{p'},k} w_{p,p'} & (\text{if } p' \in E_p), \\ 0 & (\text{otherwise}) \end{cases}, \quad (5)$$

を用いると，次のように式 (2) と同様に変形できる．$\sum_{k=1}^{K}\left\|\boldsymbol{u}^{(2)}_k - \bar{\boldsymbol{B}}_k \boldsymbol{u}^{(2)}_k\right\|_2^2 + \frac{\eta}{2}\|\boldsymbol{u}^{(2)}_k\|_2^2$.

3.2 パラメータ推定

式 (3.2) の最小化問題は，次と等価である [12].

$$\min_{\boldsymbol{U}^{(1)},\boldsymbol{U}^{(2)},\boldsymbol{U}^{(3)},A,B,\boldsymbol{Z}} \|\mathcal{Z} - \mathcal{C} \times_1 \boldsymbol{U}^{(1)} \times_2 \boldsymbol{U}^{(2)} \times_3 \boldsymbol{U}^{(3)}\|_2^2$$
$$+ \lambda_1 g_1(\boldsymbol{U}^{(1)}, A) + \lambda_2 g_2(\boldsymbol{U}^{(2)}, B) \text{ s.t. } P_\Omega(\mathcal{X} - \mathcal{Z}). \quad (6)$$

上式の損失関数は非凸関数であるが，パラメータ $\{\boldsymbol{U}^{(1)}, \boldsymbol{U}^{(2)}, \boldsymbol{U}^{(3)}, A, B, \boldsymbol{Z}\}$ に関しては凸関数 (multi-convex) となっている．紙面の都合上，詳細は割愛するが，それぞれパラメータについての損失関数は 2 次関数となるため，各パラメータについて最小二乗法を行い交互にパラメータ更新することで局所最小解が得られる [13].

4. 実験

ニューヨーク市で観測されたタクシー降車履歴データとバイクシェアリング返却履歴データ *1 を用いた実験を行う．タクシー降車履歴データでは，ニューヨーク市内を 500m^2 からなる 640 個のメッシュに分割し，30 分毎のメッシュ内での降車数を予測対象とした．バイクシェアリングデータでは，344 個のバイクステーションで 30 分毎に返却された自転車の数を予測対象とした．データ毎に観測場所の 10% を乱択してセンサー未設置とし，観測期間の最終週を取り出し各日を予測対象のデータした．パラメータの推定は，センサー設置場所で観測された予測対象日から 1 週間前までをトレーニングデータを用いて行った．提案手法である自己回帰テンソル分解 (DAR) と非負自己回帰テンソル分解 (DAR+NN) の性能を，TRMF [6], 高速低ランク回帰モデル (FAST) [5], ガウス過程 (GP) [4] と比較した．

空間自己回帰正則化関数では，観測場所の k 近傍に対し，距離重みを $w_{p,p'} = \exp(-\|\boldsymbol{r}_p - \boldsymbol{r}_{p'}\|_2^2/\sigma^2)$ [14] とし正規化を行った．$\boldsymbol{r}_p$ は p 番目の観測場所の GPS 情報，σ はスケールパラメータで，今回は $\sigma = 100$ に設定した．FAST と TRMF の空間モードのグラフラプラシアンには，正規化していない距離重みを使用した．提案手法のハイパーパラメータである角度区分数 N と k 近傍数は $\{4, 8\}$，正則化重みは λ_1，λ_2 は $\{0, 0.1, 1.0, 10.0\}$ から，5 交差検定によって選択した．GP では乱択した 5,000 点をトレーニングデータとし，最尤推定によってハイパーパラメータを最適化した．図.1 で示した各問題における精度を相対絶対値誤差 $(1/|\Omega|)\sum_{(p,t,m)\in\Omega}|x_{p,t,m} - \hat{x}_{p,t,m}|/\sum_{(p,t,m)\in\Omega}|x_{p,t,m}|$ によって評価した．

表 1 と 2, 7 日文の試行から得られた相対絶対値誤差の平均

表 1: タクシーデータの予測誤差

手法	未設置場所予測	未設置場所補完	設置場所予測
DAR	$0.569_{\pm 0.079}$	$0.509_{\pm 0.002}$	$0.317_{\pm 0.107}$
DAR+NN	$\mathbf{0.568_{\pm 0.091}}$	$\mathbf{0.499_{\pm 0.001}}$	$\mathbf{0.312_{\pm 0.108}}$
TRMF	$0.996_{\pm 0.041}$	$0.997_{\pm 0.001}$	$0.350_{\pm 0.128}$
FAST	$1.095_{\pm 0.010}$	$1.056_{\pm 0.002}$	$0.653_{\pm 0.005}$
GP	$1.256_{\pm 0.056}$	$1.095_{\pm 0.060}$	$1.683_{\pm 0.188}$

表 2: バイクシェアリングデータの予測誤差

手法	未設置場所予測	未設置場所補完	設置場所予測
DAR	$0.843_{\pm 0.116}$	$\mathbf{0.677_{\pm 0.021}}$	$0.760_{\pm 0.127}$
DAR+NN	$\mathbf{0.821_{\pm 0.089}}$	$0.678_{\pm 0.018}$	$0.818_{\pm 0.295}$
TRMF	$1.065_{\pm 0.210}$	$0.845_{\pm 0.032}$	$0.744_{\pm 0.101}$
FAST	$0.910_{\pm 0.055}$	$0.818_{\pm 0.015}$	$\mathbf{0.710_{\pm 0.058}}$
GP	$3.589_{\pm 5.801}$	$0.743_{\pm 0.065}$	$3.701_{\pm 6.139}$

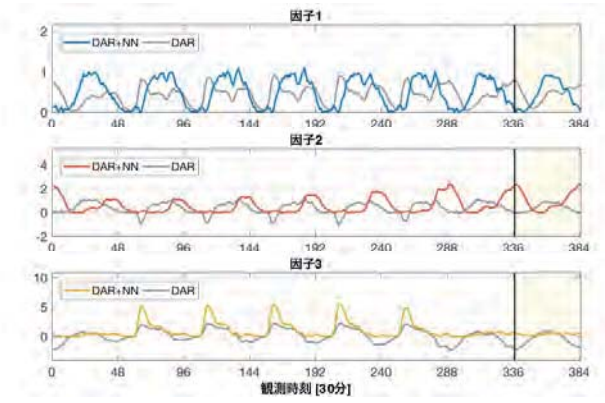


図 3: 時間モードの因子ベクトル (黄色背景はテスト期間)

*1 http://www.nyc.gov/html/tlc/html/about/trip_record_data.shtml, http://www.citibikenyc.com/

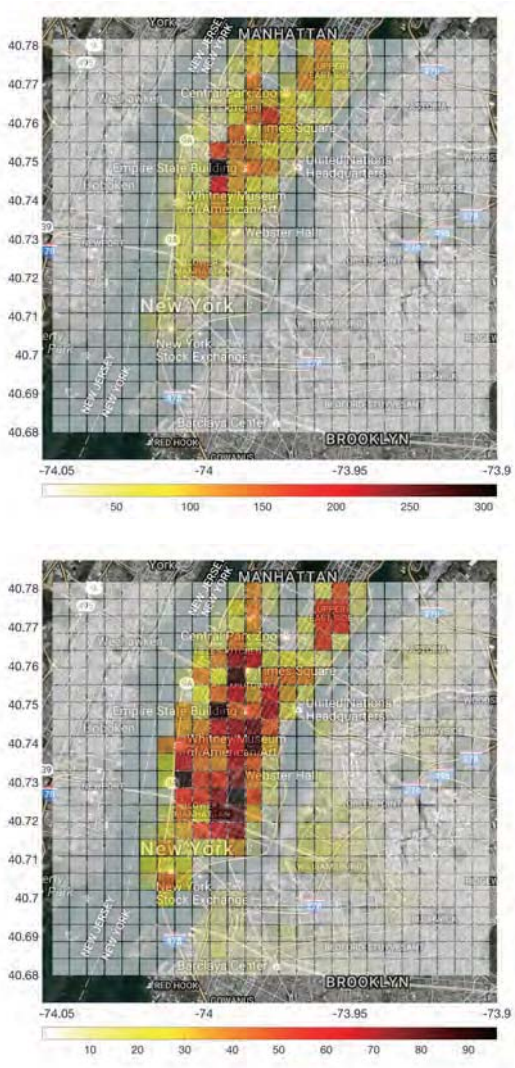


図 4: DAR+NN の空間モードの因子ベクトル (因子 1,2)

と標準偏差を示す．最も高い性能を示した手法の数値を太字とする．表より，提案手法 (DAR, DAR+NN) は観測場所が格子状あるいは非格子状であるかに関わらず，センサー未設置場所のデータ補完および予測において，既存法よりも高い性能を示した．特に予測問題において提案手法は，それぞれの実験データで 42.9%, 9.8% と大幅に予測誤差の改善を達成した．バイクシェアリングデータのセンサー設置場所での予測では FAST が高い性能を示しており，データが完全な場合での低ランク回帰モデルの有効性が示唆された．

提案法の定性的な評価を行うために，タクシーデータから推定された因子の可視化を行う．図 3 に時間モードの 3 つの因子ベクトルを非負制約ありは色線，非負制約なしは灰色で示す．さらに対応する空間モードの非負制約ありの因子ベクトルのヒートマップを図 4 に示す．図 3 より，因子ベクトル毎に異なるダイナミクスが抽出されていることがわかる．特に非負制約ありの場合は，それぞれのピークから日中，夜間，平日の午前中に出現するパターンであるとわかる．さらに図 4 より，因子 1 ではエンパイアステートビル周辺で因子が高い値をもつため，日中に都心部へ移動する降車パターンが抽出されたことが確認できた．因子 2 では異なる降車パターンが抽出されており，マンハッタン内およびブルックリンエリアで高い値が現れている．これは夜間での移動と帰宅時に現れる降車パターンが抽出された．以上から，提案手法によってニューヨーク市内でのタクシー降車の特徴的なパターンの抽出が可能になり，これらが予測精度の改善に貢献したものと考えられる．

5. おわりに

本研究では，センサーの未設置場所でのデータ補完と予測の問題を解決するために，自己回帰テンソル分解およびパラメータ推定法を提案した．タクシー降車履歴データおよびバイクシェアリングのデータを用いた実験から，提案手法による補完および予測問題での精度向上を確認した．さらに因子ベクトルの可視化を行い，提案手法の定性的な有効性を定性的に確認した．今後は非定常かつ非線形な自己相関を学習するテンソル分解，低ランク回帰モデルへの拡張などを検討していく．

参考文献

[1] L. Anselin, “Thirty years of spatial econometrics,” *Papers in regional science*, vol. 89, no. 1, pp. 3–25, 2010.

[2] X. Zhou, S. Shekhar, and R. Y. Ali, “Spatiotemporal change footprint pattern discovery: an inter-disciplinary survey,” *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, vol. 4, no. 1, pp. 1–23, 2014.

[3] L. Li, J. McCann, N. S. Pollard, and C. Faloutsos, “Dynammo: Mining and summarization of coevolving sequences with missing values,” in *Proc. of SIGKDD*, 2009, pp. 507–516.

[4] C. E. Rasmussen, “Gaussian processes for machine learning.” MIT Press, 2006.

[5] M. T. Bahadori, Q. R. Yu, and Y. Liu, “Fast multivariate spatio-temporal analysis via low rank tensor learning,” in *Proc. of NIPS*, 2014, pp. 3491–3499.

[6] H.-F. Yu, N. Rao, and I. S. Dhillon, “Temporal regularized matrix factorization for high-dimensional time series prediction,” in *Proc. of NIPS*, 2016, pp. 847–855.

[7] N. Rao, H.-F. Yu, P. K. Ravikumar, and I. S. Dhillon, “Collaborative filtering with graph information: Consistency and scalable methods,” in *Proc. of NIPS*, 2015, pp. 2107–2115.

[8] L. Anselin, “Under the hood issues in the specification and interpretation of spatial regression models,” *Agricultural economics*, vol. 27, no. 3, pp. 247–267, 2002.

[9] S. R. Dubois and F. H. Glanz, “An autoregressive model approach to two-dimensional shape classification,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, no. 1, pp. 55–66, 1986.

[10] A. Cichocki, R. Zdunek, A. H. Phan, and S.-i. Amari, *Nonnegative matrix and tensor factorizations: applications to exploratory multi-way data analysis and blind source separation.* John Wiley & Sons, 2009.

[11] Y. Xu, W. Yin, Z. Wen, and Y. Zhang, “An alternating direction algorithm for matrix completion with nonnegative factors,” *Frontiers of Mathematics in China*, vol. 7, no. 2, pp. 365–384, 2012.

[12] J.-F. Cai, E. J. Candès, and Z. Shen, “A singular value thresholding algorithm for matrix completion,” *SIAM Journal on Optimization*, vol. 20, no. 4, pp. 1956–1982, 2010.

[13] Y. Xu and W. Yin, “A globally convergent algorithm for nonconvex optimization based on block coordinate update,” *Journal of Scientific Computing*, pp. 1–35, 2017.

[14] A. Y. Ng, M. I. Jordan, and Y. Weiss, “On spectral clustering: Analysis and an algorithm,” in *Proc. of NIPS*, 2002.

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

ストリームの適応記憶型オンライン予測

Online prediction of self-adaptive memory over data stream

山口 晃広 *1 Akihiro Yamaguchi　真矢 滋 *1 Shigeru Maya　稲木 達哉 *1 Tatsuya Inagi　植野 研 *1 Ken Ueno

*1株式会社東芝 研究開発センター システム技術ラボラトリー
*1Corporate Research & Development Center TOSHIBA Corporation

We propose online prediction method for data streams with heterogeneous concept drift. The proposed method forecasts short-range future values by integrating both short-term memory of various window sizes and long-term memory of consistent clusters adaptively. On synthetic datasets with heterogeneous concept drift and real-world datasets of traffic flow, stock prices, and electricity demand, experimental results show superior accuracy without optimizing meta-parameters among datasets over several baseline methods.

1. はじめに

IoT の普及に伴い，変化する環境の中で終わりなく流れ続けるデータストリーム（以下ストリーム）をリアルタイムに分析する技術に関心が高まっている．ストリームの分析では，データ量が増え続けても記憶容量を一定以下に抑える必要がある．加えて，環境の変化などによりデータの傾向が時間変化する性質であるコンセプトドリフトへの対応も課題となる．コンセプトドリフトには急激に変化するタイプ，徐々に変化するタイプ，類似したパターンが繰り返し発生するタイプなどがあり [1]，それらに対応する技術への関心が高まっている．スライディングウインドウ（以下ウインドウ）は，これに対応する良く知られた記憶管理であり，短期的に最近のデータを保持する．しかし，ウインドウの長さは，長いとデータの急激な変化に適応することが難しく，逆に短いとノイズの影響を受けやすい．また，古いデータを捨ててしまうため，長期的に同様のパターンが繰り返し発生する場合に対応が難しい．近年，ウインドウの長さを適応的に変える短期記憶に加えて古いデータを長期記憶に圧縮して保持するクラス分類手法が提案され，実データや様々なコンセプトドリフトを持つ人工データにおいて従来手法と比較して優れた分類性能を達成している [2, 3]．

一方，交通流，株価，電力消費量などのストリームでは，近い将来の値をリアルタイムに予測するオンライン予測技術が求められる．例えば交通流の予測では，5 分間隔で配信される交通流の情報から数ステップ先の交通流を予測することで，リアルタイムな自動車のルート案内や交通制御などへの活用が期待される．これらの予測では，ウインドウを用いて短期的なデータから回帰により将来の値を予測する手法がよく研究されている．線形回帰を用いる手法が良く知られているが，[4] など非線形なカーネル回帰をウインドウのデータに適用する研究なども行われている．また，コンセプトドリフトに対応するため複数のウインドウ長で予測しその結果を適応的に重み付けて予測する手法も提案された [5]．一方，過去の履歴を用いる手法として，過去に出現した波形を保持しておき，現在の波形と類似する波形を用いて将来の値を予測する手法が，交通流，株価，電力消費量などの予測に用いられている [6]．

しかしながら，従来のオンライン予測手法では様々なコンセプトドリフトを持つストリームを精度よく予測することは難しい．ウインドウを用いる従来のオンライン予測手法では過去の履歴を用いないため，類似したパターンが長期的に繰り返し発生する場合に過去の情報を有効に活用できない．一方，波形など過去の履歴を用いる従来手法では予測前に過去の一定期間から履歴をあらかじめ抽出するため，コンセプトドリフトを考慮しない．これに対応する自明な方法として，固定長のウインドウでストリームから得られる波形を管理する方法が挙げられる．しかし，データに合わせたウインドウ長のチューニングが必要である．[2, 3] ではコンセプトドリフトを考慮しながら長期的な記憶を圧縮して保持する．しかし，[2, 3] はクラス分類が対象である．また，短期記憶と長期記憶に矛盾が発生した場合には長期記憶から矛盾した部分を取り除き短期記憶で上書きしてしまうため，取り除かれた情報をそれ以降活用できない．

本研究では，様々なコンセプトドリフトに対応するオンライン予測手法を提案する．短期記憶と長期記憶を適応的に用いるクラス分類手法 [2, 3] のアイデアを発展させて，本提案ではオンライン予測に適応する．特に [2, 3] の記憶に矛盾が発生した場合に古い記憶が消えてしまう課題を克服するため，長期記憶を矛盾が無いように複数のクラスタに分けて管理する．この適応型記憶でストリームから得られる波形を管理し，類似波形の局所回帰により将来を予測する．これにより，非線形なストリームやデータ傾向の変化に柔軟に対応する．様々なコンセプトドリフトを持つ人工データと，交通流，株価，電力消費量の実データを用いた評価により，提案手法ではメタパラメータのチューニング無しに [4, 5] を含む比較手法と比べて高い予測性能が得られることを確認する．

2. 問題設定

ストリームはタプルの列 $(\mathbf{x}_1, \mathbf{x}_2, \cdots, \mathbf{x}_t, \cdots)$ であり，タプル $\mathbf{x}_i$ は J 次元ベクトル (i.e.,$\mathbf{x}_i = (\mathbf{x}_{i,1}, \mathbf{x}_{i,2}, \cdots, \mathbf{x}_{i,J})$) である．現在時刻 t において N ステップ先の値を予測する場合，オンライン予測問題とは $\mathbf{x}_{t+N}$ のある変数 j の予測値 $\hat{\mathbf{x}}_{t+N,j}$ を求める問題である．予測ステップ N，タプルの次元 J，予測対象となる変数 j は，ユーザにより予測前に与えられる定数である．以降，$y_{i+N} = \mathbf{x}_{i+N,j}$ 及び $\hat{y}_{i+N} = \hat{\mathbf{x}}_{i+N,j}$ と記述する．本研究では近い将来の予測を対象とし N は 1 から 5 ステップ程度を想定する．時刻 t に $\hat{y}_t$ が予測された N ステップ後に，y_t が得られる．これにより予測器は予測値 $\hat{y}_t$ と観測値

連絡先: 山口晃広，株式会社東芝 研究開発センター システム技術ラボラトリー，〒 212-8582 川崎市幸区小向東芝町 1，akihiro5.yamaguchi@toshiba.co.jp

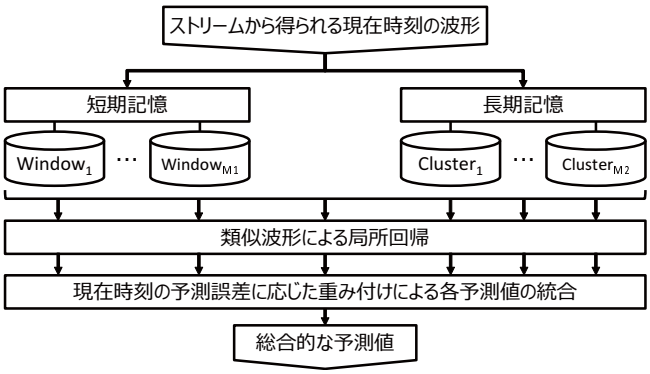


図 1: 提案する予測手法の全体像

y_t との誤差である予測誤差 $(\hat{y}_t - y_t)^2$ を測定できる．

時刻 t における長さ D の波形は $\mathbf{s}_t = (\mathbf{x}_{t-D+1}, \cdots, \mathbf{x}_t)$ であり $D \times J$ 次元のベクトルである．記憶には，波形 $\mathbf{s}_i$ と N ステップ先の値 y_{i+N} の組からなる $D \times J + 1$ 次元のベクトル $\mathbf{z}_i = (\mathbf{s}_i, y_{i+N})$ がサンプルとして保持される．記憶全体で保持できる最大サンプル数は予測前にあらかじめ決まっている．

3. 提案手法

本節では，提案手法の全体構成と長期記憶を順に説明する．

3.1 全体構成

図 1 のように記憶管理は短期記憶と長期記憶からなる．短期記憶はサンプルを要素とするウインドウで管理される．[5] と同様に複数のウインドウ長を用いることで様々なサンプル集合で予測することができる．一方，長期記憶ではウインドウに入りきらない古いサンプルを圧縮して保持する．特に [2, 3] と異なり，本提案では長期記憶を矛盾の無いようにクラスタリングする．本来，波形 $\mathbf{s}_t$ が類似すれば N ステップ先の観測値 y_{t+N} も類似し同様の傾向を示すはずである．しかし，そのような傾向を示さない場合には，それらのサンプルの間に矛盾があると考え，それらを別々のクラスタで管理する．その結果，各クラスタ内では矛盾の無いようにサンプルが保持される．長期記憶については 3.2 節で詳しく述べる．

記憶からサンプル $(\mathbf{s}_i, y_{i+N})$ の集合が適切に与えられれば，予測手法は以下のような類似波形を用いた局所回帰により実現される．まず，現在時刻 t_1 における波形 $\mathbf{s}_{t_1}$ に類似する K 個の波形 $\mathbf{s}_{i_1}, \mathbf{s}_{i_2}, \cdots, \mathbf{s}_{i_K}$ をサンプル集合から取り出す．次に，$\mathbf{s}_{i_1}, \mathbf{s}_{i_2}, \cdots, \mathbf{s}_{i_K}$ から $y_{i_1+N}, y_{i_2+N}, \cdots, y_{i_K+N}$ を推定する回帰式を求め，その回帰式に現在時刻の波形 $\mathbf{s}_{t_1}$ を代入することで N ステップ先の予測値 $\hat{y}_{t_1+N}$ を予測する．この方法はカレンダー情報の併用などのドメイン固有の部分を取り除いた類似波形の局所回帰による従来手法 [6] と同様のアイデアである．但し，従来手法と異なり本研究ではウインドウ長を短くしてコンセプトドリフトに対応する．これによるオーバーフィットを避けるため回帰式には正則化項を加えたリッジ回帰を用いる．このように局所的なサンプルに基づいて予測を行うことで，非線形なストリームに対応するだけでなくデータの傾向が局所的に変わる場合にも素早く柔軟に対応することが期待される [7].

各記憶で管理する様々なサンプル集合を用いて予測を行い，その結果を適応的に重みづけて統合し最終的な予測値を出力する．予測に用いるサンプル集合は，異なるウインドウ長で区切られた短期記憶のサンプル集合，長期記憶の各クラスタを構成するサンプル集合，長期記憶の全体のサンプル集合，短期記憶と長期記憶の全体のサンプル集合のうち，サンプル数が一定数（$L_{\min}$）以上のものである．各サンプル集合を用いて現在時刻 t から N ステップ前の波形 $\mathbf{s}_{t-N}$ を用いて予測値 $\hat{y}_t$ を算出し，[5] のように予測誤差が小さいサンプル集合を重視するように重み付けを決定する．次に，各サンプル集合に対して現在時刻 t の波形 $\mathbf{s}_t$ を用いて改めて予測して重み付け平均を最終予測値とする．このように，現在時刻の予測誤差に基づき予測結果の重み付けを適応的に調整することで，メタパラメータのチューニング無しに様々なコンセプトドリフトを持つストリームに対応する．

3.2 長期記憶

短期記憶から溢れた古いサンプルは長期記憶に保持される．長期記憶はクラスタ内に矛盾が無いように複数のクラスタで分割管理され，各クラスタではサンプルを圧縮することで長期記憶の全サンプル数を $L_{\max}$ 以下に抑える．

短期記憶からサンプルが送られてきたとき，長期記憶の処理は 2 つに分けられる．1 つ目の場合は，短期記憶から初めて長期記憶にサンプルが保持される時と長期記憶の記憶容量が一杯になった時に行われるクラスタの構築処理である．2 つ目の場合は，長期記憶にサンプルが既に保持されておりその記憶容量に余裕がある時に行われるクラスタの逐次更新処理である．以降ではそれぞれの処理を説明する．

3.2.1 クラスタの構築処理

波形 $\mathbf{s}_{i_1}$ と $\mathbf{s}_{i_2}$ が類似するにも関わらず N ステップ先の観測値 y_{i_1+N} と y_{i_2+N} が互いに異なる場合にサンプル $\mathbf{z}_{i_1}$ と $\mathbf{z}_{i_2}$ を別々のクラスタに割り当てる．ここでは，長期記憶に保持される全サンプルを対象にする．但し，初めて長期記憶にサンプルを保持する時は短期記憶の全サンプルを長期記憶へコピーしそれらを対象にする．サンプル $(\mathbf{s}_{i_1}, y_{i_1+N})$ と $(\mathbf{s}_{i_2}, y_{i_2+N})$ の距離を式 1 で定義し，k-means++[8] のクラスタリング手法を用いて M_{LTM} 個のクラスタを生成する．

$$|y_{i_1+N} - y_{i_2+N}| \exp\left(\frac{-\alpha||\mathbf{s}_{i_1} - \mathbf{s}_{i_2}||^2}{\mathrm{var}(\{\mathbf{s}_i\}_{(\mathbf{s}_i, y_{i+N}) \in \mathrm{LTM_{all}}})}\right), \quad (1)$$

ここで，$\mathrm{LTM_{all}}$ は長期記憶に保持されているサンプル集合であり，var(.) は分散を表し，α は正の定数である．

次に，先のクラスタリング処理で構築した各クラスタに含まれるサンプルを圧縮する．$m = 1, 2, \cdots, M_{\mathrm{LTM}}$ に対して，LTM_m は m 番目のクラスタのサンプル集合を表す．各 m 番目のクラスタに対して，$\frac{L_{\max}}{M_{\mathrm{LTM}}} \leq |\mathrm{LTM}_m|$ ならばミクロクラスタ数が $\frac{L_{\max}}{2M_{\mathrm{LTM}}}$ 個となるように LTM_m に k-means++[8] によるクラスタリングを適用する．その距離にはサンプル間のユークリッド距離を用いる．クラスタリングを行った場合，LTM_m はミクロクラスタの重心からなる集合に置き換えられる．

3.2.2 クラスタの逐次更新処理

本処理では，3.2.1 節の処理によりクラスタが構築されており長期記憶の記憶容量にも空きがある場合を扱う．サンプル $(\mathbf{s}_i, y_{i+N})$ が長期記憶に送られてきた時に，長期記憶に矛盾が生じないように適切なクラスタへ $(\mathbf{s}_i, y_{i+N})$ を挿入する．具体的には，$\hat{y}_{i+N}$ を各クラスタのサンプル集合で予測したとき，予測誤差が最小となるクラスタを選ぶ．もしそのクラスタにサンプルの数が十分にあれば（サンプル数が $L_{\min}$ 以上の場合），類似波形による局所回帰で $\hat{y}_{i+N}$ を予測する．もしそのクラスタにサンプル数が十分になければ（サンプル数が $L_{\min}$ 未満の場合），そのサンプル集合から $\mathbf{s}_i$ の類似波形を取り出しそれらの N ステップ先の平均値を予測値 $\hat{y}_{i+N}$ とする．

表 1: 本実験で統一して用いるメタパラメータの値

$D = 5$	波形の長さ
$K = 100$	k 近傍法における近傍の数
$\lambda = 1$	リッジ回帰における正則化項の係数
$L_{\min} = 200$	予測に用いられる最小サンプル数
$L_{\max} = 500$	各記憶に保持できる最大サンプル数
$M_{\mathrm{LTM}} = 3$	長期記憶のクラスタ数
$\alpha = 10^{-3}$	クラスタリングの距離における式 1 の定数

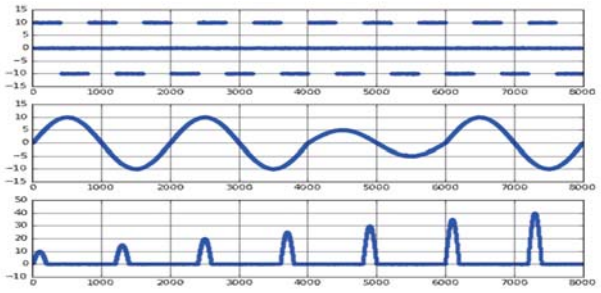


図 2: 人工データセット（1 行目 : SuddenReocc, 2 行目 : GradualAReocc, 3 行目 : GradualBReocc）

4. 実験評価

本実験全体を通して，提案手法のメタパラメータには表 1 の値を統一して用いる．短期記憶のウインドウ長は 200, 250, 350, 500 からなり，短期記憶と長期記憶を合わせて保持できる最大サンプル数は $2L_{\max}$ となる．また，予測ステップ数 N が 5 でタプルの次元 J が 1 の場合で実験する．

4.1 比較手法

本実験では，3. 節で述べた全ての機能を実現する提案手法（**FullFunc**）を以下の手法と比較する．

NoCluster は，提案手法において長期記憶を複数に分けず [2, 3] のように 1 つのクラスタで管理する．**NoLTM** は，提案手法において短期記憶と長期記憶を分けずに短期記憶のみを用いる．短期記憶のウインドウ長は最大 $2L_{\max}$ まで適応的に変える．**ARWin** は，最近のデータをウインドウに保持し適応的にウインドウ長を変えて線形回帰を行う従来手法である [5]．ウインドウ長は $3, 4, \cdots, 10$ の範囲で変える．**KRWin** は，最近のデータを固定長のウインドウに保持しカーネルリッジ回帰により非線形回帰を行う従来手法である [4]．各データセットに対して 1000–2000 ステップの期間で精度が最良のメタパラメータを選ぶ．**NRWin** は，固定のウインドウ長を用いた類似波形による局所回帰であり，従来手法 [6] からドメイン固有の部分を取り除いた手法である．ウインドウ長は提案手法で変更する範囲のウインドウ長か $2L_{\max}$ である．

4.2 データセット

4.2.1 人工データ

（Sudden）急激に変化するタイプ,（GradualA）ストリーム全体が徐々に変化するタイプ,（GradualB）部分的な波形パターン（時系列モチーフ）が成長していくタイプ,（Reocc）同様のパターンが繰り返し発生するタイプのコンセプトドリフトを持つ図 2 に示す以下の 3 つの人工データを用いる．

SuddenReocc は，急激な変化が繰り返し発生する．短期間（20 ステップごと）にコンセプトドリフトが発生する．それによる y_t の変化は $(0, \pm 10, 0, \cdots)$ を繰り返す．ここで記号 $(\pm)$ は y_t が 0 と ± 10 へ 10 回変化するごとに符号を反転する．

GradualAReocc は，ストリーム全体の傾向が滑らかに変化する．傾向の変化は非線形であり，振幅が $(10, 10, 5, 10)$ からなる正弦曲線を 1 周期ごとにつなぎ合わせた曲線である．

GradualBReocc は，時系列モチーフが徐々に成長する．時系列モチーフの形状は上に凸な半周期分の正弦曲線であり，その高さは $(10, 15, 20, \cdots)$ と成長する．時系列モチーフの出現間隔は 1000 ステップ間隔であり $L_{\max}$ より長い．

4.2.2 実データ

交通流，電力，株価における以下の実データを用いる．

Traffic は，California 州の道路を走行する車速度である [*1]．観測場所は VDS: 407750 であり，1 番目のレーンを表す Lane 1 Speed (mph) 列のみを用いる．2017/08/13–2017/08/26 の期間を用いて，総ステップ数は 4,031 ステップである．

Stock は，日経株価の終値である [*2]．[5] と同様に終値に対応する Close 列のみを評価に用いる．1997/5/19–2017/5/15 の期間のデータを用いて，総ステップ数は 5,046 ステップである．

Electricity は，New South Wales 州の電力需要量である [*3]．本研究では nswdemand 列のみを用いる．期間は 1996/05/07–998/12/05 で，総ステップ数は 45,312 ステップである．

4.3 予測性能の比較結果

表 2 は，各手法が各データセットを予測したときの性能を示している．表 2 の括弧内の値は，各データセットの後半の期間における予測誤差を平均した値（平均誤差）である．様々な分野のデータセットを用いるため，データセットによって平均誤差のスケールに違いが生じる．そこで各データセットに対して，提案手法の平均誤差を 1 としたときの比較手法の平均誤差の倍率を評価し，表 2 の括弧以外の数値はその倍率を表す．その倍率を全データセットで平均した値を表 2 の Overall に示し，各手法の性能を Overall の値で評価する．NRWin*は固定のウインドウ長に*を用いた場合の従来手法 NRWin である．

データセット全体では，提案手法 (FullFunc, NoCluster) が最良の性能を示した．提案手法の中では，FullFunc，NoCluster, NoLTM の順に性能が良く，短期記憶と長期記憶を分けることと，長期記憶を矛盾の無い複数のクラスタに分けることの有効性をそれぞれ確認した．

従来手法の中では，NRWin が FullFunc と NoCluster に次いで性能が良かった．しかし，データセットにより最適なウインドウ長は異なるため，そのチューニングがデメリットとしてあげられる．一方，提案手法では，NRWin と同じく類似波形による局所回帰を用いながら，ウインドウ長の適応的な自動チューニングにより，そのデメリットを克服できる．ARWin は提案手法と同じくウインドウ長のチューニングを必要としない．しかし， ARWin は GradualBReocc 以外のデータセットでは提案手法と NRWin より予測性能は良くなかった．KRWin はストリーム全体の傾向が滑らかに変化する GradualAReocc では性能が良かったが，データセット全体では最も性能が悪かった．以上の従来手法の比較により，類似波形の局所回帰における予測性能への有効性を確認した．

4.4 記憶管理の結果

図 3 は，短期記憶（STM）と長期記憶の 3 つのクラスタ（LTM Cluster1, LTM Cluster2, LTM Cluster3）に保持されたサンプルを表示している．1–4 行は，それぞれ SuddenReocc, Traffic, Stock, Electricity のデータセットの場合を示してい

∗1 http://pems.dot.ca.gov/
∗2 https://finance.yahoo.com/quote/%5EN225/
∗3 https://moa.cms.waikato.ac.nz/datasets/

表 2: 予測性能の比較結果

	SuddenReocc	GradualAReocc	GradualBReocc	Traffic	Stock	Electricity	Overall
FullFunc	1.00 (1.8)	**1.00 (0.074)**	**1.00 (0.32)**	**1.00 (0.47)**	**1.00 (94.8)**	1.00 (535)	**1.00**
NoCluster	1.06 (1.9)	1.03 (0.076)	1.03 (0.33)	1.04 (0.49)	1.12 (106)	0.99 (531)	1.04
NoLTM	1.17 (2.1)	1.23 (0.091)	1.09 (0.35)	1.09 (0.51)	1.47 (139)	0.99 (531)	1.17
ARWin	1.44 (2.6)	1.35 (0.10)	1.06 (0.34)	1.64 (0.77)	2.91 (276)	1.20 (643)	1.60
KRWin	1.33 (2.4)	1.05 (0.078)	12.81 (4.1)	1.79 (0.84)	6.49 (615)	1.21 (649)	4.11
NRWin200	1.39 (2.5)	1.35 (0.10)	1.09 (0.35)	1.23 (0.58)	1.68 (159)	**0.98 (524)**	1.29
NRWin250	1.83 (3.3)	1.35 (0.10)	1.12 (0.36)	1.43 (0.67)	1.69 (160)	1.00 (537)	1.40
NRWin350	1.72 (3.1)	1.35 (0.10)	1.09 (0.35)	1.26 (0.59)	1.71 (162)	1.00 (537)	1.36
NRWin500	0.94 (1.7)	1.35 (0.10)	1.06 (0.34)	1.32 (0.62)	1.59 (151)	1.04 (554)	1.22
NRWin1000	**0.89 (1.6)**	1.31 (0.097)	1.06 (0.34)	1.19 (0.56)	1.46 (138)	1.06 (566)	1.16

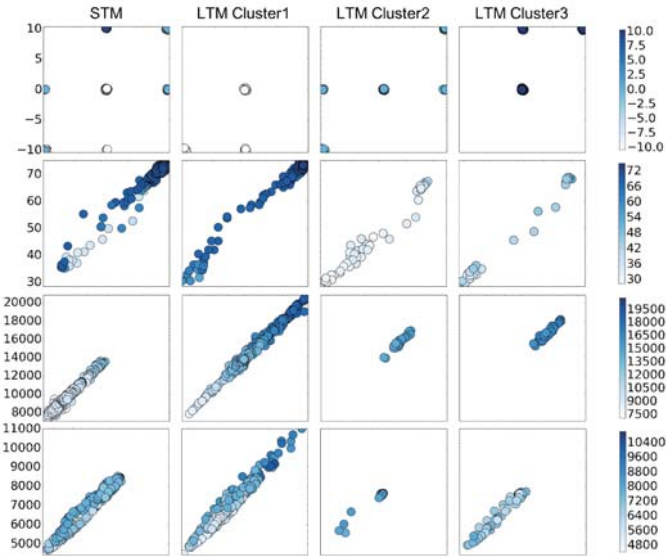


図 3: 短期記憶 (STM) または長期記憶 (LTM) の各クラスタのサンプル集合（1 行目：SuddenReocc, 2 列目：Traffic, 3 行目：Stock, 4 行目：Electricity）

る．サンプル $(\mathbf{x}_{i-D+1}, \cdots, \mathbf{x}_{i-1}, \mathbf{x}_i, \mathbf{x}_{i+N})$ に対して，丸点の座標が $(\mathbf{x}_{i-1,1}, \mathbf{x}_{i,1})$ に対応し，丸点の色が $\mathbf{x}_{i+N,1}$ に対応する．

1 行目の SuddenReocc のデータセットにおける LTM を見ると，原点 (i.e.,$(\mathbf{x}_{i-1,1}, \mathbf{x}_{i,1}) = (0, 0)$) 付近のサンプルの $\mathbf{x}_{i+N,1}$ が-10 付近と 0 付近と 10 付近の値で Cluster1 と Cluster2 と Cluster3 に分かれて描画されている．これは，SuddenReocc において，0 から-10 の方向へ急激に変化する場合と 0 付近から変化しない場合と 0 から+10 の方向に急激に変化する場合とを複数のクラスタに分けて管理できていることを表している．

2–4 行目の実データに着目する．2 行目では，サンプル間で $(\mathbf{x}_{i-1,1}, \mathbf{x}_{i,1})$ が類似しているにも関わらず $\mathbf{x}_{i+N,1}$ が異なる場合に，それらを別々のクラスタに分けて管理していることが分かる．また，3–4 行目では，STM にはサンプルの無い $(\mathbf{x}_{i-1,1}, \mathbf{x}_{i,1})$ の領域（STM の右上）であっても，LTM ではその領域（LTM Cluster1 の右上）にサンプルがあることを確認できる．これは，短期記憶から古くなり消えた情報を長期記憶で圧縮して管理できていることを表している．

5. おわりに

本研究では，様々なコンセプトドリフトを持つストリームのオンライン予測手法を提案した．予測器は類似波形の局所回帰に基づき，記憶管理については様々なコンセプトドリフトに対応するクラス分類手法 [2, 3] における適応型記憶のアイデアを発展させた．提案手法では，短期記憶と長期記憶を用いた記憶管理に加えて，長期記憶を複数のクラスタにより管理し，クラスタ内に矛盾が無いようにクラスタリングを行えることを確認した．急激に変化するタイプ，ストリームの全体や一部が徐々に変化するタイプ，類似した変化が繰り返し発生するタイプのコンセプトドリフトを持つ人工データと，交通流，株価，電力消費量の実データを用いた評価により，提案手法ではメタパラメータのチューニング無しにコンセプトドリフトに対応する従来手法と比較して高い予測精度を達成することを確認した．

参考文献

[1] Gama, J. a., Žliobaitė, I., Bifet, A., Pechenizkiy, M. and Bouchachia, A.: A Survey on Concept Drift Adaptation, *CSUR*, Vol. 46, No. 4, pp. 44:1–44:37 (2014).

[2] Losing, V., Hammer, B. and Wersing, H.: KNN Classifier with Self Adjusting Memory for Heterogeneous Concept Drift, *ICDM*, pp. 291–300 (2016).

[3] Losing, V., Hammer, B. and Wersing, H.: Self-adjusting Memory: How to Deal with Diverse Drift Types, *IJCAI*, pp. 4899–4903 (2017).

[4] Van Vaerenbergh, S., Vía, J. and Santamaría, I.: Nonlinear System Identification using a New Sliding-Window Kernel RLS Algorithm, *Journal of Communications*, Vol. 2, No. 3, pp. 1–8 (2007).

[5] Yoshida, S., Hatano, K., Takimoto, E. and Takeda, M.: Adaptive Online Prediction Using Weighted Windows, *IEICE Trans*, Vol. 94-D, No. 10, pp. 1917–1923 (2011).

[6] Dell'Acqua, P., Bellotti, F., Berta, R. and Gloria, A. D.: Time-Aware Multivariate Nearest Neighbor Regression Methods for Traffic Flow Prediction, *IEEE Trans. ITS.*, Vol. 16, No. 6, pp. 3393–3402 (2015).

[7] Zhang, P., Gao, B. J., Zhu, X. and Guo, L.: Enabling Fast Lazy Learning for Data Streams, *ICDM*, pp. 932–941 (2011).

[8] Arthur, D. and Vassilvitskii, S.: K-means++: The Advantages of Careful Seeding, *SODA*, pp. 1027–1035 (2007).

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

顧客行動分析を活用した売上予測

Improve Sales Forecasting with Customer Behavior Analysis

山浦佑介 *1 王軼謳 *1 大西健司 *1
Yusuke Yamaura Yiou Wang Takeshi Onishi

*1富士ゼロックス株式会社
Fuji Xerox Co., Ltd. Japan

In this paper, we explore the utility of customer behavior analysis of un-structured video data for improving sales forecasting, which is an important task for supply chain management in retail store. Our work is motivated by the observation that *the needs and interest of customers will influence the sales performance and customers' needs and interest can be reflected in some degree by monitoring and analyzing the customers' behavior in a store.* To the best of our knowledge, this is the first work that introduces the customer behavior analysis of monitoring video data to sales forecasting task. In order to validate our observation, we conducted a series of experiments in a physical retail store and demonstrated that integrating video-based customer behavior analysis into a conventional sale forecasting model results in a performance improvement.

1. Introduction

Sales Forecasting is an important task for supply chain management, business planning, and customer relationship management in retail industries [Mentzer 98]. In particular, retail stores provide short shelf-life food products and inaccurate forecast tends to cause stock-outs and food waste [Mena 2014]. Therefore the accurate prediction is required for reliable planning and optimization.

A number of studies on sales forecasting have been conducted in the past decades. Recently machine learning based forecasting methods have achieved high accuracy compared with traditional statistical time series methods, such as moving average model [Alon 01, Penpece 14]. To improve the performance, demand influence factors have been explored[Pechenizkiy 16, Chen 10]. Generally, weather conditions, holidays, and public events are considered due to their impact on demand and public availability[Pechenizkiy 16].

On the other hand, behavior intelligence and insight play an important role in data understanding and business problem solving [Zhou 17, Liu 15]. Customer behavior contains valuable information for marketing analysis. Therefore, it is attractive to considering exploiting customer behavior analysis in sales forecasting. The idea of combining customer behavior analysis with sales prediction been previously reported in online sales forecasting, which consider visitor's behavior tracked in their online EC-site [Currie 10, Lohse 00, Yuan 14]. However, little research has been conducted in this direction for offline cases. Customer behavior inside a physical store, which represents a shopping process until purchasing or non-purchasing but not explicitly included in the point-of-sales (POS) data or other external data, is often neglected.

In this paper, we present an approach to improve the performance of sales forecasting by incorporating the customer behavior analysis into a conventional sales forecasting model. Specifically, we develop video-based customer behavior analysis system for monitoring and analyzing customer's shopping behavior, then extract the information about how the customers interact with the stores and products, and finally design a framework to incorporate the customer behavior analysis into a sales forecasting model. To demonstrate the effectiveness of our approach, we conduct a series of experiments in a physical convenience store. We show that our approach yields improvements for all the test collections and achieves better results than the conventional sale forecasting method.

連絡先: 山浦佑介, 富士ゼロックス株式会社, 研究技術開発本部, 045-755-7395, yamaura.yusuke@fujixerox.co.jp

2. Proposed Method

In this section, we introduce our approach for incorporating customer behavior analysis into a conventional approach for sales forecasting. We first describe an overview of our video-based customer behavior analysis system, which can monitor the customer's shopping behavior inside a store. Second, we discuss how we can extract useful features from unconstructed data such as customer behavior. We adapt and extend the idea of famous technique called "conversion analysis", which is a strategy to transform a website visitor to an actual buying customer in online marketing. Finally, we explain the way to integrate new customer behavior features to the baseline model effectively. Figure 1 shows an overview of our approach for incorporating customer behavior analysis into a conventional model.

2.1 Customer Behavior Analysis

We developed video-based customer behavior analysis system for capturing and analyzing customer's shopping behavior in real stores. Our system is composed of multiple IP cameras and PCs with image processing modules installed. Specifically, surveillance cameras, which is utilized for monitoring, marketing, or security in a physical

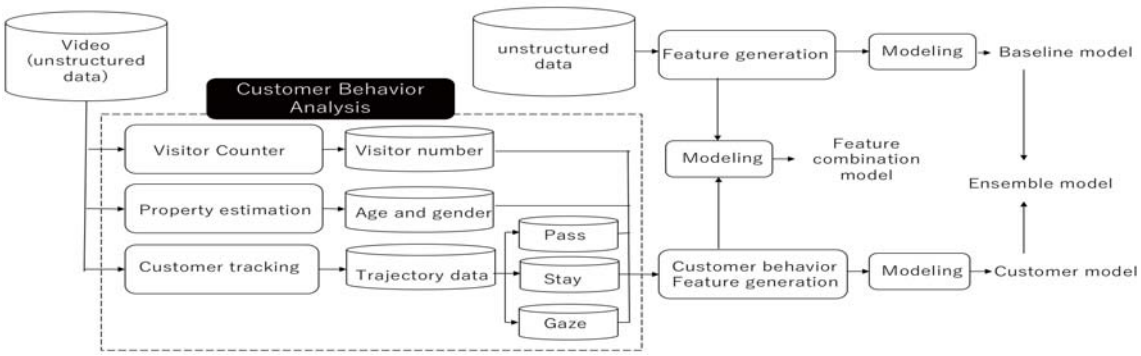


Fig. 1: Overview of the proposed approach

store, was installed. We developed several retail-oriented intelligent video analysis modules for analyzing customer's behavior inside a store. Visitor counter module receives frame images from a surveillance camera just above the store entrance and counts the number of people who visit or leave the store. Property estimation module estimate the age and gender of visitors. Customer tracking module processes multiple cameras mounted on the ceiling inside the store and this module conduct several image recognitions sub-modules, such as people detection and head orientation estimation.

We collect and analyze trajectory data of customers with the above system. In sales forecasting task, we mainly analyze the following customer behavior in a physical store:

- Visit the store
- Pass the shelf
- Stay in front of the shelf
- Gaze the shelf
- Purchase the shelf

We assume that such shopping behavior is strongly related to customer's demand, reveals the interest of customer to the product and reflected the way in which customers interact with the store and products.

2.2 Customer Behavior Feature Generation

In online marketing, conversion analysis is a well-known technique to investigate the overall business performance of an e-commerce site. Conversion analysis is conducted by measuring conversion rate, which is defined as the percentage of visitors to a web-site who complete a desired action (ex. transaction) out of total number of visitors.

In the case of physical store, if a customer has no interest to the product, he or she will neither look at the shelf nor turn to the shelf. As an initial interest level, he or she will stay in front of the shelf. If the customer has more interest, his or her gaze will fall upon the product. If the customer has further interest, he or she will gaze the shelf for a long time. If the customer has further interest, he or she probably stretches arm and touches the product. Therefore, we calculate the number of people who act these behaviors from trajectory data acquired by the customer behavior analysis system. Consequently, we extract customer behavior features, the daily number of visitors to the store at each age group and gender, people who pass by the shelf, stay in front of the shelf over 5/10 seconds, gaze the shelf over 1 second. Visitors' age is categorized into 6 groups, under 19, 20 29, 30 39, 40 49, 50 59, 60 or over.

As the daily customer behavior data of the target prediction day is impossible to obtain previously, we predict the customer behavior values in objective day using simple moving average (SMA) method. We adopted moving average of same days of week in past 4 weeks because daily sales are strongly related to the day of week. Predicted value is different but close to the actual value except the singular day such as holiday, and capture recent trends of customer behavior. Table 1 shows generated customer behavior features.

2.3 Feature Integration

To integrate the customer behavior features into the baseline model, the following two integration strategies are adopted:

- **Feature combination**

This is a simple concatenation of separate features and requires only single model. There is a possibility that high dimensional features cause overfitting or complexity of interpretation.

- **Ensemble learning**

Ensemble learning is an algorithm to acquire more accurate outcome by combining the predictions of multiple models. Ensemble modeling is most effective when large variance of outcomes or large difference among input data type. We here adopt the simplest way of ensemble averaging described as follows:

$$f_i(X) = \frac{1}{M} \sum_{i=1}^{M} \hat{f}_i(X)$$

Here, $\hat{f}_i(X)$ is the output of model i among all the multiple models and M is the number of models.

Feature Type	Feature	Description
Visitor features	$N_{visitor}$, $visitor \in g$	SMA of number of visitor each age and gender group.
Activity features	N_{pass}	SMA of number of people who pass by the shelf.
	N_{stay_five}	SMA of number of people who stay in front of the shelf over 5 seconds.
	N_{stay_ten}	SMA of number of people who stay in front of the shelf over 10 seconds.
	N_{gaze}	SMA of number of people who gaze the shelf over 1 seconds.

Table. 1: Customer Behavior Features

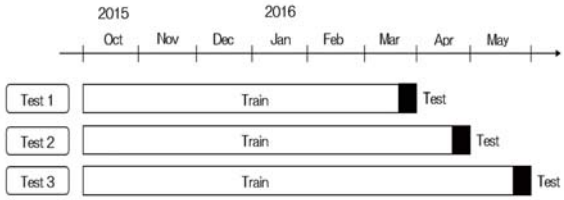


Fig. 2: Experimental data sets

3. Experiments

3.1 Experimental Setting

In this paper, we chose rice balls sale forecasting in a physical store as as our prediction targets. Specifically, we predict the daily sales number of rice ball in one week before the target day. In our study, we don't consider type difference of rice balls and the target value is total number of all types of rice balls. Our video-based customer behavior analysis system is installed in a physical store, which is composed with two surveillance cameras for visitor analysis, three omnidirectional cameras for acquisition of customer's trajectory inside the store, and two PCs with image processing modules installed.

The experiment is conducted from October 2015 to May 2016. In order to evaluate the generalization performance appropriately, we choose the last week of March, April, and May 2016 as validation period (Test1, Test2, and Test3). As we define forecasting day as one week before the target day, the training period covers from October 2015 to the day when one week before the target day as shown Figure 2.

3.2 Baseline Models

The baseline model is a conventional approach based on machine learning generally using the structured information, such as weather, calendar, and event information. We train our baseline model on Gradient Boosting Decision Tree (GBDT) proposed by Friedman [Friedman 01], which is demonstrated to be one of the most effective algorithms and is becoming a mainstream in forecasting competitions as well as Kaggle challenges. Baseline features are as follows:

- POS information: the same days of the week in past 4 weeks.
- Weather information: lowest/highest temperature, precipitation, humidity, wind speed, and categorized day-time/night weather (sunny, cloudy, rainy, snow).
- Calendar information: year, month, the day of week, seasons, quarters, public holiday, holiday, before/after holiday, between holidays, consecutive holidays, annual events, elapsed years/month/weeks/days, number of weeks in corresponding month.
- Promotion information: discount sales, special lottery, collaboration campaign, etc.

We use XGBoost[Chen 16] library for implementation of GBDT, which has become widely popular tool among various competitions. We tune the hyper parameters of XGBoost step by step for acquiring generalization ability as follows: (i) fix a relatively high learning rate (ex. η=0.1) and find the optimal number of trees under the fixed learning rate by cross-validation. (ii) tune tree-specific parameters such as the maximum number of depth, the minimum weight at child nodes, the ratio of subsamples, etc. (iii) tune regularization parameters which help to reduce model complexity. (iv) lower the learning rate (ex. η=0.01) and recalibrate the number of trees.

In addition to the conventional machine learning model, we built a moving average model with daily sales of same day of week in past 4 weeks for comparision. This is the widely-used simplest way for sales forecasting and our collaborative retail company also adopt this method for daily sales forecasting.

3.3 Experimental Results

We evaluated the effectiveness of our proposed method in a series of experiments. Specifically, we investigate the effect of incorporating customer behavior features, which is described in Section2.2, into baseline model.

We used Accuracy as evaluation metrics.

$$Accuracy = (100 - MAPE)\%$$

Here, Mean Absolute Percentage Error(MAPE) is defined as follows:

$$MAPE = \frac{100}{N}\sum_{i=1}^{N}\frac{f_i - y_i}{y_i}$$

Here, f_i is the predict value, y_i is the actual value and N is the predict data number.

Table 2 shows the final results for all experiments. From the evaluations, it is verified that the customer behavior information contributes to the improvement of prediction performance even though the customer related features are the values predicted by moving average over past 4 weeks.

Methods	Test1 (%)	Test2 (%)	Test3 (%)	Average (%)
Sales SMA model	87.18	91.28	83.55	87.34
Baseline model	88.78	92.68	87.31	89.59
+ (a) visitor features	**90.37**	93.78	84.46	89.54
+ (b) activity features	88.1	95.8	85.86	89.92
+ (a), (b)	87.44	**95.97**	86.07	89.83
Customer model	89.62	94.21	86.04	89.96
Ensemble model	89.2	93.71	**88.83**	**90.58**

Table. 2: The results of prediction models

It indicates that the latest trends of the customer behavior have impact on the sales of a product and the balance among the kinds of customer behavior should also be considered.

4. Conclusion

In this paper, we presented an approach to improve the performance of sales forecasting by incorporating customer shopping behavior analysis and investigated the impact of several strategies which can integrate the unstructured customer behavior features into a conventional structure data based model. The experimental results showed that customer behavior information provided improvements for all the test collections. Customer behavior analysis was demonstrated effective in sales prediction task.

References

[Mentzer 98] Mentzer, J. T. and Bienstock, C. C.: Sales forecasting management: understanding the techniques, systems and management of the sales forecasting process.Thousand Oaks, CA: Sage publications (1998)

[Mena 2014] Mena, C., Terry, L. a, Williams, A. and Ellram, L.: Causes of waste across multi-tier supply networks: cases in the UK food sector, Int. J. Prod. Econ. 152, 144 -158. (2014)

[Alon 01] Alon, Q.Min and R.J.Sadowski : Forecasting aggregate retail sales: a comparison of artificial neural networks and traditional method, J.Retail.Consum.Serv.8 (3) 147-156.(2001)

[Penpece 14] Dilek Penpece and Orhan Emre Elma.: Predicting Sales Revenue by Using Artificial Neural Network in Grocery Retailing Industry: A Case Study in Turkey, In: International Journal of Trade, Economics and Finance, 5(2) pp. 435-440 (2014)

[Pechenizkiy 16] Mykola Pechenizkiy and Patrick Meulsteea: Food Sales Prediction: "If Only It Knew What We Know", In: IEEE International Conference on Data Mining Workshops 128, pp. 128-143 (2008)

[Chen 10] Chen, C.-Y., Lee, W.-I., Kuo, H.-M., Chen, C.-W., and Chen, K.-H. : The study of a forecasting sales model for fresh food, Expert Systems with Applications, 37(12), 7696-7702. (2010)

[Zhou 17] Zimu Zhou, Longfei Shangguan, Xiaolong Zheng, Lei Yang and Yunhao Liu: Design and Implementation of an RFID-Based Customer Shopping Behavior Mining System, Networking IEEE/ACM Transactions on, vol. 25, pp. 2405-2418, (2017)

[Liu 15] Jingwen Liu, Yanlei Gu and Shunsuke Kamijo: Customer Behavior Recognition in Retail Store from Surveillance Camera, Multimedia (ISM) 2015 IEEE International Symposium on, pp. 154-159, (2015)

[Currie 10] Currie, C. S. M., and Rowley, I. T.: Consumer behavior and sales forecast accuracy: What's going on and how should revenue managers respond? Journal of Revenue and Pricing Management, 9(4), 374-376, (2010)

[Lohse 00] Lohse, C. L., Bellman, S., and Johnsone, E. J. (2000). Consumer buying behavior on the Internet: Findings from panel data. journal of lnteractive Marketing, 74, pp.15-29, (2000)

[Yuan 14] Yuan, H., Xu, W and Wang, M. : Can online user behavior improve the performance of sales prediction in E-commerce?, IEEE International Conference on Systems, Man, and Cybernetics, pp 2377-2382, (2014)

[Friedman 01] Friedman, J. . Greedy function approximation: A gradient boosting machine. Annals of Statistics, 29, pp. 1189 - 1232, (2001)

[Chen 16] T. Chen and C. Guestrin: Xgboost: A scalable tree boosting system, In Proceedings of the KDD, San Francisco, California, (2016)

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

特異日の影響に対するEmbeddingを用いた需要予測

Embedding special-day effects for demand prediction

田原 琢士 *1　王 軼謳 *1　根本 啓一 *1
Takuji Tahara　Yiou Wang　Keiichi Nemoto

*1富士ゼロックス株式会社
Fuji Xerox Co., Ltd.

Special days such as public holidays have significant impact on time-varying customer's demand. In this paper, we propose a new method to handle the special days' effects by embedding techniques using neural network. We evaluate the usefulness of our method in the real call center data set and demonstrate that embedded features generated by our method provide substantial performance gains in call arrival prediction. In addition, we visualize the embedding features of special day and its neighborhood and further understand their relationship.

1. はじめに

一般に，日々需要が発生するもの，例えば電力の消費量や食料品の売り上げ，カスタマーセンターへの問い合わせなどはカレンダーに大きく依存し，日，週，月，年単位でトレンドや周期性或いは季節性を示すことが多い．この性質を利用して，SARIMA や指数平滑といった一般的な時系列解析モデルを需要予測に適用する研究が数多く行われてきた [Aldor-Noiman 09, Ibrahim 16a]．時系列解析モデルを用いる手法は周期性のあるデータに大きな効果を発揮する反面，外れ値などに弱い．特に，上述したカスタマーセンターへの問い合わせのようなビジネスの現場における需要は，通常営業日の需要の周期性・季節性とは別に，祝日や年度始めといった大きな影響を及ぼす特異な要素 (特異日) の影響を受ける．そのため，上で述べた一般的な時系列解析モデルを適用するのが困難である．

この問題への取り組みとして，特異日と特異日以外の予測モデルを別個に構築する研究 [Kim 00, Kumru 15, Ghofrani 15] や，モデルの特徴量として特異日の情報を明示的に加える研究 [Aggarwal 16] などが行われてきた．特異日の情報を特徴量として予測モデルに加える際にはしばしば one-hot のダミー変数が用いられる [Aggarwal 16] が，入力の型の変更 (例：バイナリ変数，整数，三角関数など) や複数の日にまたがる特異日に対して binning を行うなど，特徴量の表現方法によって予測性能が変化することが報告されている [Barrow 16]．また，特異日だけではなくその周辺の日 (例：祝日の 1 日後，2 日後) も特徴量として用いる手法が提案されており [Ghofrani 15, Xie 15]，これらもまた特異日同様に需要に影響を与える要素となっている．以上に挙げた特徴量設計は性能の向上に貢献するものの，特異日に対応する特徴量をどのように作成するのか，そしてその周辺を何日後 (前) まで考慮するかは，人手でのモデリングに依存してしまう．

本稿ではこの問題を解決するために，特異日とその周辺の日の関係性を自動で抽出して需要予測を行う手法を提案する．提案手法では，特異日に対応する新しい特徴量として，当日のみならず，当日及びその周辺のどの日が特異日と関係するか否かを示す入力を行う．次に，これらの入力を特異日ごとにベクトル空間への埋め込み (embedding) を行った上で，neural network による予測を行う．実験では，実在するコールセンターの 6 年分のコール量のデータに対して提案手法を適用した．実験の結果，本手法で用いる新しい入力方式と embedding の有効性が確認された．また embedding の結果から，特異日とその周辺の日の関係性を可視化することができた．

連絡先: 田原琢士，富士ゼロックス (株)，
横浜市西区みなとみらい 6 丁目 1 番，
tahara.takuji@fujixerox.co.jp

2. 提案手法

提案手法の主要な要素は以下の二つである．

2.1 特異日に対応する特徴量の入力方式

従来研究では，特異日が複数の日にまたがる場合，それらを同一視して単一のバイナリ変数で扱う，あるいは複数のバイナリ変数で扱っていた [Barrow 16]．これに対して我々は，当日とその前後 W 日 (W はウインドウのサイズを示す) のどの日が特異日であるかをバイナリ変数で扱う．この方式により，特異日の続く期間に関わらず一定の長さの入力で特異日を扱うことができ，かつ周辺の日の特異日との関係 (例：特異日とその周辺の日の位置関係) も明示できる．この関係性の明示により，次節 (2.2) で述べる embedding で良い特徴量としての表現が得られると考えている．

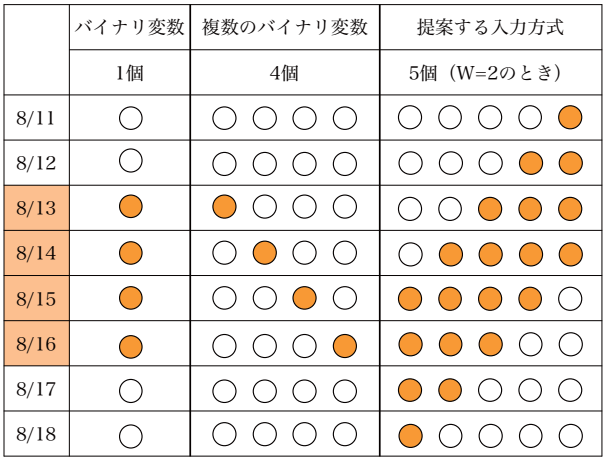


図 1: 入力方式の違い

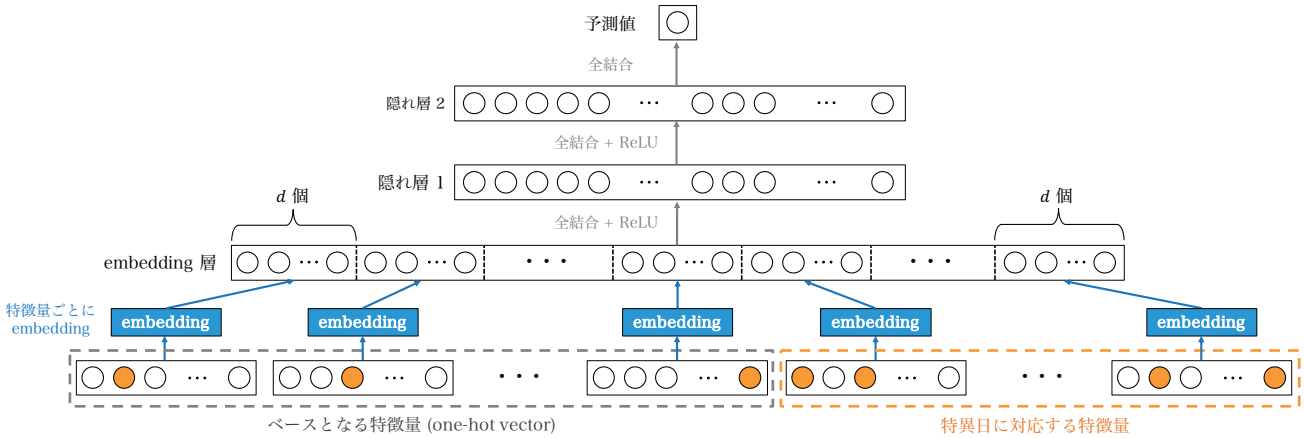


図 2: 提案モデルの構造

図 1 は，我々が今回実験で用いた特異日の一つであるお盆 (8/13 - 8/16) を用いて，8/11 - 8/18 のそれぞれの日における入力方式の違いを示している．典型的な 1 つのバイナリ変数を用いる方式では，特異日に当たる 8/13 - 8/16 のときにのみ 1 が入力される．複数のバイナリ変数を用いる方式では，特異日の長さに対応する数 (4 つ) のバイナリ変数が存在し (図では左から順に 8/13 - 8/16 に対応)，その日にだけ 1 が入力される．我々の提案方式では，$W \times 2 + 1$ 個のバイナリ変数を用意し (図では左から 2 日前，1 日前，当日，1 日後，2 日後に対応)，当日とその前後が特異日に当たるか否かが入力される．

2.2 特異日ごとの特徴量の embedding

[Barrow 16] らが示したように特異日の特徴量の表現方法は予測性能に影響する．提案手法ではこの表現方法を学習データから自動で獲得するために，2.1 節で述べた入力について，各特異日ごとにベクトル空間への埋め込み (embedding) を行う．embedding によって予測するのに適した特徴量の表現方法が得られるだけでなく，得られた表現を可視化することにより，特異日ごとのその周辺の日との関係性の可視化が可能となる．

また，2.1 節で述べた提案入力方式は，ウインドウのサイズによっては予測にほとんど影響を与えない入力（例：祝日の 1 週間後を示す入力）であっても，特徴量として予測に影響を与えてしまう．しかし，embedding によって予測結果への影響度合いを考慮した特徴量の表現方法が得られることで，正しい予測結果に寄与しない入力は無効化されると考えている．

表 1: 実験で使用した特徴量の詳細

名前	種別	入力方式
年	ベース	バイナリ変数 (one-hot vector)
月	ベース	バイナリ変数 (one-hot vector)
週	ベース	バイナリ変数 (one-hot vector)
曜日	ベース	バイナリ変数 (one-hot vector)
休日	特異日	バイナリ変数 (提案方式)
祝日	特異日	バイナリ変数 (提案方式)
年末年始	特異日	バイナリ変数 (提案方式)
GW	特異日	バイナリ変数 (提案方式)
お盆	特異日	バイナリ変数 (提案方式)

以上を踏まえて，我々は 図 2 に示す neural network モデルを構築した．カレンダーを表すベースの特徴量としては 年，月，週，曜日を使用し，one-hot vector として入力される．特異日に対応する特徴量については，2.1 で述べた，提案する入力方式によって入力を行う．構築した neural network は，各特徴量に対して個別に embedding を行う embedding 層と，concat した embedding 層に全結合された 2 つの隠れ層から成る．我々のモデルにおいて，ウインドウサイズ (W), embedding vector の次元 (d), 及び各隠れ層の unit 数 (N_1, N_2) はハイパーパラメータであり，検証データを用いて調整を行う．需要予測に Deep Neural Network を用いる研究 [He 17] や，月，週，時間を embdding する研究 [Wang 17] は行われているが，我々の知る限り，特異日ごとに，特異日とその周辺の日を同じベクトル空間に embedding する研究は存在していない．

3. 実験

本章では提案した入力方式と特異日毎の embedding の有効性を確認するための実験について述べる．

3.1 データセット

実験に使用するデータは，ある企業のコールセンターの 2012 年 4 月から 2017 年 12 月までの約 6 年分の日次の着信量データである．このコールセンターは通常平日に営業しており，土曜日は限定的に営業，日曜日は完全に休日となっている．本実験では，ハイパーパラメータの検証データとして 2016 年度のデータを使用し，2017 年度のデータで予測性能の評価を行う．

3.2 実験設定

コールセンターでコール量予測を行うのは，その予測値を用いて適切な人員配置を決定するのが大きな目的である．データ受領先のコールセンターでは月ごとに人員配置を決めており，1 か月前には配置を決定する必要がある．このため，本実験では予測月ごとに予測モデルを作成して日毎の予測を行い，その際の学習データには予測月の前々月までのデータを用いるという制約を与えて性能評価を行う．ヒアリングの結果，実験対象となるコールセンターの着信量に影響を与える特異日は休日，祝日，年末年始，ゴールデンウィーク (GW)，お盆の 5 つであることが分かったため，これらを特異日として扱って予測を行った (表 1)．ハイパーパラメータについては，2016 年度のデータを用いた検証の結果，$W = 5, d = 5, N_1 = N_2 = 64$ とした．

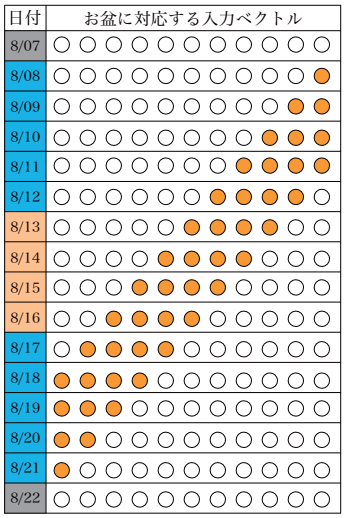
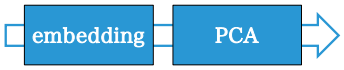


図3.a それぞれの日に対応する入力



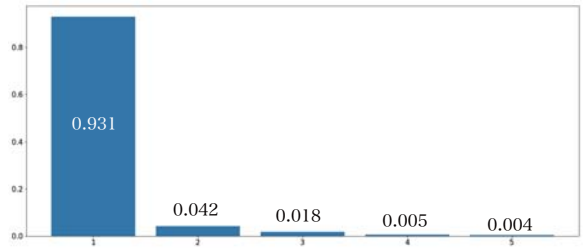


図3.b 次元圧縮時の各主成分の寄与率

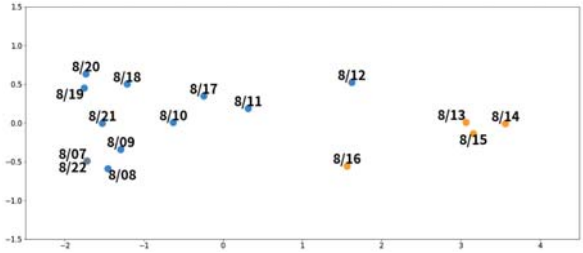


図3.c embeddingされたベクトルの第一・第二主成分による可視化

図 3: お盆の embedding の可視化

表 2: 実験で比較する手法

入力方式＼モデルの構造	全結合	embedding
複数のバイナリ変数	比較手法 1	比較手法 2
提案する入力方式	比較手法 3	**提案手法**

表 3: 実験結果 (MAPE(%) / RMSE(件))

入力方式＼モデル構造	全結合	embedding
複数のバイナリ変数	5.76 / 231.76	5.05 / 208.50
提案する入力方式	5.49 / 228.33	**4.62 / 199.63**

3.3 比較手法

本実験では，提案した入力方式と embedding の有効性を検証するために，それぞれに対して比較する手法を用意した．

入力方式の比較には，[Barrow 16] らの実験において特異日に対する予測性能が最良となった，複数の期間にまたがる特異日を同じ数のバイナリ変数で表現する方式を用いる．特異日の周辺の表現については，特異日の期間の先頭から何日前か，そして特異日の末尾から何日後か，を表現するバイナリ変数を入力として与える．ただし，休日と祝日については周囲との関係性のパターンが多く，を one-hot な入力ベクトルで表現することが難しい．そこで，休日については当日が休日，休日と休日の間，連休 (3 日以上) 後，連休 (3 日以上) 前，休日後，休日前の 6 次元の one-hot ベクトルを使用し，祝日については当日が祝日，祝日と祝日の間,，祝日後，祝日前の 4 次元の one-hot ベクトルを使用した．モデル構造については，一般的な feedforward neural network との比較を行う．

以上と提案する入力方式・モデル構造の組み合わせにより，本実験では表 2 に示す 4 つの手法を比較する．比較手法についても提案手法と同様に，特異日の前後何日目までを考慮するか (W) や feedforward neural network のユニット数などを，2016 年度のデータを用いた検証によって決定する．

3.4 結果

評価結果は表 3 のようになった．提案する入力方式と embedding を用いる提案手法が最も予測精度が良く，入力方式・モデルの構造の両方がベースラインである比較手法 1 に比べて MAPE(Mean Absolute Percentage Error)) が 1.14%，RMSE(Root Mean Squeared Error) が 32.13 件減少している．また，入力方式を固定した場合は提案する embedding 構造を用いた方が予測性能が良く，モデルの構造を固定した場合は提案する入力方式を用いた方が予測性能が良くなっている．このことから，提案する入力方式と特異日とその周辺の日ごとの embedding が有効であることが確認できた．

4. embedding された入力の可視化

ここでは代表として，実験で使用した特異日の 1 つのお盆に対応する embedding の可視化を行う．まず，予測時に学習されたお盆に対応する embedding をお盆周辺の 8/7 - 8/22 (16 日間) に適用し，次に embedding されたベクトルに対して主成分分析 (PCA) を行う．3 はそれぞれの日に対応する入力 (図 3.a)，PCA 適用時の各主成分の寄与率 (図 3.b)，PCA によって圧縮したベクトルの二次元平面プロット (横軸：第一主成分，縦軸：第二主成分)(図 3.c) である．ここで，橙色は我々が特異日と指定している 8/13 - 8/16 ，青色は前後 5 日間に 8/13 - 8/16 のいずれかを含むもの，灰色は前後 5 日間に 8/13-8/16 がない，即ちお盆との関係性が一切明示されていない日である．

各主成分の寄与率 (図 3.b) を見ると第一主成分がそのほとんど (93.1%) を占めており，お盆による影響は図 3.c の横軸で解釈できると考えられる．実際，お盆に近い日ほど第一主成分の値が大きく，多いほど値が小さい傾向があることが見て取れる．しかしながら，ただ単純に近い順序で並んでいるわけではない．例えば，我々がお盆であると指定した 8/16 は，embedding の結果お盆の 1 日前である 8/12 とほぼ同じ値を取っている．その次に値が小さい日を並べると，8/11(2 日前),

8/17(1 日後)，8/10(3 日前) となっている．このことから，今回我々の指定したお盆 (8/13 - 8/16) は，その後の日よりも，その前の日に影響を及ぼしているという仮説を立てることができる．あるいは，仮に特異日の影響がその前後に等しく及ぶとすれば，そもそも本当のお盆は 8/13 - 8/15 なのではないかという仮説を立てることもできる．

最後に，お盆にとの関係性が一切明示されていない 8/7(6 日前)・8/22(6 日後) に注目する．これらの点と第一主成分の値が近い日として，8/19(3 日後)，8/20(4 日後)，8/21(5 日後) などが見られ，これらの日はお盆との関係性がほぼ無いというふうに embedding が学習されていると考えられる．従って，2.2 節で述べたように，正しい予測結果に寄与しない入力（この場合で言えばお盆から離れた日の情報）が embedding によって自動的に無効化されていると考えられる．

5. まとめ

本稿ではビジネスの現場における需要予測において大きな影響を持つ特異日に着目し，特異日とその周辺の日の関係性を自動で抽出して需要予測を行う手法を提案した．具体的には，特異日に対応する新しい特徴量として，当日のみならず，当日及びその周辺のどの日が特異日と関係するか否かを示す入力方式と，それらについて特異日毎にベクトル空間への埋め込み (embedding) を行う neural network モデルを提案した．実験の結果，提案する入力方式とモデル構造を組み合わせた手法が最も良い予測性能を示し，提案手法の有効性が確認できた．また，埋め込まれた特異日毎の空間を可視化することにより，特異日の周辺への日の影響度合いを実例とともに示した．

今後の課題としては，今回用いたデータセット以外，例えば商品の売り上げ履歴などを用いて提案手法の有効性を確認することや，提案した手法で embedding された入力を別のモデルの入力として用いた際の人手でのモデリングとの差の検証をしたいと考えている．また，今回行った embedding されたベクトルの可視化と分析は直感的なものであり，特異日に対する仮説を立てるまでにとどまっている．今後は過去の履歴データを考慮した数値的な分析も行う予定である．

参考文献

[Aldor-Noiman 09] Divan Aldor-Noiman, Paul D. Feigin and Avishai Mandelbaum: WORKLOAD FORECASTING FOR A CALL CENTER: METHODOLOGY AND A CASE STUDY, The Annals of Applied Statistics (2009)

[Ibrahim 16a] Rouba Ibrahim, Han Ye, Pierre L ' Ecuyer, Haipeng Shen: Modeling and forecasting call center arrivals, A literature survey and a case study, International Journal of Forecasting (2016)

[Kim 00] Kwang-H Kim, Hyoung-Sun Youn, Yong-Cheol Kang: Short-Term Load Forecasting for Special Days in Anomalous Load Conditions Using Neural Networks and Fuzzy Inference Method, IEEE Transactions on Power Systems (2000)

[Kumru 15] M. Kumru, P.Y. Kumru: Calendar-Based Short-Term Forecasting of Daily Average Electricity Demand, International Conference on Industrial Engineering and Operations Management (2015)

[Ghofrani 15] M. Ghofrani, M. Ghayekhloo, A. Arabali, and A. Ghayekhloo: A hybrid short-term load forecasting with a new input selection framework, Energy(2015)

[Aggarwal 16] S. K. Aggarwal, Mahesh Kumar: ANN based residential demand forecasting using weather and special day information, India International Conference on Power Electronics (2016)

[Barrow 16] Devon Barrow, Nikolaos Kourentzes: The impact of special days in call arrivals forecasting: A neural network approach to modelling special days, European Journal of Operational Research (2016)

[Xie 15] Jingrui Xie, Tao Hong, and Joshua Stroud: Long-Term Retail Energy Forecasting With Consideration of Residential Customer Attrition, IEEE Transactions on Smart Grid(2015)

[He 17] Wan He: Load Forecasting via Deep Neural Networks, Information Technology and Quantitative Management(2017)

[Wang 17] Yi Wang, Ning Zhang, Qixin Chen, Daniel S. Kirschen, Pan Li, and Qing Xia: Data-Driven Probabilistic Net Load Forecasting with High Penetration of Behind-the-Meter PV, IEEE Transactions on Power Systems(2017)

Oral presentation | Organized Session | [Organized Session] OS-1

[3O1-OS-1a] [Organized Session] OS-1

Thu. Jun 7, 2018 1:50 PM - 3:30 PM Room O (2F Kaimon)

[3O1-OS-1a-01] Morality in Japanese Lyrics

○Kazutoshi Sasahara[1], Yasuhiro Taguchi[2] （1. Nagoya University, 2. Aichi University）

1:50 PM - 2:10 PM

[3O1-OS-1a-02] Bullied-Experience Talks in Online Communications

Masanori Takano[1], ○Takaaki Tsunoda[1] （1. CyberAgent, Inc.）

2:10 PM - 2:30 PM

[3O1-OS-1a-03] Analysis of readers by Classification of Articles in a News Service from Network Structures

○Atom Sonoda[1], Fujio Toriumi[1], Hiroto Nakajima[2], Miyabi Gouji[2] （1. The University of Tokyo, 2. Nikkei Inc.）

2:30 PM - 2:50 PM

[3O1-OS-1a-a] OS invited talk

○Nobuo Sato[1] （1. Hitachi, Ltd.）

2:50 PM - 3:30 PM

©The Japanese Society for Artificial Intelligence

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

日本語歌詞の道徳性：道徳基盤理論に基づくテキスト分析

Morality in Japanese Lyrics: A Text Analysis Based on Moral Foundations Theory

田口 靖啓 *1　笹原 和俊 *2*3
Yasuhiro Taguchi　Kazutoshi Sasahara

*1愛知大学文学部
Faculty of Letters, Aichi University

*2名古屋大学大学院情報学研究科
Graduate School of Informatics, Nagoya University

*3JST さきがけ
JST, PRESTO

Popular songs change with the time and the time changes with popular songs, a proverb says. Hit songs therefore tend to reflect the state of people's morality that exists when they are written. With the Moral Foundations Dictionary, we quantified morality in Japanese lyrics from musicians who ranked in the Oricon hit chart between 2004 and 2016. The results show that Japanese hit songs include many words related to "harm" and "purity." In addition, we found a positive correlation in the usage of morality- and immorality-related words.

1. はじめに

「歌は世につれ, 世は歌につれ」ということわざがある. その時代の歌は世情を反映し, 世のありさまも歌の流行に影響されるという意味である. そのため, 多くの人に好かれる歌の歌詞には, 人々の道徳性が色濃く反映すると考えられる. また, 歌は人々に聞いてもらうことが前提で作られており, 限られた字数で共感を生み出すために適切な単語の選択が行われていると考えられる.

以上の理由から, 歌詞は人々の道徳性を定量的に研究する格好の素材だと言える. 本研究では, ヒットソングの日本語歌詞を対象とし, テキストマイニングの手法を用いて, 日本人の道徳性について調査した.

道徳性を調べるにあたり, 道徳基盤理論 (Moral Foundations Theory; 以下, MFT と略す) をベースとした [Graham 13]. MFT は Jonathan Haidt が提唱した道徳理論である. この理論によると, 人間の道徳性は, 直感的な判断を可能にする 5 つの生得的基盤「擁護 (Harm), 公正 (Fairness), 忠誠 (Ingroup), 権威 (Authority), 純潔 (Purity)」で構成され, 道徳の多様性はこれらの基盤の組み合わせにより決定される.

- 擁護 (Harm) : 弱者を守りたいと思う生得的感覚
- 公正 (Fairness) : 他人に付け込まれないようにすべしという生得的感覚
- 忠誠 (Ingroup) : 内集団をつくり, 維持しようという生得的感覚
- 権威 (Authority) : 階級や地位などを遵守すべきという生得的感覚
- 純潔 (Purity) : 理屈なしで汚してはいけないものがあるという生得的感覚

各道徳基盤には, その基盤を遵守する場合 (Virtue) とその基盤に違反する場合 (Vice) の 2 通りがあり, 本研究では区別して分析する.

これらの道徳基盤の多様性を日本語歌詞のテキストマイニングによって定量化する.

連絡先: 笹原 和俊, 464-8601 名古屋市千種区不老町
名古屋大学大学院情報学研究科, sasahara@nagoya-u.jp

2. 方法

2.1 歌詞データ

2004〜2016 年のオリコン・シングルランキング 1 位〜100 位に掲載されているアーティストを対象として, 歌詞サイトの歌ネットから歌詞のテキストデータを取得した (対象となったアーティスト数は 337 名). ただし, 歌ネットのデータベースに存在しない曲は取得できなかった.

実際に取得できたデータは, 上記期間のシングルが 937 曲, 歌ネットに存在する上記アーティストの歌 (シングル以外も含む) が 23963 曲である. オリコン・シングルランキングの 100 位以内の歌に着目したのは, それらは多くの人々に支持された歌であり, したがって, 人々の道徳性をより強く反映していると考えたからである.

2.2 道徳基盤辞書

日本語歌詞から道徳性を計測するために, 道徳基盤辞書の日本語版 J-MFD を作成した. J-MFD の作成手順の詳細は文献 [Matsuo] で発表予定である.

J-MFD には, 道徳基盤理論の 5 つの基盤およびそれらの道徳基盤と関係する 741 の単語が登録されている. また, それらの単語が各基盤を遵守するのか (Virtue) あるは違反するのか (Vice) という区別もされており, 簡単化のために, 本論文では前者を「道徳的」, 後者を「非道徳的」と呼ぶ. 例えば, 「平和*」は「擁護遵守」 (HarmVirtue) に分類され, 「平和」や「平和な」や「平和主義」などがこれに該当する. また, 「殺人*」は「擁護違反」(HarmVice) に分類され, 「殺人」や「殺人犯」や「殺人事件」などがこれに該当する.

2.3 歌詞のテキスト分析

道徳性を定量化するために, 歌詞のテキストデータに含まれる J-MFD の道徳単語の数を数え, 歌詞の全単語数に占める割合を計算する.

まず最初に, 歌詞を日本語形態素解析システム MeCab で分かち書き処理をした. 分かち書き処理の後, 辞書内の道徳単語を歌詞のテキストデータの中で検索して, 各道徳基盤ごとに分類した. 辞書内の道徳単語に*が付いているものは活用の違いも考慮してカウントし, *が付いていなければそのままカウントした. 例えば, 「共感*」の場合, 形態素解析後の歌詞に含まれる「共感」や「共感性」や「共感する」などがカウントされ, 「守る」の場合は, 形態素解析後の歌詞に含まれる「守る」だけ

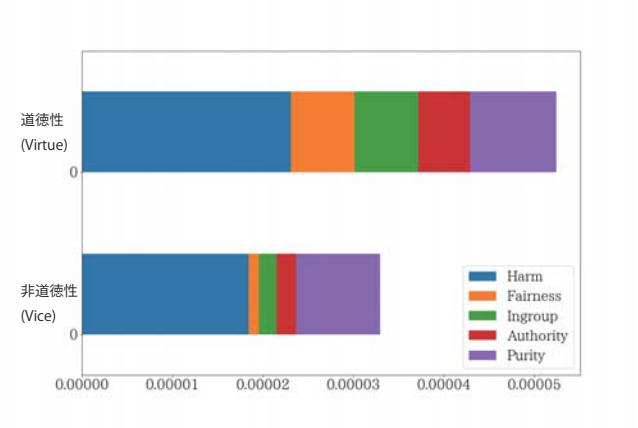


図 1: 歌詞全体における道徳性 (Virtue) と非道徳性 (Vice) の割合

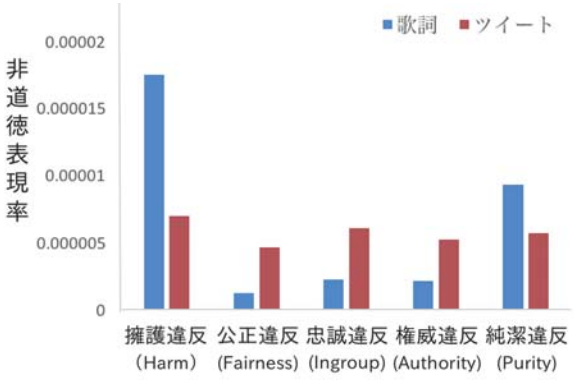


図 2: 歌詞とツイートの比較

がカウントされる. J-MFD に含まれる道徳単語はカテゴリーごとに偏りがあるので,「歌詞の中で検出された道徳単語の数 / その道徳単語の属するカテゴリーのサイズ / 歌詞の総単語数」とすることで, 計測した値を正規化した.

以上の道徳性の計測に基づき, 日本語歌詞における各道徳基盤の割合, アーティスト別に見たときの道徳性 (Virtue) と非道徳性 (Vice) の関係などについて調査した.

3. 結果

図 1 は, 歌詞データ全体において, 道徳性 (Virtue) と非道徳性 (Vice) に関する単語が使用される割合を各道徳基盤ごとに表している. ここから, 邦楽の歌詞では, 道徳性 (Virtue) に関係する単語の方が非道徳性に関係する単語よりも多く使われていることが分かる. 道徳性 (Virtue) で最も割合が大きかった基盤は,「擁護」(Harm Virtue) であった. 以降は,「純潔」(Purity Virtue),「公正」(Fairness Virtue),「忠誠」(Ingroup Virtue) と続き, 最も割合の小さかった基盤は「権威」(Authority Virtue) だった.

一方, 非道徳性 (Vice) で最も割合が大きかった基盤は,「擁護違反」(Harm Vice) で, それ以降は,「純潔違反」(Purity Vice),「忠誠違反」(Ingroup Vice),「権威違反」(Authority Vice),「公正違反」(Fairness Vice) の順であった. どちらの場合も, 日本語歌詞において「擁護」と「純潔」に関わる単語が頻繁に用いられていることがわかる.

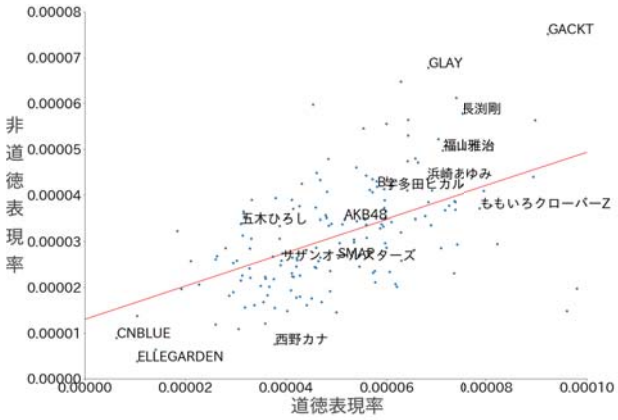


図 3: アーティストの道徳表現率と非道徳表現率

歌詞全体における道徳性 (Virtue) の単語を使用する割合を「道徳表現率」, 非道徳性 (Vice) の単語を使用する割合を「非道徳表現率」とし, 前者を X 軸, 後者を Y 軸とした時のアーティストの散布図が図 2 である. ここから, 道徳表現率と非道徳度表現率のどちらも高いアーティストが Gackt, どちらも低いアーティストは西野カナであることがわかる. さらに, 道徳表現率が高いほど非道徳表現率も高いという正の相関が認められた ($r = 0.51$, $p < 0.001$, ピアソンの無相関検定).

同様の道徳性の計測をジャンルごとにも行った (図は省略). オリコンチャート 100 位以内の曲のみを対象とすると, ジャンルがポップに著しく偏るため, オリコンチャート 100 位以内に入ったことのあるアーティストの曲を可能な限り前述の方法で取得し (23963 曲), それを分析した. その結果, 最も道徳性 (virtue) が高いジャンルは, アニメ (Animation) で, 最も道徳性 (virtue) が低いジャンルは歌謡曲および演歌 (Kayokyoku & Enka) だった. また, アジアン・ヒップホップ / ラップ (Asian Hip Hop/Rap) 以外のジャンルは, やはり「擁護」と「純潔」が多くを占めていた.

4. まとめ

本研究では, 人気のあるアーティストの曲の歌詞のテキストデータを道徳基盤辞書の日本語版 (J-MFD) を用いて分析した. オリコンチャートで 100 位以内にランクインしたアーティストのシングルの歌詞のテキスト分析からは, 擁護 (Harm) の割合が最も多く, 次いで 純潔 (Purity) が多く日本語歌詞に表現されていることがわかった. このことから, 日本語歌詞には「人を守りたい」,「きれいなものをきれいだと思う」日本人の道徳性が反映されていると考えられる. 先行研究において, 日本語においても英語においても, Twitter の投稿データでは, 擁護 (Harm) が一番使われる道徳基盤であることが知られている [Kaur 16, Matsuo]. このことから, 擁護は道徳基盤の中でもっとも中心的な基盤である可能性が示唆される.

アーティストごとの分析からは, 道徳性と非道徳性に関係する単語の使用には正の相関があることが明らかになった. これは言い換えると, 道徳的な単語を多用するアーティストは, 非道徳的な単語もたくさん使用する傾向があるということである. これと関係する仮説に, モラル・ライセンシングという考え方がある [Merritt 10]. この仮説を簡潔に言うと,「良いことをすると, 悪いことをしたくなる」傾向のことである. まだ憶測の域を出ないが, 歌の場合も, 道徳的な意味で良い歌詞をたくさ

ん書くと, その分, 非道徳的な歌詞を書きたくなり, 道徳的なバランスをとる傾向があることを示唆している。この仮説については, 英語の歌詞との比較などを行い, これらの結果の文化依存性について調査する予定である.

謝辞

本研究は JSPS 科研費 (JP15H03446, JP17H06383JST), JST さきがけ (JPMJPR16D6), JST CREST(JPMJCR17A4) の助成を受けたものです.

参考文献

[Graham 13] Graham, J., Haidt, J., Koleva, S., Motyl, M., Iyer, R., Wojcik, S. P., and Ditto, P. H.: Moral foundations theory: The pragmatic validity of moral pluralism, in *Advances in experimental social psychology*, Vol. 47, pp. 55–130, Elsevier (2013)

[Kaur 16] Kaur, R. and Sasahara, K.: Quantifying moral foundations from various topics on Twitter conversations, in *Big Data (Big Data), 2016 IEEE International Conference on*, pp. 2505–2512IEEE (2016)

[Matsuo] Matsuo, S. K. T. Y., A. and Karasawa, M.: Development of the Japanese Moral Foundations Dictionary(in prep.)

[Merritt 10] Merritt, A. C., Effron, D. A., and Monin, B.: Moral self-licensing: When being good frees us to be bad, *Social and personality psychology compass*, Vol. 4, No. 5, pp. 344–357 (2010)

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

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」

Bullied-Experience Talks in Online Communications

高野雅典 *1　　角田孝昭 *1
Masanori Takano　　Takaaki Tsunoda

*1株式会社サイバーエージェント
CyberAgent, Inc.

Social supports such as giving empathy, affection, and respect increase children's well-being and reduce stress. We aim to drive social support for bullied children through the Internet (online social support). In this study, we focus on bullying in real life (offline) and support through online communication. For this purpose, we investigate how online social supports affect bullied children and which conditions ensure the supports have positive effects by analyzing online communication data on an avatar chat service. We found that bullied-experience talks in the virtual world with a few friends have a positive effect on bullied children. The talks tended to include bullied children's self-disclosure. Therefore, this finding suggests that self-disclosure by bullied children is very important for supporting them.

1. はじめに

学校におけるいじめは被害者の身体的・精神的な健康を脅かし教育機会を奪う深刻な社会的課題である．自治体や学校は，被害者をサポートするために相談窓口を設ける・学校にスクールカウンセラーを配置するなどの対策を行っている．しかし被害者が利用をためらってしまい，サポートを受けていない場合がある．株式会社 LINE と長野県がメッセンジャーアプリケーション LINE 上に試験的に設けたいじめ相談窓口はわずか 2 週間で電話相談 1 年分の 6 倍のアクセスがあった [The Japan Times 17]．これは既存対策の利用を多くの児童・生徒がためらっていたこと，それを解消するためには被害者と親和性の高いツールによるアプローチが重要であることを示す．日本の若年層であればインターネットを通したコミュニケーションであろう．そのような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]．本研究ではオンラインソーシャルサポートによるいじめ被害の既存対策の補間を目的とする．

自身の状況や感情を開示するほど（自己開示するほど），他者が共感・関心などのオンラインソーシャルサポートの提供を促す．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]．日本で幅広く普及している Facebook や LINE での社会関係はオフラインの人間関係の延長線上にあることが多いため，いじめ告白にはそれらとは異なった匿名性の高いオンラインコミュニケーションツールが重要であろう．

本研究では，いじめ被害者に対してインターネットコミュニケーションを通した一般ユーザ同士のソーシャルサポート提供を促進することを目的とし，「いじめ被害の告白」とそれに対するオンラインソーシャルサポート行動を分析する．具体的にはアバターチャットサービス「ピグパーティ」*1 上で行われている「現実世界でいじめを受けているという告白」と「それに対する相談」に焦点を当てる．ピグパーティを対象とした理由は，若年層の利用者が多く，現実の人間関係とは切り離された匿名性の高い社会が構成される傾向にあるため，オンラインソーシャルサポートの存在が期待できるからである．

本稿では，最初にソーシャルサポートの効果を検証し，それが効果的であった理由・条件について分析する．そしてどのようにすれば，いじめ被害者により多く有効なソーシャルサポートを提供できるかについて議論する．

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

2. ピグパーティの仕様とデータ

「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）．

ピグパーティには 3 つのタイプのコミュニケーションの場（ルーム）が存在する．それらはパブリックルーム，プライベートルーム，テンポラリルームの 3 種類である．パブリックルームは公的なスペースに位置づけられ，誰でもいつでも入ることができる．人数は最大 20 人である（ルームによって異なる）．プライベートルームは各ユーザが 1 つ持つルームである．他のユーザのプライベートルームには，そのユーザのプロフィール画面にあるリンク押下，または，システムによるランダム入室によって入ることができる *2．人数は最大 10 人である．テンポラリルームはユーザが一時的に作ることができるアドホックなルームである．ユーザはメニューから検索条件を指定して任意のテンポラリルームに入ることができる．人数は最大 10

*1 https://lp.pigg-party.com/
*2 ユーザプロフィールは，同じルームに存在する場合，または，システム的なフレンド関係（両者の承認が必要）にある場合に見ることができる．



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．

表 1: いじめ告白対話に代表的なトピック．

番号	タイトル	代表的な単語
50	いじめの対策	カウンセリング 教育委員会 綺麗事 カウンセラー スクールカースト 児童相談所
52	雑談	バツキン ちいさく えりあ ておもっ みせよ お安い
68	煽り	横槍 論破 異常者 指摘 反論 煽れ
71	不登校	停学 ズル休み 登校 仮病 定時制 不登校
103	将来	中学受験 専門学校 学科 就職 奨学金 パティシエ
104	いじめの説明	絶交 上履き 仲間外れ 腹パン 言い返す 殴ら
133	共感	母性 受け身 慰める 素っ気 少なからず あてはまる
136	自殺	かなしむ しにたい 飛び降り 首吊り 死因 じさつ

人である．テンポラリルームは作成から 2 時間で閉鎖される．

本研究では，自身のいじめられた経験について発話したユーザを「告白者」，その発話が含まれる対話に参加（発言）したユーザを「聞き手」，その対話を「いじめ告白対話」と呼ぶ．「いじめ告白対話」の対話データは，2016/09/01 から 2017/08/31 の 1 年間を対象とし以下の手順で抽出した．まず関連する 4 単語「いじめ，イジメ，苛め，虐め」[*3] のいずれかを含む発言の前後 15 分の同じルームでの発言を抽出し，それを 1 つの対話とした．ただし同じルームで 30 分以内に上記の 4 つの単語を含む発言がされた場合，それらを統合して 1 つの対話として扱った．その対話の中からランダムに 40,000 件抽出し，「現在いじめられている」もしくは「いじめられたため現在不登校中である」と明確に分かる対話がされているものを「いじめ告白対話」とした．これによっていじめ告白対話数 1,030 件，発言数 287,726，告白者 1,025 人，聞き手 6,613 人が抽出された．いじめ告白対話はプライベートルームで 527 件，パブリックルームで 41 件，テンポラリルームで 562 件であった．

また告白者と聞き手の関係として友人と非友人の 2 つを定義した．いじめ告白対話の前週に 1 度でも同じルームで発言していれば友人，そうでなければ非友人とした．

各ルームタイプの仕様により，いじめ告白対話の告白者と聞き手の人数と友人率は次のようになった．プライベートルームは人数が少なく（中央値 3），パブリックルームとテンポラリルームは人数が多かった（中央値 11）．テンポラリルームは最大人数が 10 名にもかかわらず，対話の参加者はそれよりも多い場合が半数以上であった．これはいじめ告白対話の間にユーザの入退室が頻繁に行われていたことを示す．プライベートルームでは友人との対話が多く，テンポラリルーム・パブリックルームでは非友人との対話が多かった．

対話内容はトピックモデル（Latent Dirichlet Allocation; LDA [Blei 03]）を用いて分析した．トピックモデルはいじめ

*3 「いじめて欲しい」「いじめたい」などの明確にいじめ被害とは関係のない発話は除外した．

表 2: 回帰分析 (式 1) の説明変数．各フラグ x は $x \in \{0,1\}$ である．f は利用頻度，w_i は利用週を調整する変数である．

変数	説明
f	今週の利用日数
d_r	プライベートルームでの告白フラグ
d_u	パブリックルームでの告白フラグ
d_t	テンポラリルームでの告白フラグ
c_r	プライベートルームでの聞き手フラグ
c_u	パブリックルームでの聞き手フラグ
c_t	テンポラリルームでの聞き手フラグ
w_i	i 番目の週フラグ（i 番目の週であれば 1，そうでなければ 0．$i \in [0, 52]$）．時期・季節要因を調整するための共変量．

告白対話に加え，いじめ告白対話でない 3000 対話を用い，それらを 5 分ごとに区切って構築した．その結果，8 つの「いじめ告白対話」に特徴的な対話トピックが抽出された（表 1）．3.2 節ではこのトピックモデルの結果を用いたいじめ告白対話の分析について述べる．

ピグパーティのユーザはデータ分析に関する利用規約に同意した上でサービスを利用している．また本研究で示すデータは対話データの統計処理の結果であり個人を特定可能なものではない．固有名詞等の特異に現れる単語については分析の対象外とした．

3. 結果

3.1 ソーシャルサポートの効果

ここで知りたいことは告白者や聞き手の Well-being にいじめ告白対話が与えた影響であるが，Well-being はユーザの行動ログから知ることはできない．そこで，本稿ではユーザの利用日数の増加を Well-being の向上と仮定する．いじめ告白をしたこと・されたことがユーザにとってよい経験であったとすれば，そのユーザの利用日数は増加するはずだからである．すなわち，いじめ相談効果を次週の利用日数 y に与えた効果とする．それを評価するために次の式 1 に示す一般化線形モデルを考えた．

$$\begin{aligned} y &\sim B(7,p) \qquad (1)\\ logit(p) &= \beta_0 + \beta_1 f + \beta_2 b_r + \beta_3 b_u + \beta_4 b_t \\ &\quad + \beta_4 c_r + \beta_5 c_u + \beta_6 c_t + \sum_{i=0}^{52} \gamma_i w_i \end{aligned}$$

ここで，B は二項分布，p は各日にログインする確率である．説明変数を表 2 に示す．このモデルを元にして AIC にもとづいて変数選択を行った．

その結果を表 3 に示す．f, d_r, d_u, c_r, c_t の変数が選択された（調整用の共変量 w_i については分析の対象ではないので省略する）．プライベートルームで告白することが告白者に正の影響を与えた（$d_r > 0$）．一方で，パブリックルームで告白した場合は負の影響を与えた（$d_u < 0$）．テンポラリルームでの告白の効果は検出できなかった（AIC による変数選択において変数として採用されなかった）．聞き手に対する効果としては，プライベートルームとテンポラリルームでユーザに正の影響を与えた（$c_r, c_t > 0$）．

したがってプライベートルームでは，告白者の自己開示とそれに応じた聞き手によるソーシャルサポートの提供が行われていたことが示唆される．一方で，テンポラリルームとパブリックルームでは自己開示やソーシャルサポートになんらかの問題が有ったと思われる．

表 3: いじめ告白が告白者・聞き手に与えた影響 (式 1)．共変量 w_i は分析の本質ではないので示していない．

Explanation Variable	Coefficient	Standard Error	t-value	p-value	
f	0.50397	0.00279	180.664	Less than 2.0×10^{-16}	***
d_r	0.28737	0.04104	7.003	2.5×10^{-12}	***
d_u	-0.28158	0.13125	-2.145	3.2×10^{-2}	*
c_r	0.26653	0.02647	10.068	Less than 2.0×10^{-16}	***
c_t	0.10321	0.01382	7.470	8.0×10^{-14}	***
Intercept	-1.10932	0.04293	-25.838	Less than 2.0×10^{-16}	***

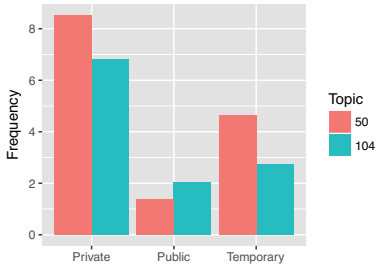


図 2: いじめの説明（トピック 104）といじめの対策（トピック 50）の 1 人あたりの出現頻度．

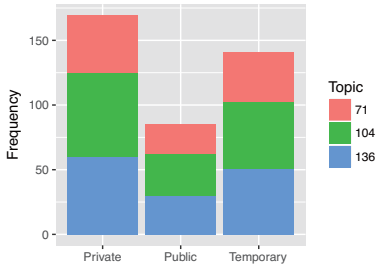


図 3: 自己開示的なトピック（不登校（71），いじめの説明（104），自殺（136））に含まれる単語が告白者の発話に含まれる頻度．各トピックについて PMI（$\log_2 P(w|t) - \log_2 P(w)$）が正の単語を対象とした．$P(w)$ は単語 w の出現比率，$P(w|t)$ はトピック t の元での単語 w の出現比率である．

3.2 自己開示とソーシャルサポート

前節の分析からプライベートルームの告白者の自己開示と聞き手のソーシャルサポートの存在が示唆された．本節では具体的にどのようなものであったかを，効果の検出されなかったテンポラリルーム，負の影響があったパブリックルームと比較して分析した．

図 2 にいじめの説明（トピック 50）と対策（トピック 104）のトピックのいじめ告白対話参加者 1 人当たりの出現頻度を示す．2 つのトピックの出現頻度はプライベートルーム，テンポラリルーム，パブリックルームの順に多かった．またプライベートルームとテンポラリルームはいじめの状況説明よりも対策の方が多い，一方でパブリックルームでは説明よりも対策の話題のほうが少ない．これは前者 2 つでは告白者の「いじめの告白」に対して対話が発展し，いじめについての説明や対策に関する議論が行われているが，後者ではほとんど取り合われてないことを示すと考えられる．そのため前節の分析では，パブリックルームでのいじめ告白は告白者に負の影響があり，聞き手には影響が無かったのだと考えられる．

告白者の自己開示について見るために，図 3 に告白者の自己開示的な発言（不登校，いじめの説明，自殺トピックで特徴的な単語が含まれる発話）の頻度を示す．こちらもプライベートルーム，テンポラリルーム，パブリックルームの順で多かった．したがってどのルームタイプでも告白者は自己開示をしているが，プライベートルームが最もその傾向が強かったと言える．

ではいじめ告白対話の内容は何が異なったのか？前述のようにパブリックルームではほとんど取り合われていなかった．そのため以下ではプライベートルームとテンポラリルームの差に焦点を当てる．図 4 に両ルームにそれぞれ特徴的なトピックの出現頻度の時間発展を示す（ユーザ 1 人あたりの平均値）．対話中ではじめて「いじめ（イジメ，虐め，苛め）」を含む発言がされたときを 0 分としたときの，相対的な時間ごとに示している．

両者に共通して 0 分に「いじめの説明」と同時に「いじめの対策」が増加し，その後の主なトピックは「いじめの対策」になった．これは告白者がいじめられていることを告白した直後から，そのルームにいるユーザで対策について話し合っていたことを示す．すなわち両ルームともに聞き手はソーシャルサポートを提供していたと言える．

プライベートルームでは「共感」トピックが対話の全体を通して見られた．したがってプライベートルームでは告白者に対し聞き手の同情的な反応が多かったと思われる．一方でテンポラリルームでは「煽り」という告白者や他の聞き手に対して悪意ある発言に関するトピックが全体的に一定数見られた．テンポラリルームでも「いじめの対策」トピックが最も多かったことから，基本的には対策について話し合ってるものの，一部の聞き手が他者を煽るような発言をしていたと考えられる．

そのような内容の違いにおける告白者への影響はいじめ告白対話への参加時間にも反映された．告白者の滞在時間もプライベートルームは他のルームに比べて際立って長い（図 5）．一方で，聞き手の滞在時間は各ルームタイプで大きな違いはない．プライベートルームでは対話が発展したため滞在時間が長くなり，対して，テンポラリルームとパブリックルームでは煽られる・取り合ってもらえないなど，いじめ告白対話を発展させづらかったため滞在時間が短くなったと考えられる．

以上からプライベートルームでは告白者に対して，聞き手はいじめ対策について話し合う，いじめを受けていることに対して共感を示すなどをして，いじめ告白対話は十分に発展したと考えられる．それらがソーシャルサポートとして働き，告白者に対して正の影響を与えたのであろう．これはプライベートルームでの対話は少人数の友人から構成されていたためだと考えられる．

テンポラリルームでも同様に告白者に対して，聞き手はいじめ対策について話し合っていたが，その一方で他者を煽るなど告白者を含む対話参加者に対して悪意のある発言をするユーザもいた．そのためいじめ告白対話は発展しづらく，テンポラリルームでのソーシャルサポートは有効に機能しなかったと考えられる．これはテンポラリルームが誰でも入室可能なため，対話が多くの非友人から構成されていたためであろう．

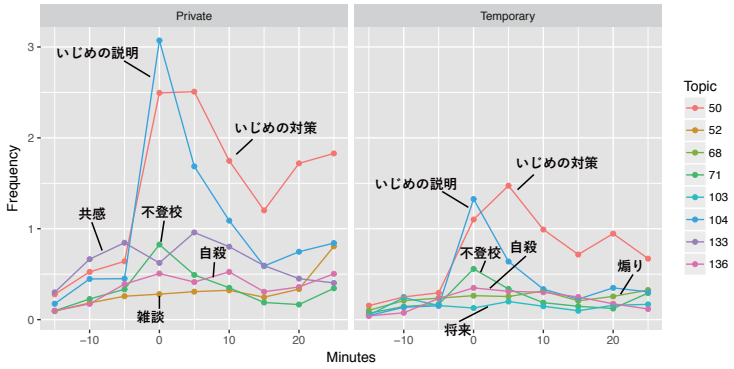


図 4: 特徴的なトピック出現頻度の推移.

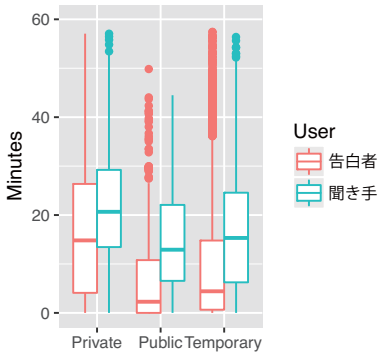


図 5: いじめ告白者の滞在時間.

4. 議論

本研究では，オンラインコミュニケーションにおけるいじめ被害者に対するソーシャルサポートを促進するために，ピグパーティ上で行われているいじめの告白と相談行動を分析した．その結果，告白の聞き手と告白者の関係性や聞き手の対応に依存して，ソーシャルサポートが有効に働くか否かが決まることがわかった．

入退室が制限されたプライベートルームにおいて，少人数の友人に対していじめ告白をしたとき，告白者に対してソーシャルサポートは有効に働いた．そこでは告白者は自身がいじめられていることや，その結果，不登校になった（またはしたいと考えている）ことや自殺を示唆する発言が見られるなど，自身の状況や感情について自己開示を行っていた．それに対して聞き手は対策を話し合う，共感を示すなどをしていた．これがソーシャルサポートとして働いていたと考えられる．

一方で，テンポラリルームでは告白者が自己開示をし，聞き手がソーシャルサポートを提供するような行動を示しても，有効に働かなかった．一部の聞き手がソーシャルサポートではなく告白者を貶すような発言をしていたからであった．テンポラリルームでの対話は人数が多い，非友人の割合が高い，人の入退室が激しい（通りすがりのユーザが多い）ため，そのような悪意あるユーザがいじめ告白対話に含まれがちだったのであろう．

パブリックルームでは，告白者が自己開示をしても，聞き手が取り合わずいじめ被害について対話が発展しなかった．それは告白者に対して負の影響を与えることがわかった．このときも聞き手の人数は多く，非友人の割合が高かった．

Choudhury ら [Choudhury 14] は電子掲示板で自己開示とオンラインソーシャルサポートの関連を示した．本研究では，プライベートルームとテンポラリルームのいじめ告白対話でのみこの傾向が見られた．興味深いことに告白者に対してソーシャルサポートが有効に働いたのはプライベートルームのみであった．これはソーシャルサポートが有効に働くためには，告白者と聞き手が友人であること，悪意ある発言をする人がいない閉じた場での対話が重要であることを示唆する．

またソーシャルサポートを提供した聞き手にもよい影響が見られた．ソーシャルサポート提供は提供者の Well-being を向上させる [Morelli 15] が，この結果はその効果がオンラインコミュニケーションであっても成立することを示す．告白者にソーシャルサポートが有効に働かなくてもこの効果は見られた．すなわち聞き手が大人数の場で告白者と非友人であっても，ソーシャルサポートの提供者への効果は有効だった．

以上からオンラインソーシャルサポートを促進するためには，アクセスがある程度制限される閉じた場で友人に対して自己開示をすることが重要であった．また，匿名性は自己開示をしやすくするために重要である [Choudhury 14, Kang 16]．ピグパーティは現実世界とは切り離された社会関係が構成される傾向にあり匿名性が高い．また各ユーザが自分のプライベートルームを持つため閉じた場で対話することができる．したがって，自治体及び学校の既存のいじめ対策や，幅広く使われているオンラインコミュニケーションサービスでのコミュニケーションを補間し，いじめ被害の悩みなどを打ち明けて相談する場として機能することが期待できる．

自己開示とオンラインソーシャルサポートの機能をより促進するためには，例えば，システムからユーザに話題の提供をする機能を実装し，他愛も無い話題と共に自己開示を促す話題を提示するなどが考えられる．ただし，テンポラリルームやパブリックルームでのいじめ告白対話の効果が示すように，聞き手との関係性やルームの仕様などの環境に依存して告白者に良い影響がない・悪い影響を与えてしまうことがある．そのため閉じた場での友人同士のコミュニケーションにおいて自己開示を促すことが重要である．

参考文献

[Blei 03] Blei, D. M., et al.: Latent Dirichlet Allocation, *Journal of Machine Learning Research*, Vol. 3, No. Jan, pp. 993–1022 (2003)

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

[Kang 16] Kang, R., et al.: 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.

[Mimno 11] Mimno, D., et al.: Optimizing semantic coherence in topic models, *EMNLP*, pp. 262–272 (2011)

[Morelli 15] Morelli, S. A., et al.: Emotional and instrumental support provision interact to predict well-being., *Emotion*, Vol. 15, No. 4, pp. 484–93 (2015)

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

ネットワーク構造に基づく新聞記事の分類による読者の行動分析

Analysis of readers by Classification of Articles in a News Service from Network Structures

園田 亜斗夢 *1　鳥海　不二夫 *1　中島 寛人 *2　郷治 雅 *2
Atom Sonoda　Fujio Toriumi　Hiroto Nakajima　Miyabi Gouji

*1東京大学　*2日本経済新聞社
The University of Tokyo　Nikkei Inc.

Information is transmitted through websites, and the immediate reaction to various information is required. Hence, the efforts for readers to select information themselves have increased, which leads to the further improvement of recommendation services that can reduce such burdens. On the other hand, it is pointed out that filter bubbles that only provide biased information to users are generated due to the redundant recommendation. In this research, we analyzed behavioral changes prior to recommendation by clustering, and showed that behavior changes after average number of browsing number and article type change during the period.

1. はじめに

新聞社等のメディアの発信するニュースの主な媒体が新聞から web サイトに拡大するに従い，記事の速報性の向上や記事数の増加が進んでいる． これに伴い，ユーザが記事を選択する際に必要な時間と労力が増大していると推測される．このような負担を減らし，満足度を向上させるため，ユーザの嗜好に応じた推薦サービスは多くの分野で導入されている。一方で，過度の推薦によってユーザに偏った情報のみを提供するフィルターバブルが発生しているとの指摘もある [Pariser 2011]．

記事の推薦は，ユーザの選択行動を変容させる可能性がある [Nguyen 2014]．本研究では，フィルターバブルの発生を抑制し，多様な意見に触れる機会を提供できるような推薦システムの開発のために，推薦システム開発に先立ち，既存のニュースサイト上でどのような場合にユーザは行動を変容させるのかについて分析する．新聞社の 1 つである日本経済新聞社の web サービス日経電子版を用いて，筆者らが提案した記事の分類手法 [園田 2018] に基づき，分類された記事の情報を用いて，ユーザの行動が変容する過程について分析する．実際の推薦システムでは，ユーザの行動履歴を閲覧した記事のクラスタの割合を分析し，それに基づき記事を推薦し，読む記事を変化させることで読者の行動変容を促すことを目指す．本研究では，推薦システムの開発に向け，閲覧記事の多様性が増加したユーザの行動変容要因を明らかにする．

2. 記事のクラスタリング

2.1 分析に用いるデータ

本研究では，2017 年 5 月 21 日から 8 月 20 日までの 3ヶ月間の日本経済新聞社の web サービス日経電子版のデータを用いる．この間に読まれた記事は全部で約 60 万記事であり，会員数は約 200 万人であった．

この中で，一定程度以上読まれている記事のみを扱うため，今回は読者が 100 人以下の記事は対象から除いた．これは，将来的な推薦システムの開発には，ニュースという即時生の高いコンテンツであるという性質上，24 時間以内の記事を優先して推薦するため，定期的な更新が必要となり，計算時間の観点からデータを減らす必要があることと，推薦ではフィルターバブルを抑制するという目的から全体のユーザ数に対し極端に読者の少ない特殊な記事を推薦することは考えていないためである．分析対象となるデータはこれらの処理を行った約 7 万記事である．

連絡先: 園田　亜斗夢，東京大学，東京都文京区本郷 7 － 3 － 1，090-1364-4850，sonoda@crimson.q.t.u-tokyo.ac.jp

2.2 関連記事ネットワークの構築

ある 2 つの記事を読んだユーザが複数人いた場合，2 つの記事は共通した興味を引く内容を有していると考えられる．つまり，記事を読んだユーザの重複度から記事の類似性を求めることができる．そこで，ユーザの重複度の高い記事同士をリンクで結ぶことで，記事ネットワークの構築を行う．2 つの記事 a_i，a_j のユーザ群 U_i，U_j の重複率は Simpson 係数を用いて次のように求められる．

$$Sim(a_i, a_j) = \frac{|U_i \cdot U_j|}{min(|U_i|, |U_j|)} \quad (1)$$

ここでは，前述の類似度が閾値 0.62 以上の記事の間にリンクを張ることで，重みあり無向ネットワークを構築した．このとき，モジュラリティQ=0.936，リンクは 38002 件，ノードは 17233 件であった．

なお，このような類似度を測る指標としては，Simpson 係数のほかに Jaccard 係数，Dice 係数などがあるが，共起を用いた関係性の強さを表現するための指標としては Simpson 係数が適切であるとされている [松尾 2005].

2.3 記事のクラスタリング

ここで, 上記のネットワークに対してクラスタリングを行った．クラスタリング手法には Modurality を基準とする Louvain 法 [Blondel 2008] を用いた．クラスタリングにより，2470 件のクラスタが得られた．これらのいずれかのクラスタに含まれる記事は，図 1 のようになっている．横軸に記事の投稿日，縦軸に記事数をとったものである．記事数が多い日と少ない日があるのは，休日は記事が減るためである．この図から，対象期間内に発表された記事が多く含まれていることがわかる．一方，期間の後半では，発表された後の日数が少なく，閲覧数が適切に蓄積されていないことから，クラスタリング結果に含まれる記事数が減少していることがわかる．このことから，この先の行動分析では，クラスタリング結果に含まれる記事数が十分ある，クラスタリング対象期間の前半と中盤を比較する．

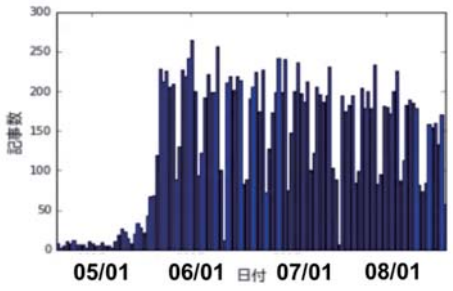


図 1: いずれかのクラスタに含まれる記事数の推移

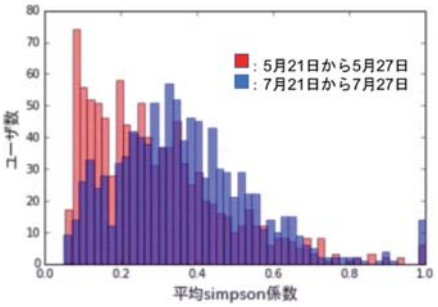


図 2: クラスタ間平均類似度の変化

3. 読者の行動変容の分析

読者の行動を，読んだ記事の種類，と定義して，ある一定の期間経過後，その行動が変化したかどうか評価する．特に，本研究では閲覧行動の多様性の変化を行動変容として分析する．

3.1 閲覧行動の多様性の評価

読者ごとの閲覧記事を，前章のクラスタリングのどのクラスタに属するかにより評価し，読んだ記事のクラスタの類似度により閲覧行動の多様性を評価する．クラスタ間の類似度は，クラスタに含まれる記事を読んだユーザに基づいて，2 つのクラスタ c_i，c_j のユーザ群 U_i，U_j から Simpson 係数を用いて次のように求められる．

$$Sim(c_i, c_j) = \frac{|U_i \cdot U_j|}{min(|U_i|, |U_j|)} \tag{2}$$

これにより，クラスタ毎の類似度がわかる．これを用いて，ユーザ u の閲覧性の多様性は，u が読んだ全ての記事 n 件について，2 つの記事 a_i，a_j の属するクラスタ $c(a_i)$，$c(a_j)$ から以下の式で表される，クラスタ間平均類似度により評価する．

$$f(u) = \frac{\sum_{i,j,i\leq j} Sim(c(a_i), c(a_j))}{{}_{n+1}\mathrm{C}_2} \tag{3}$$

一定期間ごとに閲覧行動の多様性を評価し，多様性に変化が見られた読者について，その特徴を分析する．一般に，フィルターバブルとは推薦システムによりユーザがその人の観点に合わない情報から隔離され，ユーザ自身の興味があると判断された範囲に集約されていくことである．したがって，読んでいる記事のクラスタの類似度でその影響を測ることができると期待される．例えば，もしフィルターバブルによって観点に合う情報のみと接するようになれば，閲覧記事は類似したものが多くなるため，多様性が失われ，$f(u)$ の値は増加すると考えられる．

3.2 実験

分析では，5 月 21〜27 日（期間 1）と 7 月 21〜27 日（期間 2）の行動を比較した．これは，前章で確認した通り，クラスタリング対象期間の後半では，クラスタに含まれる記事が減少するためである．この期間に，それぞれ 10〜100 記事読んでいるユーザを選択し，その中のクラスタに含まれる記事を 10 以上読んでいるユーザから 1000 ユーザをランダムサンプリングする．これらの読者について，前節で定義したクラスタ間平均類似度を求める．

3.3 結果と考察

クラスタ間平均類似度は図 2 のようになった．期間 1 の平均類似度の平均は 0.292, 期間 2 の平均は 0.364 となり，有意水準 1 %で有意に平均類似度は上昇していた．クラスタ間平均類似度は，ユーザの興味に基づいてクラスタリングされた記事のクラスタの類似度によって，ユーザの読んでいる記事の興味の幅を測るものである．つまり，クラスタ間平均類似度が大きいということは類似した記事を読んでいるということで，クラスタ間平均類似度が上昇した場合は興味が狭まり，低下した場合は興味の幅が広がったと言える．よって，この分析から，既存の表示システムでも，期間が進むにつれ，興味が偏っていくと考えられる．これには，ランキングやあなたへのおすすめという推薦システムが導入されていることが影響していると推測される．

4. 読者の行動変容を導く特徴の分析

ここでは，前章で得られた期間 1，2 のクラスタ間平均類似度について，ユーザごとの変化を分析する．前章で述べたとおり，全体ではクラスタ間平均類似度は上昇し，つまり，多様性は減少していた．一方，クラスタ間平均類似度が低下し，多様性が増加していた読者もいた．そこで，多様性増加グループと多様性減少グループを比較する．

4.1 対象ユーザと比較する特徴量

多様性増加グループは 1000 読者中 259 ユーザであった．一方，多様性減少グループとして，多様性が減少した読者から増加グループと同数の上位 259 ユーザを選んだ．これらの多様性減少グループに含まれるユーザは，類似度が 68.7 %以上上昇している特に類似度が上昇しているユーザ群で構成される．これらの多様性減少グループと多様性増加グループの間で，期間中の閲覧数，クラスタエントロピーと，行動評価の指標となる期間 1，2 のクラスタ間平均類似度と，ユーザ属性として年代，入会年，性別を比較した．まず，前章で定義したクラスタ間平均類似度の変化と，期間中に読んだ記事数，クラスタの種類の平均情報量（クラスタエントロピー）の関係を分析する．なお，クラスタエントロピーとは，クラスタ間の類似度は考慮せず，読んだクラスタの種類の多様性を測る指標で，p_i を各ユーザにおけるクラスタ c_i の存在確率として以下のように表される．

$$H(u) = -\sum_i p_i \cdot logp_i \tag{4}$$

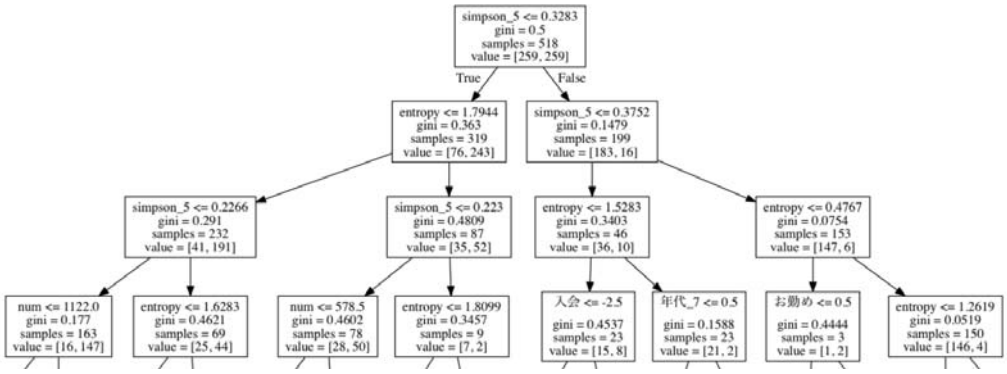


図 3: 期間 1 の平均類似度を含めた決定木分析

表 1: 多様性の変化別の特徴量の平均

多様性	増加	減少	有意水準
閲覧数	536	486	P<0.05
クラスタエントロピー	1.47	1.60	P<0.01
期間 1 の平均類似度	0.416	0.179	P<0.01
期間 2 の平均類似度	0.322	0.409	P<0.01

4.2 結果

各指標の結果を表 1 に示す．表 1 より，多様性増加グループのユーザは記事の閲覧数が多いことがわかることから，多くの記事を読んだユーザは興味が広がると考えられる．一方，多様性増加グループのクラスタエントロピーは低い．このことから，単純に異なるクラスタの記事を読むだけでは，3.1 節で定義したクラスタ間平均類似度で測れる多様性は増加しないことがわかる．これは，クラスタにはそれぞれ類似度があり，類似度の高いクラスタと低いクラスタでは意味が異なるためと，クラスタに含まれる記事の数に差異があるためと考えられる．

期間 1，2 のクラスタ間平均類似度に関しては，平均類似度が低下した多様性増加グループは期間 1 がもともと高く，平均類似度が上昇した多様性減少グループは期間 2 が低いという結果が得られた．

ユーザ属性に関しては，性別と入会年には有意差が認められず，年代については，会員数の少ない 70 代と 20 代以下以外は有意差が見られなかった．

4.3 決定木分析

上記の多様性増加・減少グループについて，特徴量として前節と同様の期間中の閲覧数，クラスタエントロピーと，行動評価の指標となる期間 1 のクラスタ間平均類似度と，ユーザ属性として年代，入会年，性別を用いて決定木分析を行った．ただし，期間 2 の平均類似度に関しては，実際の推薦では，推薦した後に推薦の影響を測定するために用いるもので，推薦の前には測定不可能なため除いた．交差検定を行った結果は，77.2 %の精度で予測できた．この時の決定木を図 3 に示す．value の 1 項目は多様性増加グループ，2 項目は多様性減少グループである．この図から，期間 1 のクラスタ間平均類似度の影響が大きいことがわかる．これは，前節で考察したように，期間 1 のクラスタ間平均類似度が低いものは上昇し，高いものは低下するという傾向があるということだと考えられる．

そこで，期間 1 の平均類似度以外の特徴量の予測への寄与を調べるため，期間 1 の平均類似度を除いた分析もしたところ，精度 64.1 %で予測できた．この時の決定木を図 4 に示す．これより，中心の二つの分岐に注目すると，クラスタエントロピーが 1.5889 より低く閲覧数が 531 より多いものは多様性増加グループの割合が多く，クラスタエントロピーが 1.5889 から 1.8593 の間にあり，閲覧数が 1028 以下のものは多様性減少グループの割合が多いことがわかり，大きくは前節の考察と一致し，閲覧数が多いと多様性が増加し，興味の幅が広がりやすいと言える．

表 2: 多様性増加グループに所属するユーザが多く閲覧したクラスタ

多様性増加グループ [%]	多様性減少グループ [%]	クラスタの主な内容
72.6	57.5	短信
66.8	51.4	市場速報
59.1	44.8	米国政治＋医療
30.1	14.7	経済指標
30.1	14.7	科学技術

4.4 特徴的なクラスタの分析

次に，特定のクラスタの記事を読んだ読者は多様性に変化が生じるという仮定のもと，多様性増加・減少グループの一方に多く含まれるクラスタについて分析する．表 2，3 に各グループに多く含まれるクラスタを抜粋した．多様性増加グループに多いクラスタには，国内の政治問題は多くは含まれておらず，米国政治についてもトランプ大統領に関するものであった．また，科学技術や経済情報，市場情報が多く含まれた．一方，多様性減少グループに多いクラスタには政治問題や，企業に関する情報が多く含まれていた．このことから，政治に興味があることと，興味の幅を広げることには，負の相関関係が存在する可能性が示唆された．

4.5 考察

多様性増加グループは少ないが，そのようなグループのユーザは他のユーザに比べて，多くの記事を読んでいることがわかった．その上で，読んでいるクラスタの種類が多いことは興味を広げることにはつながらないことがわかった．これは，[園田 2018] のクラスタリング手法では，クラスタ間に類似度の高いクラスタとそうではないクラスタが生成され，また，それぞれのクラスタに含まれる記事の数に差異があることによる

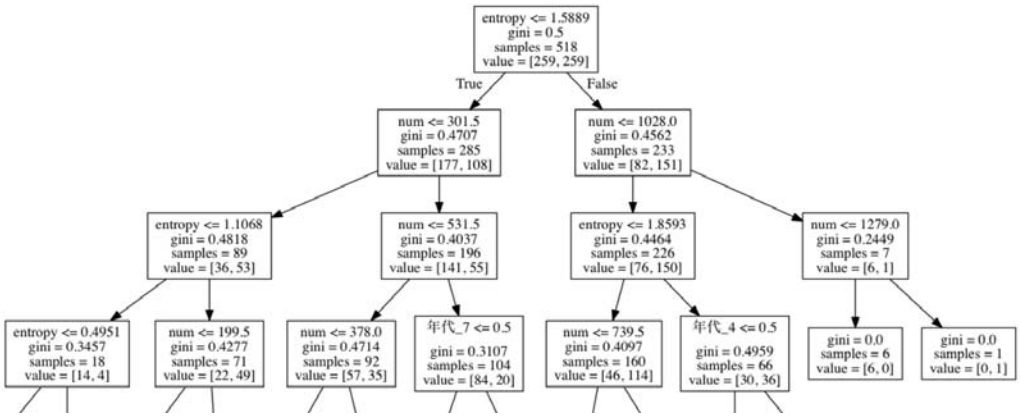


図 4: 期間 1 の平均類似度を除いた決定木分析

表 3: 多様性減少グループに所属するユーザが多く閲覧したクラスタ

多様性増加グループ [%]	多様性減少グループ [%]	クラスタの主な内容
29.3	43.6	IT 企業
19.3	34.7	ヤフー
18.1	33.6	アジア政治＋交通
16.2	32.4	米国政治
8.1	22.4	加計学園問題

と考えられ，推薦では，クラスタの類似度等も考慮する必要があると考えられる．また，ユーザ属性と閲覧数，ユーザエントロピーのみでその後の興味が広がるかどうかを一定程度予測することができることがわかった．しかしながら，期間の開始時点でのクラスタ間平均類似度の情報がある場合は 77%と比較的高い精度で予測できるが，この情報がない場合は，64%と精度が下がることから，ユーザの行動の変化を説明する際に，年齢・性別・職業のようなユーザ属性や閲覧数だけで説明できる部分は限定的であるといえる．このことから，ユーザ属性等に関わらず，行動変容を起こさせることも可能であると期待される．

また，多様性増加グループと減少グループには閲覧割合の異なるクラスタがあり，その中でも政治に関するクラスタなどは，多様性減少グループに所属するユーザが多く読んでいることがわかった．これは，政治に関する記事は同時に関連する記事が多く出されることで，話題に興味を持ったユーザが続けて関連する記事を読み，ほかの話題に興味が向きづらくなるのではないかと推測される．

5. 結論

本研究では，日経電子版の記事について，ユーザの閲覧記録に基づいて，類似度ネットワークを構築し，ユーザの興味に基づいた記事をクラスタリングし，それぞれのクラスタ間の類似度の平均によりユーザの行動の多様性を評価し，2 つの期間の行動を比較し，行動変容を導く特徴について分析した．これらの結果から，閲覧数やクラスタの種類，ユーザの年齢が行動変容に影響を与えていることが確認できた．しかしながら，それらの影響は限定的で，表層的な属性では行動変容の可能性はさほど限定されないこともわかった．また，多様性増加グループと減少グループでは，読んでいるクラスタの内容も異なることがわかった．

今後の課題は，行動変容を導く要因のさらなる分析，これらの結果を利用した推薦システムの開発などが挙げられる．本研究結果から，ユーザの興味は一定期間を経て，多くの記事を読むことで変化するということが確認された．そこで，推薦システムの開発においては，多くの記事が読まれ，クラスタ間の距離を考慮した多様な記事を推薦することで，フィルターバブルの発生を抑制し，多様な意見に触れる機会を提供できるような推薦システムの開発が可能であるか実験することで，行動変容を導く要因のさらなる分析が可能になると考えられる．

参考文献

[Pariser 2011] Pariser, Eli. The filter bubble: What the Internet is hid-ing from you. Penguin UK, 2011.

[Nguyen 2014] Nguyen, Tien T., et al. ”Exploring the filter bubble: the effect of using recommender systems on content diversity.” Proceedings of the 23rd international conference on World wide web. ACM, 2014.

[園田 2018] 園田　亜斗夢, 鳥海 不二夫, 中島 寛人，郷治　雅，ネットワーク構造に基づく新聞記事の分類，第 15 回社会システム部会研究会，2018.

[松尾 2005] 松尾豊, et al. ”Web 上の情報からの人間関係ネットワークの抽出.” 人工知能学会論文誌 20.1 (2005): 46-56.

[Blondel 2008] Blondel, Vincent D., et al. ”Fast unfolding of communi-ties in large networks.” Journal of statistical mechanics: theory and experiment 2008.10 (2008)

2:50 PM - 3:30 PM (Thu. Jun 7, 2018 1:50 PM - 3:30 PM Room O)

[3O1-OS-1a-a] OS invited talk

○Nobuo Sato[1] （1. Hitachi, Ltd.）

我々は人間の行動やコミュニケーションの定量計測を可能にするセンサデバイスの研究を2007年から行っている．研究内容は，センサデバイスの開発だけでなく，行動分析からその利活用までと多岐にわたる．本報告では、我々が今まで取り組んできた行動計測/行動分析手法，及び，ビジネスの事例から，顧客の課題をどのようして解決に導いてきたのかを実例を交えて紹介する．

©The Japanese Society for Artificial Intelligence

Oral presentation | Organized Session | [Organized Session] OS-1

[3O2-OS-1b] [Organized Session] OS-1

Thu. Jun 7, 2018 3:50 PM - 5:30 PM Room O (2F Kaimon)

[3O2-OS-1b-01] Analysis of Moving-time Patterns from Entry and Exit Data of Office Workers

○Seidai Kojima[1], Hayato Ishigure[1], Miwa Sakata[1], Atsuko Mutoh[1], Koichi Moriyama[1], Nobuhiro Inuzuka[1] （1. Department of Computer Science, Graduate School of Engineering, Nagoya Institute of Technology）

3:50 PM - 4:10 PM

[3O2-OS-1b-02] Adaptive experimental designs and method of estimating causal effect

○Hirotoshi Yanagi[1], Takahiro Hoshino[2], Keisuke Takahata[1] （1. Graduate School of Economics, Keio University, 2. Faculty of Economics, Keio University）

4:10 PM - 4:30 PM

[3O2-OS-1b-03] Opinion Formation Model Including Pressure and Silence Caused by Inconsistency

○Sonoko Kimura[1], Kimitaka Asatani[2], Toshiharu Sugawara[1] （1. Waseda University, 2. The University of Tokyo）

4:30 PM - 4:50 PM

[3O2-OS-1b-04] Analysis of differences in viewing behavior of politics news by age

○Yoshifumi Seki[1] （1. Gunosy Inc）

4:50 PM - 5:10 PM

[3O2-OS-1b-05] Conflict mineral regulations based on network structure of global supply chain

○Takayuki Mizuno[1], Takaaki Ohnishi[2], Tsutomu Watanabe[2] （1. NII, 2. Univ. of Tokyo）

5:10 PM - 5:30 PM

©The Japanese Society for Artificial Intelligence

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

オフィスワーカーの入退室データを用いた移動時間パターンの分析

Analysis of Moving-Time Patterns from Entry and Exit Data of Office Workers

小島世大 Seidai Kojima　石榑隼人 Hayato Ishigure　坂田美和 Miwa Sakata　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
Department of Computer Science, Graduate School of Engineering, Nagoya Institute of Technology

Recently, IC card systems are popular and their log data are used for analyzing human behaviors. In this paper, we propose an analysis method of employee's moving-time patterns using log data in entry and exit management system. We express employees with feature quantities focused on moving time from room to room, extract a set of employees with similar moving-time patterns using clustering, and confirm the relationship between moving-time patterns and employee attributes. We examine our proposed method using actual entry and exit data and confirm the effect.

1. はじめに

近年 IC カードの普及に伴い、IC カード利用履歴を用いた人の行動分析の研究が増えている [1][2]。

さらに、電子錠と IC カードにより、人の入退を制御する入退室管理システムの導入が増えている。入退室管理システムは、電子錠に備えられたカードリーダにかざされた IC カードの情報を読み取り通行履歴として記録する。現在では、企業は単純な入退室制御だけではなく、社員や部門毎の入退室傾向の分析や社員がどの部屋にいるのかを把握したいなどの要望がある [4]。また、近年、センサノード及びネットワークの技術が急速に発展している。環境に設置されたセンサノードと人が身に着けるウェアラブルセンサーの併用は、企業におけるオフィス内のワーカーの行動のモニタリングへ利用されている。センサデータを用いたオフィスワーカーの行動分析 [5] もされているが、これには特別な装置を必要とする。本研究では、多くの組織で普及が進んでいる入退室管理システムから得られる入退室データを用いて、社員の移動時間パターンを抽出し、移動時間パターンと社員属性の関係を分析する。本研究で移動とはある部屋を退室し、次にある部屋に入室するまでのこととする。入退室データから社員の行動分析ができれば、企業の働き方改革等への利用も考えられる。

2. 関連研究

IC カードの利用者数の増加により、IC カード利用履歴データが人の行動分析手段として注目を集めている。 鈴木ら [2] は交通 IC カードの利用履歴を用いて人が駅の改札口を出て、次の改札口に入るまでの間にその人の滞在目的があるとし、生活パターンを定量的に表す生活行動属性を提案した。 カード利用者の生活圏 (駅) によらず似た生活パターンを持つ人を抽出しマーケティング等へ活用し得ると示した。また、嶋本ら [1] は英国・ロンドンで導入されている Oyster Card の 4 週間分の利用履歴データを用いて公共交通の変動を把握した。料金支払い形態に応じて利用者の利用属性を分類することで，1 人あたりの利用回数の変動の 4 割以上を説明できることを示した。さらに，分析対象の 4 週間の期間に学生の秋休み期間が含まれていることに着目した分析を行い、秋休み期間中には直接関連する学生のみならず学生以外の利用者の公共交通の利用が減少することを明らかにした。

水岡ら [3] は 大量の視聴データにクラスタリング手法を適用し、好みのチャンネルの連続視聴や特定日時のチャンネル切り替えなど特徴的な視聴パターンを持つ集合を機械的に抽出できることを示した。視聴パターンとは、時間帯ごとの視聴行動の組み合わせのことであり、特徴的な視聴パターンの抽出や、その視聴パターンを持つ視聴者集合の傾向分析をすることは、視聴者の特性を生かした番組や CM を作成することが容易になり、テレビメディアの価値の向上、視聴者に合わせた魅力的なコンテンツの提供などの抽出、分析することのメリットについても述べている。

本研究では、会社内の入退室データからクラスタリングを用いて、似た移動時間パターンを持つ社員の集合を抽出する。その集合に含まれる社員の属性分布と移動時間パターンの関係について分析し、考察する。

連絡先: 小島世大, 名古屋工業大学 大学院, 〒 466-8555 愛知県名古屋市昭和区御器所町, s.kojima.571@nitech.jp

3. 入退室データ

本研究では (打刻日、打刻時刻、場所、操作、社員 ID) の 5 つの属性で構成された入退室データを扱う (表 1)。操作には、部屋を退室もしくは入室したかが記録されている。移動時間に着目するために、退室と入室がセットになっているものを結合し、表 2 のようなデータ構造に変換する。移動時間は入室時刻 − 退室時刻で計算する。

表 1: 入退室データ

打刻日	打刻時刻	打刻場所	操作 (退室 or 入室など)	社員 ID

表 2: 変換後のデータ構造

退室日	退室時刻	移動時間	退室場所	入室場所	社員 ID

4. 事前調査

協力企業の入退室データ (2016 年 6 月 332 名分) から社員の移動時間に着目した調査を行った。図 1 に移動開始時刻と移動時間の散布図を示す。図 1 より、どの時間帯においても 0-5

分の移動時間である移動が多く、昼休憩の時間帯 (12 時から 12 時 50 分) は移動時間が長い移動が多くみられる。さらに、協力企業の聞き取り調査より昼休憩で移動時間の長い移動は社外にランチを取りに行っている可能性があると考えられる。

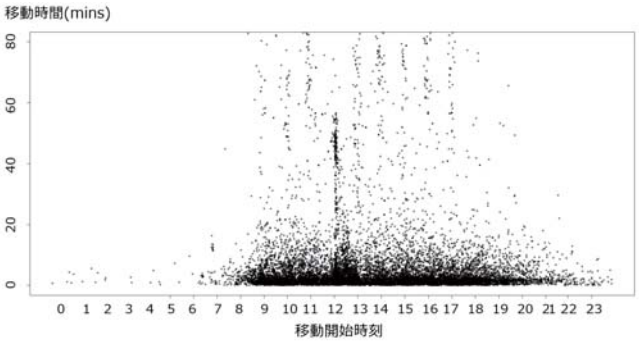


図 1: 移動開始時刻と移動時間の散布図

次に移動開始時刻毎の移動回数の頻度を図 2 に示す。移動開始時刻を 10 分で区切り、6 種類の色分けで示した。図 2 から毎時 50 分から 0 分 (ピンク) 及び 0 分から 10 分 (赤) に移動が多くみられる。また、特に昼 12 時頃の移動が多くみられた。

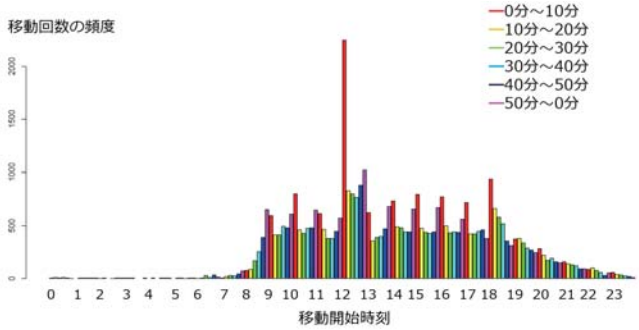


図 2: 移動開始時刻毎の移動回数の頻度

これらの事前調査より、時間帯や移動時間区分毎に移動回数を数える方法で社員の移動時間のパターンを読み取ることが可能だと考える。

5. 提案手法

提案手法の流れを図 3 に示す。まず、全社員に対して時間帯及び移動時間区分毎の移動回数を移動特徴量として算出する。算出した移動特徴量を正規化しクラスタリングを行い、適合度検定を用いてクラスタ毎の社員属性の分布とそのクラスタの移動パターンの特徴について考察をする。

5.1 移動特徴量

社員 p を次の特徴量ベクトル F_p で表す。

$$F_p = (m_{p1}, m_{p2}, ..., m_{pi}, ..., m_{pk})$$

社員 p の移動特徴量 m_{pi} は移動区分 i(時間帯及び移動時間区分) の移動回数とする。例えば、図 4 に示す社員 ID1 の午前の移動時間区分 (0-5 分) の移動回数は、入退室データより 10:00 と 11:00 の 2 回となる。

移動特徴量の算出 (5.1 節)
↓
移動特徴量の正規化 (5.2 節)
↓
移動特徴量によるクラスタリング (5.3 節)
↓
適合度検定 (5.3 節)

図 3: 提案手法の流れ

退室日	打刻時刻	移動時間	退室場所	入室場所	社員ID
6/12	10:00	4分	Room1	Room1	1
6/12	11:00	3分	Room1	Room2	1
6/13	13:00	8分	Room2	Room4	1
6/12	14:00	7分	Room2	Room3	2
6/12	15:00	2分	Room3	Room3	2

入退室データ(変換後)

社員ID	午前 移動時間区分 (0-5分)	午前 移動時間区分 (5-10分)	午後 移動時間区分 (0-5分)	午後 移動時間区分 (5-10分)
1	2回	1回	0回	0回
2	0回	0回	1回	1回

図 4: 社員毎の移動特徴量の算出例

5.2 移動特徴量の正規化

5.1 節で算出した移動特徴量からクラスタリングによって似た移動時間パターンを持つ社員の集合を抽出するために、値の正規化を行う。似た移動時間パターンとは、社員の総移動回数に対する移動区分毎の移動回数の割合が似ている場合と考えられるため、まず、社員に対して総移動回数のみでクラスタリングをする。クラスタリングには k-means 法を用い、クラスタ数は elbow 法で決定する。クラスタリングの結果、クラスタ内人数の少ないクラスタや総移動回数の極めて少ないクラスタは移動時間パターンの抽出が困難であると判断し、取り除く。

次に総移動回数でクラスタリングした結果と次の式を用いて 5.1 節で表した社員 p の移動特徴量 m_{pi} を正規化する。

$$m_{pi} \leftarrow \frac{m_{pi}}{\sum_{j \in c} m_{ji}}$$

c は社員 p を含むクラスタである。移動特徴量毎に社員の移動特徴量の値の割合を計算することで移動特徴量毎の値の大きさを揃える。しかし、全社員に対して移動特徴量毎の計算を行うと、移動時間パターンの似た移動回数の少ない社員と移動回数の多い社員の移動特徴量の割合は異なる値となる。そこで、社員の移動特徴量の割合をクラスタ毎に計算することで、移動回数の少ない社員と移動回数の多い社員を比較したときに、それぞれの移動区分毎の移動回数の割合が同じであった場合に似たパターンを持つ社員であるとみなす。

5.3 移動特徴量によるクラスタリングと適合度検定

5.2 節の方法で正規化した移動特徴量を用いて全社員に対してクラスタリングを行う。クラスタリングには k-means 法を用い、クラスタ数は elbow 法で決定する。次に、クラスタ毎の社員属性の分布と全社員属性の分布に対して適合度検定を行い、検定結果の中で有意差のあったクラスタ毎に移動時間パターンと社員属性の分布の関係について考察する。

6. 実験

6.1 実験方法

実験では協力企業の 2016 年 6 月の 332 名の入退室データを表 2 の形式に変換し、60 分以内の移動時間であった移動のみを用いる。移動特徴量の正規化を行い、社員を 9 次元 (時間帯 (午前・昼休憩・午後の 3 次元) ×移動時間区分 (0-5 分・5-20 分・20-60 分の 3 次元)) の特徴量で表した。適合度検定で用いる社員属性は、(性別、部署、職種、採用種別、年代、社歴) の分布とし、有意水準は 5 %とした。

6.2 結果と考察

移動特徴量の正規化のためのクラスタリングの結果、クラスタ内人数が少ないクラスタ 1 と移動回数の少ないクラスタ 7 の 97 名を取り除いた (表 3)。残りの 235 名の社員を正規化した移動特徴量によるクラスタリングを行った結果、9 つのクラスタに分かれた (図 5)。ここで、クラスタ同士の移動時間パターン (社員の総移動回数に対する時間帯及び移動時間区分毎の割合) がすべて異なる特徴を持っていたことが確認できた。表 4 に検定結果の p 値を示す。赤字で示す 5 つの項目において有意差を確認した。次に、有意差の出た項目について、クラスタの時間帯及び移動時間区分毎の移動回数の特徴と社員属性分布の関係について考察する。

表 3: 移動特徴量の正規化のためのクラスタリング結果

クラスタ番号	クラスタ内人数	移動回数の平均
1	2	581
2	13	308
3	46	214
4	60	150
5	71	71
6	45	58
7	95	8

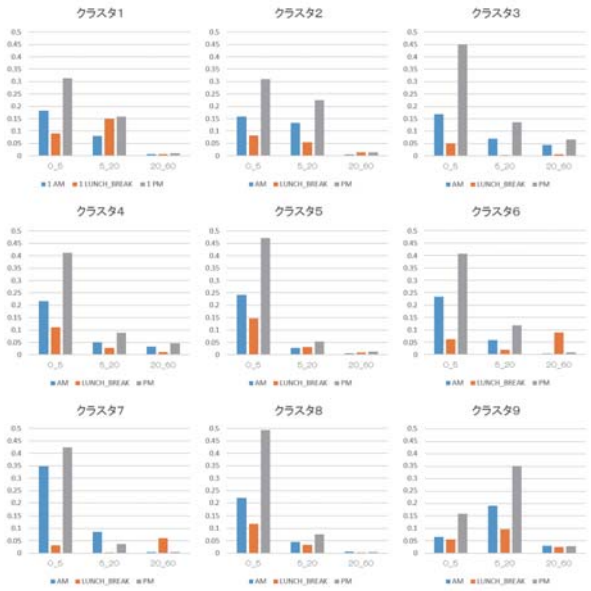


図 5: 全クラスタの移動時間パターンの特徴 (x 軸は移動時間区分,y 軸は移動回数の割合の平均)

表 4: 検定結果 (赤字は p< 0.05,df は自由度)

クラスタ	クラスタ内人数	性別 (df:2)	部署 (df:17)	職種 (df:9)	採用種別 (df:4)	年代 (df:8)	社歴 (df:6)
1	20	0.3	0.3	0.6	0.1	0.2	0.9
2	39	0.08	0.4	0.9	0.1	0.9	0.7
3	4	0.08	0.008	0.09	0.1	0.5	0.3
4	28	0.4	0.1	0.3	0.4	0.4	0.3
5	98	0.6	0.8	0.9	0.6	0.9	0.9
6	26	0.3	0.04	0.4	0.3	0.5	0.3
7	2	0.06	0.4	0.02	0.02	0.5	0.4
8	8	0.7	0.2	0.3	0.4	0.6	0.08
9	10	1	0.9	0.5	0.2	0.8	0.03

クラスタ 6 の人数は 26 人であった。図 6 にクラスタ 6 に含まれる社員、図 7 に全社員の時間帯及び移動時間区分毎の総移動回数に対する移動回数の割合の平均を示す。図 6 と図 7 を比較すると、移動時間が長い移動が昼休憩に多い特徴を持つクラスタであった。次に、図 8 にクラスタ 6 に含まれる社員と全社員の部署の分布を示す。このクラスタ 6 に含まれる社員は全社員の分布に比べて 1800 の部署が特に多く、逆に 1500 の部署は全社員の分布に比べて少ないことが分かる。この結果から 1800 の部署は部署内で社員同士が仲が良く昼休憩も一緒にとりに行く人が多い部署であるのではないかという推測もできる。

次に、図 9 にクラスタ 9 の 10 人の時間帯及び移動時間区分毎の総移動回数に対する移動回数の割合の平均を示す。クラスタ 9 の 10 人と全社員の移動時間区分毎の特徴を比べたところ、クラスタ 9 は午前、昼休憩、午後で少し長めの移動時間区分 (5-20 分) の移動が多い特徴を持つクラスタであった。有意差がでた社歴の分布を確認すると、クラスタ 9 に含まれる社員は全社員の社歴分布に比べて 10 年以上 15 年未満の社歴である社員が特に多く、社歴が 5 年未満の社員が少ないことが分かった (図 10)。この結果から、社歴が少し長くなってきた社員は移動に時間がかかることが多く、たばこ等の小休憩を取りやすくなっている可能性も推測できる。

他に、クラスタ 3 の 4 人と全社員の時間帯及び移動時間区分毎の特徴を比べたところ、クラスタ 3 は昼休憩の移動回数が少ない特徴を持つクラスタであった。有意差がでた部署の分布を確認すると、クラスタ 3 に含まれる 4 人はそれぞれが違う部署に属していた。適合度検定を行って有意差が出たのは期待度数の設定が全データの社員属性の分布の割合とするためであると示唆される。よって、このクラスタの移動時間のパターンが部署に関係しているとは考えにくい。

また、クラスタ 7 の 2 人と全社員の時間帯及び移動時間区分毎の特徴量を比べたところ、午前の短い時間の移動が多く、昼

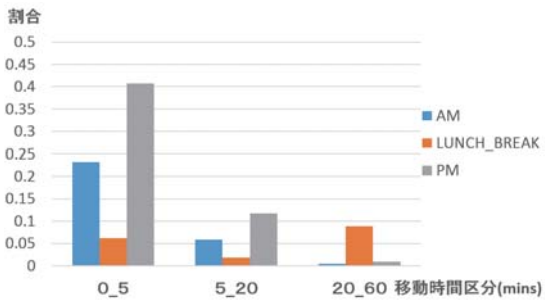


図 6: クラスタ 6 に含まれる社員の移動時間区分毎の移動回数の割合の平均

休憩は長めの時間の移動が多い特徴を持つクラスタであった。有意差がでた職種と採用種別の分布を確認すると、社員 2 人のそれぞれが違う職種と採用種別であった。適合度検定を行って有意差が出たのは期待度数の設定が全データの社員属性の分布の割合とするためであると示唆される。よって、このクラスタの移動時間のパターンが職種と採用種別に関係しているとは考えにくい。

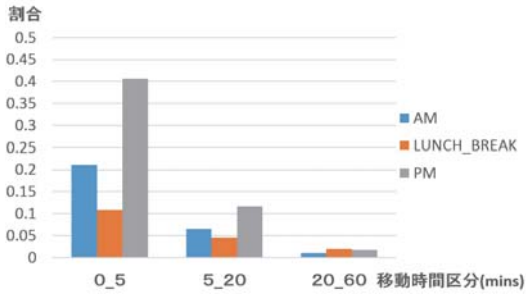


図 7: 全社員の移動時間区分毎の移動回数の割合の平均

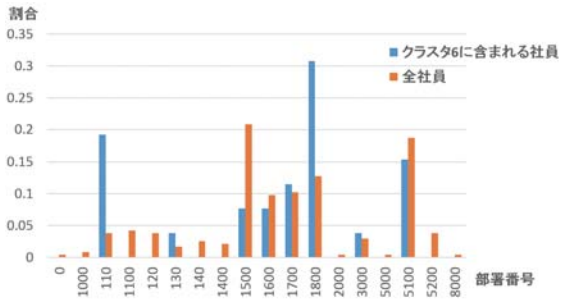


図 8: クラスタ 6 に含まれる社員と全社員の部署分布

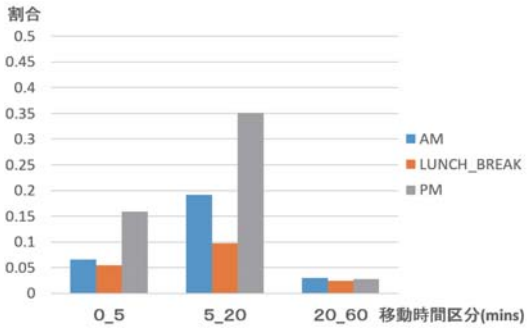


図 9: クラスタ 9 に含まれる社員の移動時間区分毎の移動回数の割合の平均

7. まとめと今後の課題

本研究では、入退室データを用いて社員の移動時間パターンを抽出し、分析をした。入退室データから社員の移動時間に関する事前調査を行った結果、時間帯及び移動時間区分毎の移動回数に社員毎の特徴があることが示唆された。そこで、社員毎の総移動回数に対する時間帯及び移動時間区分毎の割合が似たパターンの社員の集合を抽出するために正規化した移動特徴量を用いて、クラスタリングを行った。クラスタ毎の社員属性の分布と全社員属性の分布に対して適合度検定を行い、有意差がでた結果の考察を行った。クラスタリングでは特徴量を正規化したことで、似た移動時間のパターンを持つ社員の集合を抽出し、クラスタ同士の移動時間パターンがすべて異なる特徴を持っていたことが確認できた。このことより、提案手法を用いて特徴ある似た移動時間パターンを持つ社員の集合を抽出することができたと考えられる。

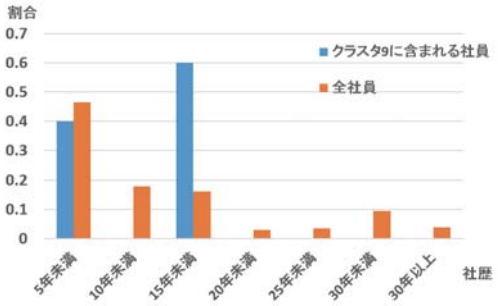


図 10: クラスタ 9 に含まれる社員と全社員の社歴分布

今回社員に対して特徴量を移動時間区分毎の移動回数で表したが、そのほかにも場所に注目したクラスタリングをすることで特徴的な行動の抽出をすることも可能であると考える。その際には、次元数も増えるため、データ期間を増やして実験することや、クラスタリング方法についても再検討する必要があると考える。また今回はクラスタ毎の社員属性について適合度検定を行ったが、標本サンプル数が少ないという欠点もある。そこで、他の検定方法を試すことや、検定対象についても検討し直してみる必要がある。

謝辞

本研究を進めるにあたり、入退室データを提供して頂いた協力企業に感謝の意を表する。

参考文献

[1] 嶋本寛, 北脇徹, 宇野伸宏, 中村俊之, “IC カード利用履歴データを用いた公共交通需要変動分析”, 土木学会論文集 D3(土木計画学),Vol.70,NO.5(土木計画学研究・論文集 第 31 巻) ,pp.605-610,2014.

[2] 鈴木敬, 相薗敏子, “交通 IC カード利用履歴を用いた生活行動属性指標の提案”, 信学技報,IEICE,Technical Report,LOIS2011-84,2012.

[3] 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”, 特集論文, 理論と方法 (Sociological Theory Methods), Vol.26, No.1:pp.83-97, 2011.

[4] 佐藤雅之, 及川和彦, 永嶋規充,“入退室管理システムにおける通行履歴の応用”, 情報処理学会第 77 回全国大会,2G-05

[5] 岡田将吾, 神谷祐樹, 佐藤祐作, 藤田義弘, 山田敬嗣, 新田克己,“センサ環境を利用したオフィスワーカーの行動パターン分析”,The 27th Annual Conference of the Japanese Society for Artificial Intelligence,2013

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

異質性を考慮した適応的な実験デザインとそこでの介入効果推定

柳 博俊[*1] 星野 崇宏[*2] 高畑 圭佑[*1]
Hirotoshi Yanagi Takahiro Hoshino Keisuke Takahata

[*1] 慶應義塾大学大学院経済学研究科・理化学研究所 Graduate School of Economics, Keio University
[*2] 慶應義塾大学経済学部・理化学研究所 Faculty of Economics, Keio University

This paper reports a plan of the experiment on goo-net, which is one of the largest used car sales sites in Japan. The purpose of this experiment is to examine whether assisting a development of customer preference by recommendation is effective for conversion in EC. We suggest two methods of developing customer preference: LDA (Latent Dirichret Allocation) and contextual bandit algorithm. LDA uses various activity logs, for example price and color, to give a recommendation adjusted for each customer. In addition, contextual bandit algorithm aims to help customers clarify their hidden preferences. We use HHI, Herfindahl-Hirschman Index, as context variable. We show that HHI has significant differences in the distribution between consumers who reach CV (preference well developed) and those who do not.

1. はじめに

本稿では顧客行動データを用いたWeb上でのマーケティングについての研究の1ケースとして,大手中古車販売サイトである中古車鑑定グーネットサイト上での介入実験施策について報告する. 介入実験では最終目標であるコンバージョン(グーネットサイトからの中古車見積もり発注 以降CV)率の上昇への貢献を目標とし,中古車鑑定グーネットのトップページに LDA(Latent Dirichret Allocation)を用いた閲覧車種傾向に基づくリコメンドと文脈付きバンディットを用いたリコメンドを2パターン用意して行う.前者のリコメンドではサイト閲覧者ごとに車選びの軸が異なると考えられるため,価格 / 色など異なる要素を用いた複数パターンの LDA ベースのリコメンドを用意し車種を推薦する.一方,後者ではリコメンドをクリックさせることによって, 言語化できていない自分の好みや、それまで知らなかった検索領域が顕在化させることを目的とし,サイト閲覧者の閲覧集中度を表現する HHI (ハーフィンダール・ハーシュマン・インデックス) [高畑ら 2017]などを context として与えた文脈付き多腕バンディットアルゴリズムによってリコメンドを行う.また,文脈付きバンディットアルゴリズムを用いるパターンにおいてはリコメンドのクリックをしてから CV に至るまでの因果関係を仮定し,リコメンド情報が顧客の情報探索を進め,最終的な CV 率を上昇させたかについて効果検証を行う.

2. 実験の枠組み

2.1 介入方法について

今回, 介入として中古車鑑定グーネットのトップページの右上にリコメンド結果を表示する. 介入の対象者は中古車鑑定グーネットへの来訪者のうち数%の ID を無作為抽出し実験対象者とする. 今回は実験対象者をさらに以下のように分割し,リコメンドの配信を行う.

A. LDA ベースのリコメンド対象者 / 比較対象群
B. 文脈付きバンディットアルゴリズムによる推薦の対象者

2.2 文脈付き多腕バンディットアルゴリズムを用いるパターンで仮定する因果関係と測定する効果について

文脈付き多腕バンディットアルゴリズムを用いるパターンでは図1の因果関係を仮定し効果測定を行う. 今回我々が介入できるのは図の A で T(リコメンド)を提示するかどうか / 何の内容を提示するかであり、パフォーマンスは A を変えることによる E の向上により測られる. しかし,元の CV 率が低いことから、恐らく A を最適化してもそう簡単には E は向上しないということが予想される.このとき A→E の効果がないというのは,A→B がない(T があってもそもそもクリックされない)場合と、B→E がない(リコメンドは CV 率の向上にほとんど寄与しない)場合という2つに分けることができる.そのため今回は A→B を向上させるための方策としてクリックを報酬とした文脈付きバンディットアルゴリズムを実装する. そして A→B を最大化した状態で B→E で新しい情報提示による CV 率向上の効果があるかどうかを検証することを目的とする.

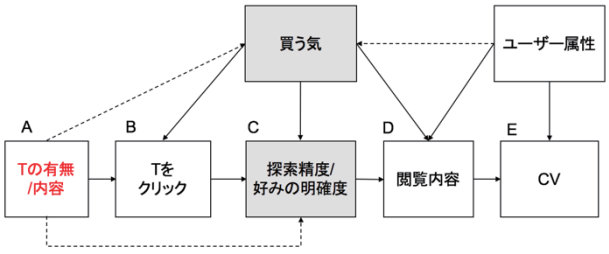


図 1 クリックから CV までの因果関係図

3. データおよび変数について

3.1 LDA を用いたリコメンドに使用するデータ

LDA を用いたリコメンドを行うための学習データとして, Google Analytics より取得した以下のサイト内行動データを用いる：
閲覧した車の
車種 / 商品価格 / 車体タイプ / 車体色 / 走行距離. ：

2017 年 1 月下旬の間に CV したサイト閲覧者 / しなかったサイト閲覧者を 100 人~200 人ピックアップし,それらサ

連絡先: 柳博俊 , h.yanagi-95@keio.jp

イト閲覧者が 2016 年 12 月初め～2017 年 1 月末までに閲覧した商品価格 / 車体タイプ / 車体色 / 走行距離などに注目する.また,閲覧した車種の価格や走行距離は任意のグレード別にカテゴリカル変数に変換する.

これらの変数を用いることによって, サイト閲覧者の車選びで重視している要素に基づいたリコメンドを行えると考えられる.

3.2 文脈付きバンディットアルゴリズムで利用するデータ

文脈付きバンディットアルゴリズムではサイト訪問者に対して情報探索を促進するリコメンドを目指すため, 過去の閲覧履歴やアクセス時間などに加えて閲覧傾向の分散度をcontextとして使用する.具体的には HHI(ハーフィンダール・ハーシュマン・インデックス)を用いて, 各指標における閲覧シェアを変数化する. HHI は経済学において特定産業や消費者の購買商品のシェアなどを表す一次元の指標として用いられる.HHI を用いることでよりシェアの分散度合いが少なく目的がはっきりしているサイト訪問者には閲覧の傾向に沿ったリコメンドを行い, 分散度合いが大きく未だ自分の好みや嗜好が健在化していないサイト訪問者にはより幅広い選択肢を提示することが可能になると考えられる.

4. LDA を用いたリコメンドについて

4.1 トピックの推定

LDA では先述した閲覧した車の履歴を単語として見立てて, それらが発生した背後にあるトピックの分布(サイト訪問者の性質)を推定することを目的とする.

実験に先立ち, 先ほど紹介した使用データのうち閲覧車種履歴を用いたリコメンドエンジンを作成した.

図 2-3 は推定されたトピックの内容の一部である.図 2 のトピックでは丸みを帯びたフォルムの車体を好む性質が抽出されている. また図 3 ではスポーツ/アウトドアタイプの車種が抽出されており,サイト閲覧者の嗜好が抽出されている.

Item	topic_1
GMC エンボイ	0.159952
イスト	0.074902
MS-8	0.047887
1963	0.044714
クライスラー PTクルーザー	0.034886
1971	0.033573
リンカーン タウンカー	0.024432
ギガ	0.022883
ランドクルーザー	0.018450
エルグランド	0.017360

図 2 トピック 例 1

Item	topic_2
レンジローバースポーツ	0.435311
mileage_15_20	0.193752
インプレッサXV	0.061146
イスト	0.039273
1971	0.029500
マークIIブリット	0.023690
ボルボ S60	0.016637
3シリーズ	0.016259
アウディ S1スポーツバック	0.015521
ベリーサ	0.015186

図 3 トピック 例 2

4.2 Hellinger 距離を用いた推定されたサイト閲覧者のトピック分布の類似性に基づくリコメンド

トピックへの所属確率の分布がサイト閲覧者ごとに推定されるため, これを用いてサイト閲覧者間の閲覧傾向の Hellinger 距離を計算する.類似度が図 4 の h_dist のように計算されるためそのサイト閲覧者が類似している他の閲覧者や, CV している閲覧者と似た閲覧パターンを持っているのかを得ることができる.

連絡先: 柳博俊 , h.yanagi-95@keio.jp

userID	topic_1	topic_2	topic_3	topic_4	topic_5	topic_6	cv_total	h_dist
1316139815312362189	0.009925	0.205661	0.093046	0.021096	0.222158	0.448114	0	0.000000
3385589392243463725	0.019077	0.086887	0.047381	0.026001	0.389359	0.431295	0	0.240893
8147347924547906237	0.007723	0.164751	0.043977	0.112763	0.369778	0.301008	0	0.284767
2353873922013083397	0.034562	0.042661	0.031518	0.025789	0.227764	0.637706	0	0.318808
531629305315827399	0.002236	0.190590	0.004812	0.058312	0.403398	0.340652	80	0.319390
3417117703480461953	0.016837	0.197739	0.008268	0.014633	0.085928	0.676595	0	0.320351
433454736669269316	0.007830	0.145565	0.001285	0.004930	0.180884	0.659505	102	0.325380
4356687588076252287	0.021795	0.051978	0.071247	0.007876	0.114649	0.732455	0	0.331929
8279621157647593536	0.005980	0.129724	0.026161	0.118107	0.431104	0.288924	0	0.347598
8451850785033740637	0.002593	0.019448	0.029512	0.045453	0.220849	0.682145	57	0.384529
5569387482556499933	0.028231	0.042885	0.002849	0.010569	0.351875	0.563591	0	0.389859

図 4 Hellinger 距離による類似度上位ユーザの例

5. 今後の展望

こちらの実験計画に従い実験を行う予定である.実験を行う中で課題があぶり出されてくると考えられるが, 現状使用するデータと計算コストの 2 点について問題を感じている.

LDA の学習データの属性や文脈付きバンディットの context として用いる変数については何がより精度を上げてくれるかを複数の実験の中で,よりサイト閲覧者の嗜好を捉えることが可能な変数を逐次探索 / 利用してより精緻なリコメンドを行うように改善していく.

また LDA は学習時に, 文脈付きバンディットは配信時にともに計算コストがかかる手法であるため, 現状の手法のままだと, 一定期間ごとにバッチ処理を行い,サイト閲覧者の訪問前に提示するものを用意するため, 真の意味でリアルタイムな嗜好を反映したリコメンドではない.そのため一度学習したら次回行こうその推定値を用いて迅速に計算できるようにするなどの改善策が考えられる.

参考文献

[新美・星野 15] 新美潤一郎, 星野崇宏: ユーザ別アクセス・パターン情報の多様性を用いた顧客行動の予測とモデリング, 応用統計学, Vol. 44, No. 3 (2015).

[新美・星野 17] 新美潤一郎, 星野崇宏: 顧客行動の多様性変数を利用した購買行動の予測-Deep Learning を応用した実店舗・Web・モバイルの多面的な分析- , 人工知能学会論文誌, Vol. 32, No. 2 (2017).

[高畑ら 17] 高畑圭佑, 星野崇宏, 柳博俊, 渋谷友磯子: 行動経済学的な知見を用いた消費者の情報探索行動の予測とレコメンデーション法の開発, 人工知能学会全国大会論文集 vol.31, 2017

[LI. 10] Lihong Li: A Contextual-Bandit Approach to Personalized News Article Recommendation, Proc. of The 19th Int'l Conf. on World Wide Web, 2010

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

意見の一貫性のなさによる圧力と沈黙を考慮した意見形成モデル

Opinion Formation Model Including Pressure and Silence Caused by Inconsistency

木村 苑子 *1　浅谷 公威 *2　菅原 俊治 *1
Sonoko Kimura　Kimitaka Asatani　Toshiharu Sugawara

*1早稲田大学　*2東京大学
Waseda University　The University of Tokyo

People often belong to multiple communities and accommodate themselves to majority opinion in each community. Thus, they sometimes express different and occasionally inconsistent opinions in the individual communities. When the inconsistency in opinion is uncovered, she/he may be criticized, and then, quit expressing opinions. Recently inconsistency in opinion is easily uncovered because of the growth of communication tools, e.g. SNS. Therefore, we investigate the mechanism of quitting expressing opinion because of the criticism of the inconsistency in opinions in social media. We modeled multiple communities as multiplex networks and investigate how opinions are formed and why users quit expressing opinions due to uncovered inconsistency. For this purpose, we first extended a conventional model whose opinion formation mechanism is based on the bounded confidence model. Then we also considered different opinion formation mechanisms and examined opinion formation in different types of multiplex complex networks, in order to adjust more realistic situations.

1. 序論

人は様々なコミュニティに所属し，それぞれのコミュニティの環境に適応しながら意見形成をしている．周囲への適応の結果，自分の所属するコミュニティ間で異なる意見を表明し，意見に一貫性のなさが生じる場合がある．このような意見の一貫性のなさが発覚すると炎上や二枚舌として批判され，その圧力により意見の表明をやめ沈黙することがある．SNS の発達により，以前に比べ意見の一貫性のなさが他人に発覚しやすくなった．したがって複数のコミュニティでの意見形成について考えるとき，意見の一貫性のなさへの圧力を感じて意見の表明を躊躇したり，意見の表明をやめ沈黙したりするメカニズムを考慮する必要性が生じている．

複数のネットワークでの意見形成についての研究の 1 つに Halu らの選挙のモデル [Halu 13] がある．Halu らは 2 つの対立する政党を 2 つのネットワークで表現し，意見伝播の条件との衝突を解消しながら意見を収束させる様子をシミュレーションした．その結果，政党内での結びつきの強い政党が選挙に勝利しやすいことを示した．

情報科学の観点から意見の一貫性のなさへの圧力を考慮したモデルに浅谷らによるモデル [浅谷 15] がある．浅谷らはマルチプレックスネットワーク上でのネットワーク内での適応とネットワーク間でのコンフリクトをモデル化し，シミュレーション実験を行なった．その結果，現実世界の複数のコミュニティにおける意見形成において，意見の収束，コミュニティ間の意見の違い，サイレントマジョリティなどの現象が発生することを説明した．浅谷らのモデルでは，ネットワーク構造は Erdős-Rényi（ER）モデル [Erdős 59] に基づくランダムグラフであり，意見を表明しているエージェント同士がすべてのネットワークで Bounded Confidence Model（BCM）[Hegselmann 02] に基づき意見形成を行う．しかし，現実のネットワーク構造がランダムグラフではないことに加え，提案されたエージェントの意思決定のプロセスも必ずしも現実に即しているとはいえない．

連絡先: 木村 苑子，早稲田大学，s.kimura@isl.cs.waseda.ac.jp

本研究では，より現実に近い意見形成のプロセスを再現するため，浅谷らによるモデル [浅谷 15] に以下の変更を加えてその挙動を観察した．沈黙しているエージェントも意見を聞くことはできるため，提案モデルでは沈黙しているエージェントも意見形成を行う現象を取り入れた．また，意見形成の多様性を表すために，ネットワークごとに意見形成方法を BCM か多数決かをランダムに選択した．さらに，現実のネットワーク構造を取り入れるために，ネットワーク構造を Connecting Nearest Neighbor（CNN）モデル [Vázquez 03] とし，特に次数の高いエージェントは影響力が強いとしてモデル化した．

2. モデル

エージェントの集合を $A = \{1, \cdots, N_a\}$ とし，本論文ではネットワークはノードをエージェントとするグラフと考える．本モデルは，独立に生成された L 層のネットワーク（L は正の整数）によって構成され，エージェントはこれらすべてのネットワークに所属する．エージェント $i \in A$ は，それぞれのネットワークで意見を持つものとし，i が所属する第 n 層のネットワーク（以下これを $NW(n)$ と表す）における時刻 t の意見を $O_i^n(t)$ と表す．ここで，$0 \leq O_i^n(t) \leq 1$ とし，0 と 1 はそれぞれある意見の対極を意味する．エージェントは各ネットワークごとに異なる意見を持つことができる．また，i がネットワーク $NW(n)$ で時刻 t での意見の表明を $V_i^n(t)$ と表す．この値は 2 値とし，1 のときは表明状態を，0 のときは沈黙を表す．

2.1 BCM に基づくネットワーク内での意見形成

上記のモデルで，全エージェントに対してネットワーク内での意見形成とネットワーク間での圧力と沈黙を行う．意見形成を行うエージェントと圧力と沈黙を行うエージェントはランダムに選ばれる．選ばれたエージェントは，各ネットワーク内で周囲に適応しながら意見形成を行い，意見を変化させる．意見形成のモデルである BCM は 2 つの意見の差異が ε 以内であれば互いの意見をすり合わせ，そうでなければ双方とも意見を変化させないとするものである．ε は BCM での意見のすり合わせ許容度を表し，$0 \leq \varepsilon \leq 1$ である．

意見形成を行うエージェント i, j は意見を表明しており，

意見形成を行うネットワーク $NW(n)$ において隣接している．時刻 t において，$NW(n)$ で i, j が BCM で意見形成を行う場合，i, j の $NW(n)$ での意見 $O_i^n(t)$, $O_j^n(t)$ の変化を，式 (1)，式 (2) で表す．

[$|O_i^n(t) - O_j^n(t)| < \varepsilon$ の場合]

$$\begin{aligned} O_i^n(t+1) &= O_i^n(t) \times (1-a) + O_j^n(t) \times a \\ O_j^n(t+1) &= O_j^n(t) \times (1-a) + O_i^n(t) \times a \end{aligned} \tag{1}$$

[それ以外の場合]

$$\begin{aligned} O_i^n(t+1) &= O_i^n(t) \\ O_j^n(t+1) &= O_j^n(t) \end{aligned} \tag{2}$$

ここで a は BCM での意見のすり合わせ度合いを表し，$0 \leq a \leq 1$ である．

2.2 ネットワーク間での圧力と沈黙

エージェントはネットワーク間で表明している自分の意見に一貫性がなくなった場合，周囲のエージェントから圧力を感じて意見の表明をやめ沈黙するものとする．圧力を受けるエージェント i，圧力を与えるエージェント k はどこかのネットワークで隣接している．k と隣接している複数のネットワークでの i の意見の最大値と最小値の差異が β 以上のとき，i は k から圧力を感じ，k と隣接しているネットワークで意見の表明をやめ沈黙する．ここで β は意見の一貫性のなさへの許容度を表し，$0 \leq \beta \leq 1$ である．なお，このネットワーク間での圧力と沈黙のプロセスはある確率 α で発生する．この α をネットワーク間の接続性とする．時刻 t において，i が k から圧力を受けて沈黙する際の i のネットワーク $NW(n)$ での意見の表明 $V_i^n(t)$ の変化を式 (3)，式 (4) で表す．

[$\max\{O_i^n(t),\ n \in N_{ik}\} - \min\{O_i^n(t),\ n \in N_{ik}\} > \beta$ の場合]

$$V_i^n(t+1) = 0\ (\forall n \in N_{ik}) \tag{3}$$

[それ以外の場合]

$$V_i^n(t+1) = V_i^n(t)\ (\forall n \in N_{ik}) \tag{4}$$

ここで，N_{ik} は i, k が隣接しているネットワークの集合を表す．

3. 提案モデル

3.1 提案モデル 1：意見形成アルゴリズムを変更したモデル

浅谷らによるモデル [浅谷 15] では，意見を表明しているエージェント同士で意見形成をしていた．しかし実際には，沈黙したエージェントも意見を表明している隣接エージェントの意見を聞き，意見を変化させることがあると考えられる．この現象をモデルに取り入れる．

浅谷らによるモデル [浅谷 15] では意見形成を行うエージェント i, j はどちらも意見を表明していたが，提案モデル 1 では i, j のどちらか一方が意見を表明していればよい．沈黙しているエージェント i と意見を表明しているエージェント j で意見形成を行う場合，i は j の意見を観測することができるため意見を j にすり合わせるが，j は i の意見を観測することができないため意見を i に合わせることはない．このために BCM の式 (1)，式 (2) を修正し，時刻 t において第 n 層のネットワーク $NW(n)$ で，沈黙しているエージェント i と意見を表明しているエージェント j が意見形成を行う場合，i, j の $NW(n)$ での意見 $O_i^n(t)$, $O_j^n(t)$ の変化を式 (5)，式 (6) で表すものとする．

[$|O_i^n(t) - O_j^n(t)| < \varepsilon$ の場合]

$$\begin{aligned} O_i^n(t+1) &= O_i^n(t) \times (1-a) + O_j^n(t) \times a \\ O_j^n(t+1) &= O_j^n(t) \end{aligned} \tag{5}$$

[それ以外の場合]

$$\begin{aligned} O_i^n(t+1) &= O_i^n(t) \\ O_j^n(t+1) &= O_j^n(t) \end{aligned} \tag{6}$$

式 (5)，式 (6) で表される，BCM を修正した意見形成方法を modified BCM（mBCM）と呼ぶものとする．なお，意見を表明しているエージェント同士で意見形成を行う場合は通常の BCM の式 (1)，式 (2) に従う．

3.2 提案モデル 2：一部のネットワークで多数決で意見形成を行うモデル

浅谷らによるモデル [浅谷 15] では，すべてのネットワークで意見形成アルゴリズムが BCM と均一であった．しかし実際には，コミュニティごとに意見形成方法が異なる多様性が考えられる．これを表現するために，意見形成アルゴリズムをネットワークごとに変え，通常の BCM で意見形成を行うネットワークの他に多数決で意見形成を行うネットワークを加える．BCM は意見を互いにすり合わせるモデルであり，自然なコミュニティを表すが，多数決は意見を周囲に合わせるモデルであり，強制力の強いコミュニティを表す．

多数決の意見形成では，意見の値によってエージェントを N_s 種類（N_s は正の整数）のスペクトルに分類したものと仮定する．分類されたエージェントの集合を $A_m = \{i \in A \mid m = \lceil O_i \times N_s \rceil\}$ で表す（ただし $O_i = 0$ のとき $i \in A_1$ とする）．また，ここで O_i はエージェント i の持つ意見である．つまり，A_1 に所属するエージェントの意見は 0 に近く，A_{N_s} に近付くにつれ所属するエージェントの意見は大きくなっていくというように，順序的になっている．エージェント i は意見形成を行うネットワーク $NW(n)$ での隣接エージェントが表明している意見を観測し，自分と意見を表明している隣接エージェントを $A_1 \sim A_{N_s}$ に分類する．分類されたエージェントが最も多かった種類を多数派とし，自分の意見を多数派の意見に近付ける．ただし，自分が多数派に所属する場合と，票が割れ所属するエージェントが最も多い種類を決められない，つまり多数派が存在しない場合は意見を変化させない．

時刻 t において第 n 層のネットワーク $NW(n)$ で i が多数決で意見形成を行う場合，i の $NW(n)$ での意見 $O_i^n(t)$ の変化を式 (7)，式 (8) で表す．

[A_m が多数派で $i \notin A_m$ のとき]

$$O_i^n(t+1) = O_i^n(t) \times (1 - a_{md}) + \left(\frac{m-1}{N_s} + \frac{1}{2N_s}\right) \times a_{md} \tag{7}$$

[A_m が多数派で $i \in A_m$ のとき，多数派が存在しないとき]

$$O_i^n(t+1) = O_i^n(t) \tag{8}$$

ここで，a_{md}（$0 \leq a_{md} \leq 1$）は多数決での意見のすり合わせ度合いを表す定数である．

3.3 提案モデル 3：影響力の強いエージェントが存在するモデル

浅谷らによるモデル [浅谷 15] では各ネットワークの構造にランダムグラフを用いており，各エージェントの次数は正規分布で均一的であった．しかし実際には影響力の強いエージェントが部分的に存在する．これをネットワーク構造を CNN モデルに拡張することで表現した．CNN モデルではエージェントの次数はべき分布に従う．高い次数のエージェントは影響力が強いと考え，逆に他のエージェントからの影響を受けにくいとした．つまり，影響力の強いエージェントは意見をあまり変化させず，また周囲からの圧力を感じづらい．これを表現するために，影響力の強いエージェントについては，式 (1)，式 (2) における a の値を小さく，式 (3)，式 (4) における β の値を大きく設定した．なお，提案モデル 3 では意見形成方法として通常の BCM を用いた．

4. 実験

4.1 実験 1

4.1.1 実験環境

実験 1 では，沈黙者の意見変化を想定した状況での意見形成を調査する．そのために，沈黙したエージェントは意見形成を行わない既存モデル [浅谷 15] と，沈黙したエージェントも意見形成を行う提案モデル 1 を比較した．実験 1 で用いたパラメータの値を表 1 に示す．実験 1 では，すべてのネットワーク構造を ER モデルに基づくランダムグラフとした．また，初期状態において各エージェントは各ネットワークで同じ意見を表明しており，意見に一貫性がある状態とした．各エージェントの意見はランダムに決定される．

表 1: 実験 1 におけるパラメータの値

パラメータ		値
BCM Conformity Bias	ε	0.4
BCM すり合わせ係数	a	0.5
ネットワークの数	L	8
エージェントの数	N_a	100
各ネットワーク間の接続性	α	Variable $(0.0 \leq \alpha \leq 1.0)$
一貫性のなさへの許容度	β	Variable $(0.3, 0.5)$

4.1.2 実験結果と考察

一貫性のなさへの許容度 β が 0.3，0.5 の場合について，各ネットワーク間の接続性 α を変化させて実験を行なった．ネットワーク全体における意見の標準偏差を図 1 に示す．

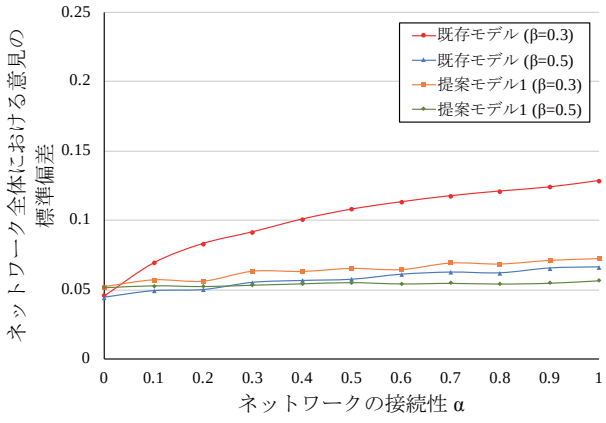


図 1: 実験 1 でのネットワーク全体における意見の標準偏差

図 1 より，既存モデルより提案モデル 1 の方がネットワーク全体の意見の標準偏差が小さく，意見の多様性が保たれなかった．これは，提案モデル 1 では沈黙したエージェントも意見形成を行い，発言しているエージェントに意見をすり寄せるので，一貫性のなさへの許容度 β が小さく沈黙しやすい場合でも意見形成が行われるためである．また，提案モデル 1 でのネットワーク全体における意見の標準偏差は，既存モデルに比べて β の違いによる差異が小さく，$\beta = 0.3$ の場合が $\beta = 0.5$ の場合に近付く結果となったが，これも同様の理由からである．

4.2 実験 2

4.2.1 実験環境

実験 2 では，ネットワークごとに異なる意見形成方法を用いる状況での意見形成を調査する．そのために，すべてのネットワークの意見形成方法が BCM である既存モデル [浅谷 15] と，ネットワークごとに BCM と多数決という異なる意見形成方法を用いる提案モデル 2 を比較した．実験 2 で用いたパラメータのうち，実験 1 で用いたパラメータとの差分の値を表 2 に示す．実験 2 ではすべてのネットワーク構造を ER モデルに基づくランダムグラフとした．また，初期状態において各エージェントは各ネットワークで同じ意見を表明しており，意見に一貫性がある状態とした．各エージェントの意見はランダムに決定される．提案モデル 2 において，あるネットワークの意見形成方法が BCM である確率と多数決である確率はともに 0.5 とし，多数決の際には意見を 4 種類に分類した．

表 2: 実験 2 におけるパラメータの値

パラメータ		値
意見形成方法が BCM の確率	P_{bcm}	0.5
意見形成方法が多数決の確率	P_{md}	0.5
多数決での意見の種類の数	N_s	4
多数決でのすり合わせ係数	a_{md}	0.5

4.2.2 実験結果と考察

一貫性のなさへの許容度 β が 0.3 または 0.5 の場合について，ネットワーク間の接続性 α を変化させて実験を行なった．ネットワーク全体における全エージェントの意見の標準偏差を図 2 に示す．

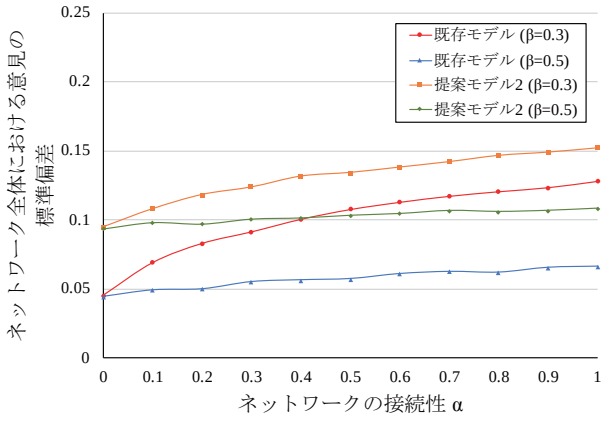


図 2: 実験 2 でのネットワーク全体における意見の標準偏差

図 2 から，β が同じ場合同士で比較すると，既存モデルより提案モデル 2 の方がネットワーク全体における意見の標準偏差が大きく，意見の多様性が保たれた．既存モデルではすべてのネットワークで BCM で意見形成を行うが，提案モデル 2 では一部のネットワークでは BCM で，一部のネットワークで

は多数決で意見形成を行う．BCM では意見形成後の意見は意見形成を行う 2 つの意見の間の値になるため，BCM での意見形成を繰り返すとエージェントの意見は全体の意見の平均値に近付いていくと考えられる．一方，多数決では隣接エージェントの多数派意見に自分の意見を近付けるが，エージェントごとに隣接エージェントが異なるため，エージェントごとに多数派意見も異なる．したがって，すべてのエージェントが同じ意見に近付いていくわけではない．この違いのために，BCM で意見形成を行う既存モデルより，BCM と多数決の両方で意見形成を行う提案モデル 2 の方が全体の意見の標準偏差が大きくなったと考えられる．

4.3 実験 3

4.3.1 実験環境

実験 3 では，影響力の強いエージェントが存在する状況での意見形成を調査する．そのために，ネットワーク構造をランダムグラフとした既存モデル [浅谷 15] と，ネットワーク構造を CNN モデルとした提案モデル 3 を比較した．実験 3 で用いたパラメータのうち，実験 1 で用いたパラメータとの差分の値を表 3 に示す．初期状態において各エージェントは各ネットワークで同じ意見を表明しており，意見に一貫性がある状態とした．各エージェントの意見はランダムに決定される．また，提案モデル 3 において，次数が高い順に 10 個のエージェントを影響力の強いエージェントとした．BCM での意見のすり合わせ度合い α は通常のエージェントでは 0.5，影響力の強いエージェントでは 0.1 とした．また意見の一貫性のなさへの許容度 β は通常のエージェントでは 0.3 または 0.5，影響力の強いエージェントでは 0.6 または 0.8 と 0.3 だけ大きくした．

表 3: 実験 3 におけるパラメータの値

パラメータ		値
影響力の強いエージェントの数	N_{as}	0 or 10

4.3.2 実験結果と考察

通常のエージェントの一貫性のなさへの許容度 β が 0.3 または 0.5 の場合について，ネットワーク間の接続性 α を変化させて実験を行なった．ネットワーク全体における全エージェントの意見の標準偏差を図 3 に示す．

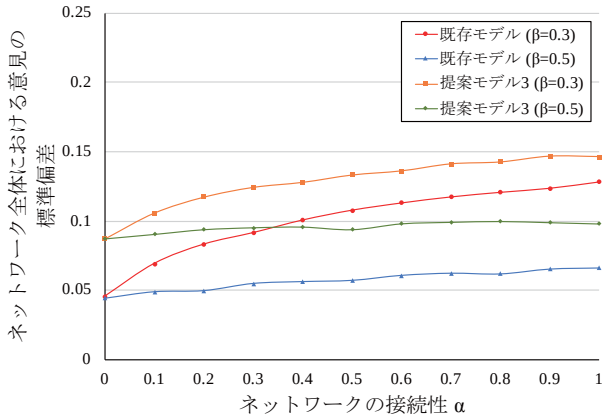


図 3: 実験 3 でのネットワーク全体における意見の標準偏差

図 3 より，β が同じである場合同士で比較すると，既存モデルより提案モデル 3 の方がネットワーク全体における意見の標準偏差が大きく，意見の多様性が保たれた．提案モデル 3 ではネットワーク構造が CNN モデルであるため，影響力が強く意見のすり合わせ度合いは小さいが許容度が大きいエージェントがハブとして存在する．このとき，隣接エージェントの影響力の弱いエージェントが多く，そのようなエージェントは意見形成を行う回数が少ないためであると考えられる．

5. 結論

本研究では，沈黙したエージェントも意見形成をするモデル，意見形成方法をネットワークごとに BCM か多数決かランダムに決定するモデル，ネットワーク構造が CNN モデルであり影響力の強いエージェントが存在するモデルを提案し，各モデルでマルチプレックスネットワーク上での意見形成の様子をシミュレーションした．その結果，意見形成方法の違いやネットワーク構造の違いが意見形成の結果に影響を及ぼすことがわかった．沈黙したエージェントも意見形成をする場合，沈黙するエージェントが多くなるときに意見の多様性が失われ意見が均一的になった．また多数決で意見形成を行うネットワークが存在する場合とネットワーク構造が CNN モデルである場合は，意見の多様性が保たれやすくなった．

本研究では既存のモデルに 3 種類の変更を加えたが，本モデルにはさらなる改良の余地がある．例えば沈黙したエージェントも意見形成をするモデルでは，意見に一貫性がなくなり圧力を受け沈黙したエージェントが，自分の意見の変化により意見の一貫性を取り戻し再び意見を表明する現象が考えられる．また，ネットワーク構造が CNN モデルである場合に，本研究では影響力の強いエージェントとそうでないエージェントを分類しパラメータを一律に変化させたが，エージェントの次数に応じた連続的な影響力を考え，影響力に応じてパラメータを連続的に変化させることが考えられる．本研究ではこれらの現象を考慮していないので，これらの現象を取り入れることが今後の課題である．

参考文献

[Erdős 59] Erdős, P. and Rényi, A.: On Random Graphs I., *Publicationes Mathematicae (Debrecen)*, Vol. 6, pp. 290–297 (1959)

[Halu 13] Halu, A., Zhao, K., Baronchelli, A., and Bianconi, G.: Connect and win: The role of social networks in political elections, *Europhysics Letters*, Vol. 102, No. 1, p. 16002 (2013)

[Hegselmann 02] Hegselmann, R. and Krause, U.: Opinion Dynamics and Bounded Confidence Models, Analysis and Simulation, *Journal of Artificial Societies and Social Simulation*, Vol. 5, No. 3, pp. 1–2 (2002)

[Vázquez 03] Vázquez, A.: Growing network with local rules: Preferential attachment, clustering hierarchy, and degree correlations, *Phys. Rev. E*, Vol. 67, p. 056104 (2003)

[浅谷 15] 浅谷 公威, 鳥海 不二夫, 大橋 弘忠: コミュニティ間における多面性と意見形成, 人工知能学会論文誌, Vol. 30, No. 5, pp. 658–666 (2015)

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

世代による政治ニュース記事の閲覧傾向の違いの分析

Analysis of differences in viewing behavior of politics news by age

関 喜史 *1
Yoshifumi Seki

*1株式会社 Gunosy
Gunosy Inc.

In recent years, youth low interest about political interest has become a problem in Japan. This problem has has been discussed by questionnaires, but surveys based on actual behavior are rarely carried. In this research, using the user action logs in news curation service, analyze how the viewing trend of news articles on politics varies depending on ages.

1. はじめに

本研究では，スマートフォンアプリケーションにおける政治ニュースの閲覧傾向について，年代という観点からその違いの分析を行う．近年若年層の投票率の低下が社会問題化している [総務省]．世代間で政治への関心がどのように異なるのかという点については，アンケートを用いた研究や調査はあるが，実際の行動に基づく研究は多くない [鈴木 12]．ニュースの閲覧傾向が世代間で異なることは知られており，閲覧傾向から関心の違いについて重要な示唆が得られる可能性がある [LINE 16]．

本研究ではスマートフォンアプリケーションのグノシーにおける政治カテゴリにおけるニュース記事の閲覧傾向を世代別に比較することにより，政治領域のニュース消費における世代の違いが与える影響について考察する．

2. データセット

本研究では株式会社 Gunosy が提供する情報キュレーションサービスであるグノシー *1 におけるユーザ行動データを用いる．今回は政治的関心が社会的に高まっていると考えられる第 48 回衆議院議員選挙の公示期間である 2017 年 1 0月 10 日から 10 月 22 日までのデータを用いる．

対象となるニュース記事はグノシーにおいて政治カテゴリに割り当てられたニュース記事とする．カテゴリはグノシーにおいて分類されたものであり，その分類は人手によらないものもあるため，政治カテゴリに含まれるニュース記事が政治に関するものではないことも，政治に関するニュースが政治カテゴリ以外のカテゴリに割り当てられるこもあるが，その影響は軽微であると考え，本研究ではそれを考慮しない．

そして本研究では世代別に閲覧行動を分析するため，ユーザの年齢データを用いる．グノシーでは利用時にニュース記事の配信などに利用するために，利用開始時を中心にユーザに対して性別と年代を登録するように促しており，ユーザは自分の年代を２０歳未満 20 24 歳, 25 29 歳, 30 代, 40 代, 50 代以上から選択する．さらにこの登録情報を教師データにし，ユーザの行動履歴を素性にすることによって登録していないユーザの年代を機械学習によって推定している．これによりグノシー内での行動履歴が一定以上存在するユーザに対しては年代情報が存在する．もちろん推定した情報は 100%ではなく，正確ではないこともあるが，本研究ではその影響は考慮しない．本研究では 20 代以下, 30 代, 40 代以上の３つに年代をわけで比較を行うことにする．

連絡先: 関 喜史，株式会社 Gunosy，〒 106-6125 東京都港区六本木 6-10-1 六本木ヒルズ森タワー 25 階，03-6455-4562，yoshifumi.seki@gunosy.com

*1 http://www.gunosy.com

3. 世代別の政治ニュース記事の閲覧行動

3.1 世代別の閲覧数ランキング

まず世代別に政治ニュース記事の閲覧のランキングを作成し，閲覧数が多いニュース記事を比較する．

表 1: 20 代以下の政治ニュース記事閲覧数ランキング

閲覧数順位	ニュース記事の概要
1	話題になった女性議員の選挙運動について
2	議員による不倫問題について
3	有名政治家の若いころの写真と現在の比較
4	若者が作った選挙情報サイトについて
5	開票速報
6	選挙結果の速報
7	話題になった議員の政治功績の紹介
8	選挙後の政局についての推測
9	首相の街頭演説での政局を野球に例えた発言
10	若者政治団体の元代表のインタビュー

表 2: 30 代の政治ニュース記事閲覧数ランキング

閲覧数順位	ニュース記事の概要
1	議員による不倫問題について
2	話題になった女性議員の選挙運動について
3	有名政治家の若いころの写真と現在の比較
4	開票速報
5	選挙結果の速報
6	話題になった議員の政治功績の紹介
7	選挙後の政局についての推測
8	立憲民主党の選挙結果の予測
9	自民党議員の応援演説での行動について
10	若者が作った選挙情報サイトについて

表 3: 40 代以上の政治ニュース記事閲覧数ランキング

閲覧数順位	ニュース記事の概要
1	議員による不倫問題について
2	話題になった女性議員の選挙運動について
3	選挙後の政局についての推測
4	開票速報
5	立憲民主党の選挙結果の予測
6	自民党議員の応援演説での行動について
7	街頭演説における立憲民主党議員の他の野党を批判する発言について
8	選挙結果の速報
9	野党議員の選挙演説での虚偽の発言とその謝罪
10	元希望の党所属議員による希望の党批判

表 1, 2, 3 に世代別の政治ニュース記事閲覧数ランキングの上位 10 件を示す．すべての世代でランキングの 1 位と 2 位はスキャンダルで騒がれた議員に関するニュース記事となった．政治家のスキャンダルは世代を問わず注目される問題であるといえる．また全体の傾向として，20 代と 30 代の傾向はある程度類似しており，30 代と 40 代の傾向も類似しているが，20 代と 40 代では異なる点が多く，年齢の近さと興味関心の近さが関連していることが示唆される．

20 代以下の閲覧数ランキングの特徴として，若者の政治運動に関するニュース記事が 2 件含まれている．30 代では 20 代で 4 位のニュース記事が 10 位,40 代以上では 10 位以内に含まれていない．このことから同世代の活動に注目していることが示唆される．一方 40 代以上では選挙戦における議員の発言を取り上げるニュース記事が多くランキングに含まれている．そして政局に関するニュース記事がほとんどであり，20 代以下,30 代でランキングに含まれていた政策に関するニュース記事が含まれていない．そして 30 代のランキングでは政局に関するニュース記事が比較的含まれているが，20 代以下のランキングにはほとんど含まれていない．このことから年齢が高いほど政局に関する興味関心が高く，年齢が低いほど政局に関する興味関心が低いこと考えることができる．

3.2 閲覧数ランキングの差分の比較

前節では閲覧数ランキング上位 10 件の比較を行った．本節では閲覧数ランキングの違いが大きいニュース記事を示し，その背景を考察する．閲覧数ランキングから年齢の近さと興味関心の近さに関係があることが示唆されたため，より大きな違いを確認するために，20 代以下と 40 代以上で比較を行う．比較は閲覧数ランキングにおける順位の差分を用いる．

まず 20 代以下が 40 代以上より多く閲覧しているニュース記事を表 4 に示す．最も順位の差分が大きかったのは若者の投票率を向上させるための試みを紹介したニュース記事であり，前節でも述べたように自分たちの世代を対象にしたニュース記事への関心が高いことがわかる．また全体として各党の政策に関するニュース記事が多く，前節同様に政局より政策に関心があるといえる．加えてインターネット上での選挙運動についても関心が高い．

次に 40 代以上が 20 代以下より多く閲覧しているニュース記事を表 5 に示す．表 4 と比較して政局に関するニュース記事が多く，40 代以上は 20 代以下に比べて政策より政局への関心が高いことがわかる．また不倫や，森友・加計問題などスキャンダルに関する関心も 20 代以下に比べて高いといえる．

表 4: 20 代以下が 40 代以上に比べてより閲覧しているニュース記事

差分順位	ニュース記事の概要
1	若者の投票率をあげようとする試み
2	各党の子育て支援政策について
3	首相が不在者投票を行ったこと
4	各党の政策を面白く紹介した記事
5	各党党首のソーシャルメディア活用について
6	視覚障害者向けの選挙サイトについて
7	各党のキャッチコピーの比較
8	各党の政策の違いについて
9	政党の公約について
10	不在者投票の概要

表 5: 40 代以上が 20 代以下に比べてより閲覧しているニュース記事

閲覧数順位	ニュース記事の概要
1	不倫問題で注目された議員の選挙戦
2	民進党と希望の党の合流報道に関するコメント
3	開票速報
4	森友・加計問題に関する野党党首のコメント
5	地方都市首長が希望の党の支援を撤回
6	立憲民主党党首の人柄について
7	選挙結果の予測
8	野党大連立構想について野党党首のコメント
9	希望の党入りした元民進党議員の選挙戦について
10	注目選挙区の情勢について

このように順位の差分を比較することで，前節において閲覧数ランキングの比較によって示唆された点がよりはっきりと示された．

4. まとめ

本研究ではグノシーにおける世代別の政治に関するニュース記事の閲覧傾向を比較した．その結果若い世代は政策に，中高年は政局に関心があるといった傾向が示唆された．今回の分析はあくまでグノシー内の行動であり，一般化できるものではない．しかし本研究で得られた示唆は実社会を部分的には反映しているはずであり，世代間の政治への関心の違いを分析する上で重要なデータであるといえる．

今後はジャーナリズムの専門家も交え，結果をより深く正しく解釈していくことを目指すとともに，ソーシャルメディアの分析や，アンケート調査などと比較することで，閲覧行動から得られる示唆がどのような特徴を持っているのかを明らかにしていきたい．

参考文献

[LINE 16] LINE 株式会社， 世代間のニュースサービス利用に関する意識調査，https://linecorp.com/ja/pr/news/ja/2016/1267， 2016.

[総務省] 総務省, 国政選挙の年代別投票率の推移について, http://www.soumu.go.jp/senkyo/senkyo_s/news/sonota/nendaibetu

[鈴木 12] 鈴木万希枝, 若年層のニュース消費に関する研究: 情報源接触パタンおよびニュース情報への選択的接触の検討, 三田哲学会, 2012.

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

グローバル・サプライチェーンのネットワーク構造に基づく紛争鉱物規制

Conflict mineral regulations based on network structure of global supply chain

水野　貴之[*1]
Takayuki Mizuno

大西　立顕[*2]
Takaaki Ohnishi

渡辺　努[*3]
Tsutomu Watanabe

[*1] 国立情報学研究所, 総合研究大学院大学複合科学研究科
National Institute of Informatics, School of Advanced Sciences, SOKENDAI (The Graduate University for Advanced Studies)

[*2] 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

[*3] 東京大学大学院経済学研究科
Graduate School of Economics, The University of Tokyo

We investigate the network structure of global supply chain using a dataset that contains information on business partners for about 500,000 firms worldwide. First, we show that this network has scale-free topology and that the shortest path length is around six. Second, we show through community structure analysis that the firms comprise a community with those firms that belong to the same industry but different home countries, indicating the globalization of firms' production activities. Finally, we discuss what such production globalization implies for the proliferation of conflict minerals (i.e., minerals extracted from conflict zones and sold to firms in other countries to perpetuate fighting) through global supply chain. We show that several bridge firms between some specific industries and countries play an important role in the global proliferation of conflict minerals.

1. はじめに

環境への負荷増大や貧困，難民問題，人種差別，テロ，地域紛争などへの懸念が地球規模で拡大するなか，グローバルに事業を展開する企業が果たすべき責任とはなにか．「世界を良い方向に変えていく」ための1つの手段として，世界的な視野に立ち，自社とそのサプライチェーン全体の透明性を高め、環境と人権問題に責任を果たすことが求められている．たとえば，英国政府は，大企業に対してサプライチェーンの上流に「労働者の人権を無視した無責任な企業」が含まれていないことを，求めている[1]．また，米国政府は，武装勢力の資金源である紛争地で採掘されたレアメタル（紛争鉱物）を製品に使わないことを求めている[2]．透明性を高めることは，製品の高品質を維持し，長期的な事業効率を改善して，持続可能なサプライチェーンの構築につながる．

グローバル・サプライチェーンに対して複雑ネットワーク解析をおこなうと，世界の 90%以上の企業が1つのグローバル・サプライチェーン（最大連結成分）に属しており，しかも，それらの企業から任意に選んだ 2 社は，わずか平均 6 取引先を経由すれば繋がることが分かる[3,4]．このような特徴は，スモールワールド性と言われている．スモールワールド性があるために，もし，各企業がグローバル・サプライチェーン上の上流に向かって，無責任な企業が含まれていないか，調査をおこなうと，すぐに全数調査（つまり，全世界の企業を調べること）になってしまい，調査が破綻してしまう．そこで，我々は，グローバル・サプライチェーンのネットワーク構造を利用した，無責任な企業対策・紛争鉱物規制を提案する．

2. データ

我々は，S&P Capital IQ が提供する約 50 万社のグローバル・サプライチェーンのデータセットと，Dow Jones が様々な報道資料からかき集めた約 5 万社のネガティブな報道がなされた無責任な企業（例えば，奴隷労働や環境破壊，紛争鉱物の仕入れ等がマスメディアによって指摘された企業）のリストを用いる．我々は，この2つのデータセットを，企業名や住所情報等を用いて結合した．

3. ネットワーク構造

企業はグローバルに繋がっている．図1は，企業間の取引関係を取引数の多い上位 1000 社について描いた図である．多くの米国企業，欧州企業，日本企業が密に繋がっていることが分かる．また，アフリカの企業であっても，欧州企業などを通じて，簡単に世界中の企業と繋がってしまうことが分かる．任意に選んだ 2 社が，いくつの取引先を仲介して接続されるのかを調べた最短経路長（SPL）の確率密度分布が図2である．任意に選んだ 2 社は，わずか平均 6 取引先を経由すれば繋がることが分かる．つまり，無責任な企業がサプライチェーンの上流にないか，サプライチェーンをさかのぼって探すと，6社程度上流にさかのぼっただけで全社になってしまい，とても調査しきれない．

なぜ，6 社という僅かな取引先の仲介で繋がってしまうのか．その理由の1つは，コミュニティ構造である．グローバル・サプライチェーンにおける，企業をノード，取引関係をリンクとして，サ

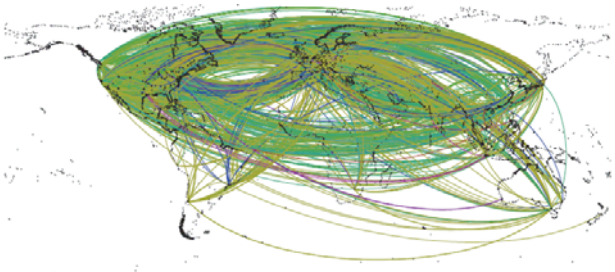


図1　グローバル・サプライチェーン

連絡先：水野貴之，国立情報学研究所，東京都千代田区一ツ橋2－1－2．mizuno[at]nii.ac.jp

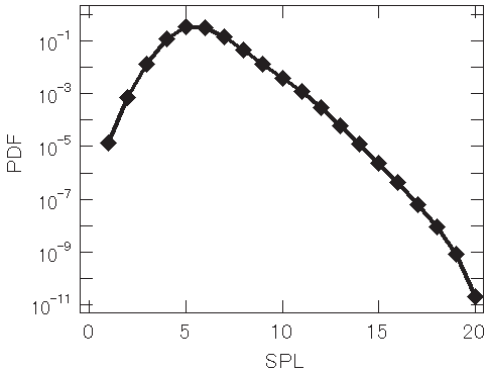


図2 企業間の最短経路長(SPL)の確率密度分布

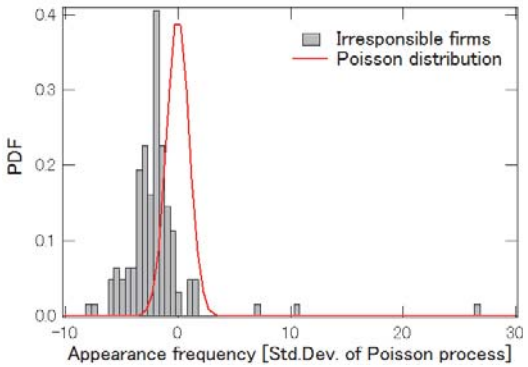


図3 コミュニティに含まれる無責任な企業数の確率密度分布

プライチェーンにおける任意の部分のリンク密度を調べると，密になている部分と疎になっている部分が見つかる．つまり，グローバル・サプライチェーンには，複数の企業コミュニティが存在しており，同じコミュニティに属する企業間は密に繋がっている．そして，少数の企業がコミュニティ間を橋渡しする構造になっている．つまり，どの企業でも橋渡しをする企業(我々は**ブリッジ企業**と呼ぶ)を通じて，世界中の企業と繋がっている．

このようなコミュニティは，ネットワークのコミュニティ検出と呼ばれるアルゴリズムで抽出することが可能であり，本論文では，代表的なアルゴリズムである Louvain 法[5]と MapEquation[6]で検出した．コミュニティは階層構造を持っており，上層のほとんどのコミュニティは，国をまたいで，各製品を生産する工程での原材料から加工，販売をおこなう企業が，ひとまとまりになっていた(つまり，大きな枠での産業を表している)．それらの上層のコミュニティには，国や地域を表す下層のコミュニティが，それぞれ複数所属している．

4. 無責任な企業が集中するコミュニティ

Dow Jones から提供された約 5 万社の無責任な企業が，特定のコミュニティに固まって存在することを示す．もし，この 5 万社がグローバル・サプライチェーン上にランダムに存在するのであれば，コミュニティ内に含まれる無責任な企業の数はポアソン分布に従う．図3は，平均値0，標準偏差1に正規化されたポアソン分布と，同じく正規化されたコミュニティに含まれる無責任な企業数の確率密度分布である．この図では，コミュニティ検出に Louvain 法を用いたが，MapEquation でも結果に大差はない．無責任な企業の数が，ポアソン分布から明らかに乖離しており，大多数のコミュニティが無責任な企業は殆ど含んでおらず，ポアソン分布での+2 σ の値を越えるような，ごく少数のコミュニティに無責任な企業が集中していることが分かる[7].

5. 無責任な企業対策，紛争鉱物規制

4 章から，特定のコミュニティに無責任な企業が集中していることが分かった．つまり，そのコミュニティと，日本企業が属するコミュニティを繋ぐブリッジ企業を検出し，そのブリッジ企業で無責任な企業が生産した中間財が紛れ込んでいないか調査すれば，3 章で示したような全社調査をする必要はなく，僅かなブリッジ企業を調べるだけでよいので，大変，低コストで効率的である．また，調査対象をブリッジ企業のみに絞れるため，ブリッジ企業の川下にある企業のみ，ブリッジ企業から上流の企業の環境改善に責任を持てばよいので，どの企業に責任があるか責任の所在をハッキリさせることができる．

無責任な企業の1カテゴリーとして，紛争鉱物を扱う企業があるが，それらの企業と G8 の企業を結びつけるブリッジ企業は，本論文の 50 万社の内，わずか 14 社である[7]．この 50 万社は，全ての上場企業を含んでおり，世界の大部分の取引量をカバーできているが，もちろん，このカバーできていない取引関係もある．従って，この 14 社のみで規制をおこなうのではなく，この 14 社と同じ属性を持つ企業で規制をおこなうほうがよい．紛争鉱物の場合のブリッジ企業は，スズ・タンタル・タングステン・金の精錬所や鉱物関係の商社であり，これらの企業で規制をおこなえば，紛争鉱物は除去できる．この結果は，2021 年に EU で導入しようとしている紛争鉱物規制の規制対象とほぼ同じである．

紛争鉱物に関する対応は 2010 年頃からおこなわれており，11 年をかけて OECD が中心となり，経験的に効率的な規制対象企業を，やっとの事で特定してきた．しかし，紛争鉱物を扱う企業という1カテゴリー以外の無責任な企業が生産する中間財に対する対策は，まだまだ未整備の状況である．本分析手法を使えば，違法伐採であれば特定の木材加工業，奴隷労働で作られた糸等はアパレルの中間財の卸売業など，簡単に規制対象の業種を特定することができる．本研究は，グローバル・サプライチェーンの透明性を高めることに貢献できる．ひいては，製品の高品質を維持し，長期的な事業効率を改善して，持続可能なサプライチェーンの構築につながることが期待できる．

参考文献

[1] Modern Slavery Act 2015, UK, Mar. 2015.

[2] Dodd–Frank Wall Street Reform and Consumer Protection Act, USA, Jul. 2010.

[3] Takayuki Mizuno, Takaaki Ohnishi, Tsutomu Watanabe. The Structure of Global Inter-firm Networks. Social Informatics Lecture Notes in Computer Science 8852, pp. 334-338, 2015.

[4] Takayuki Mizuno, Takaaki Ohnishi and Tsutomu Watanabe. Structure of global buyer-supplier networks and its implications for conflict minerals regulations. EPJ Data Science 5, 2 (15 pages), 2016.

[5] Vincent D Blondel1, Jean-Loup Guillaume, Renaud Lambiotte and Etienne Lefebvre. Fast unfolding of communities in large networks. Journal of Statistical Mechanics, 2008, P10008, 2008.

[6] Martin Rosvall and Carl T. Bergstrom. Multilevel compression of random walks on networks reveals hierarchical organization in large integrated systems. PLoS ONE 6, e18209, 2011.

[7] Takayuki Mizuno, Takaaki Ohnishi, Tsutomu Watanabe. Exploiting global buyer-supplier networks to improve supply chain due diligence. Submitted to EPJ Data Science.

[3Z1] [General Session] 13. AI Application

座長:日和 悟（同志社大学）

Thu. Jun 7, 2018 1:50 PM - 3:10 PM Room Z (3F Matsu Take)

[3Z1-01] Linear independent non-negative matrix factorization for automatic decomposition of experimental spectra

○Nobuaki Kikkawa[1], Akitoshi Suzumura[1], Shin Tajima[1], Shunsuke Yamakawa[1], Ryoji Asahi[1] （1. Toyota Central R&D Labs., Inc.）

1:50 PM - 2:10 PM

[3Z1-02] A universal 3D voxel descriptor for solid-state materials informatics with convolutional neural networks

○Seiji Kajita[1], Nobuko Ohba[1], Ryoji Asahi[1] （1. Toyota Central R&D Labs. Inc.）

2:10 PM - 2:30 PM

[3Z1-03] Visualization of SEM/EBSD Features of Ionic Conductivity with Convolutional Neural Networks

○Ruho Kondo[1], Shunsuke Yamakawa[1], Yumi Masuoka[1], Shin Tajima[1], Ryoji Asahi[1] （1. Toyota Central R&D Labs., Inc.）

2:30 PM - 2:50 PM

[3Z1-04] Infra Machine Learning for Predictive Maintenance via Classification Models

○Takato Yasuno[1] （1. Yachiyo engineering Co., Ltd.）

2:50 PM - 3:10 PM

©The Japanese Society for Artificial Intelligence

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

実験スペクトル自動分解のための線形独立非負行列因子分解法の提案

Linear independent non-negative matrix factorization for automatic decomposition of experimental spectra

吉川信明 Nobuaki Kikkawa　鈴村彰敏 Akitoshi Suzumura　田島伸 Shin Tajima　山川俊輔 Shunsuke Yamakawa　旭良司 Ryoji Asahi

株式会社 豊田中央研究所
Toyota Central R&D Labs., Inc.

We propose a new algorithm to decompose a set of arbitrary complex spectra into independent basis spectra. Based on the non-negative matrix factorization (NMF) algorithm we introduce a regulation term to a cost function in order to ensure the linear independency between basis spectra. We apply it to decompose a set of complex X-ray diffraction (XRD) spectra, which is typically obtained from high-throughput materials libraries. Each of the decomposed spectra nicely matches with one of the single phase spectra in an available XRD database. Alternatively, the method facilitates to find new phases when the decomposed spectra are not found in the database. These features are particularly useful for materials informatics where big spectrum data obtained from experiment are to be handled.

1. はじめに

近年の情報科学の発展を受け材料科学の分野においても情報技術の活用が急務となっている。このような材料科学と情報科学の境界領域は materials informatics（MI）と呼ばれ、米国 Materials Genome Initiative[1] をはじめ、各国のプロジェクトにより研究が進められている。例えば、コンビナトリアル合成と高速（high-throughput, HT）測定を組み合わせることで大量の実験データを取得し、そのデータを情報科学の知見に基づき利用することで材料開発を効率化しようという試みが進められている[2]。我々は、薄膜合成技術と放射光を用いた HT-XRD（X-ray diffraction）測定技術を組み合わせることで組成の異なる多数のサンプルを一度に合成し、各サンプルの XRD スペクトルを得ることに成功しており、これらのデータを材料開発に活かす技術の構築が望まれている。

XRD スペクトルはサンプル内の結晶相ごとに特有のピークパターン（単相スペクトル）を持ち、その強度がサンプル中の結晶相の割合に対応する。単相スペクトル（から同定された結晶相）とその相の割合は物理的に良い記述子となることから、これを求めることが XRD 解析の目的となる。特に HT-XRD 測定では、

① 各サンプルから得られたスペクトルは、サンプル数に比べ少数の単相スペクトルの線形結合で近似できる。
② 測定結果、単相スペクトル、線形結合係数のいずれも非負である。

という性質を持つ場合が多く、非負行列因子分解（Non-negative Matrix Factorization, NMF）、あるいは多変量スペクトル分解（Multivariate Curve Resolution, MCR）と呼ばれる方法が有効となる[3-8]。これらの手法は HT 測定で得られる XRD スペクトルが数種類の非負基底の非負線形結合で表されると仮定して、極小値探索により非負基底、および線形結合係数を求める手法であり、理想的には非負基底が単相スペクトル、線形結合係数が各結晶相の割合に対応する。

NMF 法による XRD スペクトル分解の問題は、非負基底および非負線形結合係数に対する制約が少なく解が一意でないため、非負基底が単相スペクトルに対応する保証がない点である。この問題に対処するには極小値探索時に正則化項を加えることが有効であり、L1 正則化[9, 10] や L2 正則化[8]をはじめ、直交性[11]、滑らかさ[12] 等を正則化項として加味することが提案されている。しかしながらいずれの方法も満足のいく分解ができているとは言い難い。

複数の結晶相が混合された混合相の XRD スペクトルでは通常、一部のピークを除き各結晶相の単相スペクトルは重ならない。これは数学的には単相スペクトル間の線形独立性が高いことに対応する。したがって線形独立性を向上させる正則化項は、結晶相の XRD スペクトルの分解において良い正則化項になることが予想される。そこで本研究では線形独立性の定量化、および線形独立性を考慮した NMF の開発を目的として研究を行った。

連絡先：吉川信明，豊田中央研究所，
〒480-1192 愛知県長久手市横道 41-1，0561-71-8044，
e1703@mosk.tytlabs.co.jp

2. 方法

正則化項を含む NMF は $Y \in \mathbb{R}^{N\times M}$、$C \in \mathbb{R}^{N\times L}$、$S \in \mathbb{R}^{L\times M}$ として

$$\text{minimize } f(Y,CS) \equiv d(Y,CS) + g(C,S)$$
$$\text{subject to } C_{nl} \geq 0,\ S_{lm} \geq 0$$

で表される。HT-XRD スペクトルの文脈では、Y は HT-XRD 測定で得られたスペクトルのセット、C は線形結合の係数、S は単相スペクトルに対応する。また、$d(Y,CS)$ は入力値と分解値の乖離度、$g(C,S)$ は正則化項である。なお、本研究では乖離度として、

$$d(Y,CS) = \frac{1}{2}\|Y-CS\|_F^2 = \frac{1}{2}\sum_{nm}\left(Y_{nm} - \sum_l C_{nl}S_{lm}\right)^2$$

を使用している。

本研究で提案する線形独立性を考慮した正則化項は、

$$g^{\text{indep}}(S) = -\frac{k_1^{\text{indep}}}{2}\log[\det(SS^{\mathrm{T}})] + \frac{k_2^{\text{indep}}}{2}\mathrm{tr}(SS^{\mathrm{T}})$$

である。ここで $k_1^{\text{indep}}, k_2^{\text{indep}}$ はハイパーパラメータであり正値を取る。本正則化項は S の各成分が線形従属となるときに ∞、直交する場合に 0 となる関数であり、特に線形従属性が高い場合に急激に大きくなる。このような特性は NMF の分解結果が線形従属となることを強く抑制する効果を持つ。

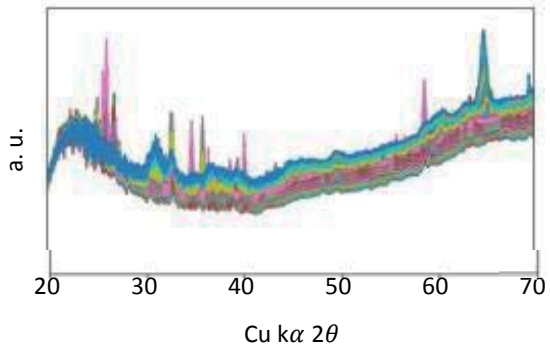


図 1 HT-XRD 測定により測定される XRD スペクトルのセット.

3. 結果と議論

図 1 は斜めスパッタ法により製膜した 81 サンプルの Ga_2O_3-GeO_2-Cr_2O_3 系コンビナトリアル傾斜組成薄膜の HT-XRD スペクトルであり、図 2 はその分解結果と分解結果を既存の XRD スペクトル DB と照合した結果である。分解されたスペクトルと DB 照合結果は良い一致を示しており、提案手法により複数の相を含んだ HT-XRD スペクトルから良好な精度で単相スペクトルを抽出できていることが分かる。提案手法は通常の NMF に線形独立性の正則化項を加えるだけという非常に単純な方法であり、本手法がうまくいくということは、線形独立性が単相スペクトルの特徴を良く捉えていることを意味する。また、本手法ではスペクトルの分解に DB を利用しないため、DB に存在しない新しい結晶相の抽出が可能である。実際、本手法で見つかった Ga_4GeO_8 相は（DB には登録されていたが、）専門家の手動解析では見逃されていた相であった。

4. まとめ

本研究では線形独立性という単相スペクトルの特徴をうまく捉えた正則化項を用いることで、HT-XRD スペクトルから単相スペクトルを抽出する NMF 手法を開発した。本手法は DB を参照することなく単相スペクトルを得ることが可能であるため、未知の相を抽出する能力を持つ。また、今回は特に言及していないが単相スペクトルとともにその強度も同時に取得されるため、この強度に注目することで相図の自動作成等も可能と考えられる。

本研究では提案した線形独立性の正則化項を加える以外に特殊な手法は用いていない。したがって既存の正則化項と組み合わせたり、NMF 手法を改良することにより、より高精度な分解が達成できる可能性を持つ。なお、XRD スペクトルは条件によってピークのブロード化やシフトが起こるが、これらついても今後本手法を改良することで対応する予定である。

5. 謝辞

本研究を進めるに当たり、弊社西川和孝氏、松原賢東氏から実験データを提供頂いた。また岸田佳大氏にはデータ測定に協力いただいた。

参考文献

[1] A. Jain *et al.*, "Commentary: The Materials Project: A materials genome approach to accelerating materials innovation," *Apl Materials*, vol. 1, no. 1, p. 011002, 2013.

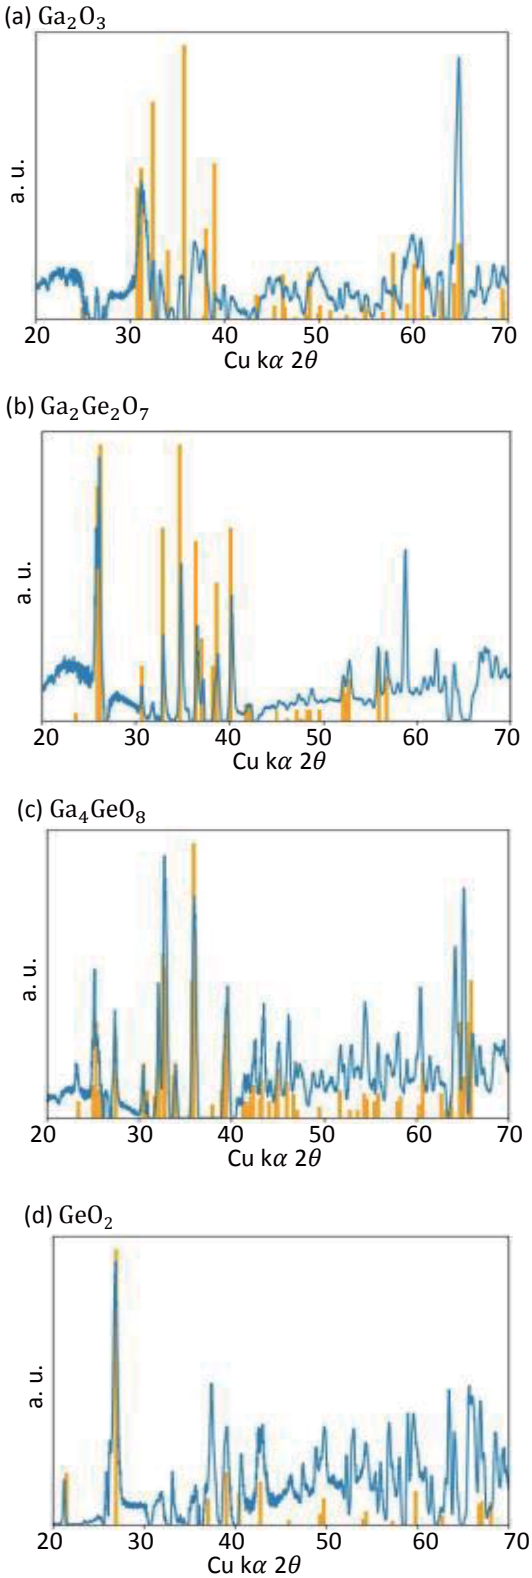


図 2 HT-XRD スペクトルの分解結果（青）と DB 照合の結果（黄）. (b)~(d) については細かいピーク特徴まで捉えられている. (a) については抽出精度は高くないが、実験条件を考慮すれば同定は可能である.

[2] R. Potyrailo, K. Rajan, K. Stoewe, I. Takeuchi, B.

Chisholm, and H. Lam, "Combinatorial and high-throughput screening of materials libraries: review of state of the art," *ACS combinatorial science*, vol. 13, no. 6, pp. 579-633, 2011.

[3] D. D. Lee and H. S. Seung, "Algorithms for non-negative matrix factorization," in *Advances in neural information processing systems*, 2001, pp. 556-562.

[4] C. Long, D. Bunker, X. Li, V. Karen, and I. Takeuchi, "Rapid identification of structural phases in combinatorial thin-film libraries using x-ray diffraction and non-negative matrix factorization," *Review of Scientific Instruments*, vol. 80, no. 10, p. 103902, 2009.

[5] S. Ermon *et al.*, "Pattern Decomposition with Complex Combinatorial Constraints: Application to Materials Discovery," in *AAAI*, 2015, pp. 636-643.

[6] J. Gregoire, D. Van Campen, C. Miller, R. Jones, S. Suram, and A. Mehta, "High-throughput synchrotron X-ray diffraction for combinatorial phase mapping," *Journal of synchrotron radiation*, vol. 21, no. 6, pp. 1262-1268, 2014.

[7] R. Tauler, "Multivariate curve resolution applied to second order data," *Chemometrics and intelligent laboratory systems*, vol. 30, no. 1, pp. 133-146, 1995.

[8] V. P. Pauca, J. Piper, and R. J. Plemmons, "Nonnegative matrix factorization for spectral data analysis," *Linear algebra and its applications*, vol. 416, no. 1, pp. 29-47, 2006.

[9] V. Pomareda, D. Calvo, A. Pardo, and S. Marco, "Hard modeling multivariate curve resolution using LASSO: application to ion mobility spectra," *Chemometrics and Intelligent Laboratory Systems*, vol. 104, no. 2, pp. 318-332, 2010.

[10] P. O. Hoyer, "Non-negative sparse coding," in *Neural Networks for Signal Processing, 2002. Proceedings of the 2002 12th IEEE Workshop on*, 2002, pp. 557-565: IEEE.

[11] C. Ding, T. Li, W. Peng, and H. Park, "Orthogonal nonnegative matrix t-factorizations for clustering," in *Proceedings of the 12th ACM SIGKDD international conference on Knowledge discovery and data mining*, 2006, pp. 126-135: ACM.

[12] S. Essid and C. Févotte, "Smooth nonnegative matrix factorization for unsupervised audiovisual document structuring," *IEEE Transactions on Multimedia*, vol. 15, no. 2, pp. 415-425, 2013.

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

固体系材料インフォマティクスのための畳み込みニューラルネットを活用する3Dボクセルデータ記述子

A universal 3D voxel descriptor for solid-state materials informatics with convolutional neural networks

梶田晴司　大庭伸子　旭良司
Seiji Kajita　Nobuko Ohba　Ryoji Asahi

株式会社 豊田中央研究所
Toyota Central R&D Labs., INC.

Materials informatics (MI) is a promising approach to liberate us from the time-consuming trial and error process for material discoveries. Contrary to molecular systems, however, practical successes of the solid-state MI are very scarce because existing descriptors insufficiently describe 3D features of field quantities (e.g., electron distributions and local potentials). We develop a simple, generic 3D voxel descriptor that compacts any field quantities, in such a suitable way to implement convolutional neural networks. We examine the reciprocal-lattice 3D voxel space descriptor encoded from the electron distribution by a regression task with 680 oxides data. The present scheme outperforms other descriptors in the prediction of Hartree energies that are significantly relevant to the long-wavelength distribution of the valence electrons.

1. はじめに

材料探索は研究者のカンと経験で実施されてきたが，材料インフォマティクス (materials informatics; 以下 MI) のアプローチではデータを活用した超高効率な材料探索が期待されている．機械学習を適用するには物質の特徴をなんらかのプロトコルで数値ベクトルに変換する必要がある．この数値ベクトルは記述子と呼ばれ，機械学習アプローチの成否を決める重要なものである．

分子系の MI は創薬を中心に発展が進んでいるが，固体の MI はいまだ緒に就いた段階である．固体の MI が難しい理由は，電子密度分布やポテンシャルといった場の量を表現する記述子が限られるためである．物質は点で表される原子核と，連続的な広がりを持つ電子で構成されている．原子核に着目した点描像の記述子として coulomb matrix(CM)[1, 2, 3] や smooth overlap of atomic positions(SOAP)[4, 5, 6] が提案されている一方，場の量を表現する記述子は少ない．電子が局在的に分布する分子系と異なり，電子の広がりが固体特性の本質的な起源になる場合が多いため，場の量を取り扱う記述子は固体系でより重要となる．

そこで我々は，結晶内の場の量を表現する逆格子 3 次元ボクセル空間 (reciprocal-lattice 3D voxel space: 以下 R3DVS) 記述子を開発した [7]．そして 680 種類の酸化物の電子分布から R3DVS 記述子を生成し，それを畳み込みニューラルネット (convolutional neural networks: 以下 CNNs) の学習データに使用してエネルギーに関連する物理量を回帰する．SOAP と CM 記述子を用いた機械学習とのベンチマークをとり，R3DVS 記述子の特徴や回帰精度を包括的に評価する．

2. 関連研究

記述子には大きく分けて 2 つのカテゴリがある．1 つは原子番号や電気陰性度，バンドギャップ，密度，擬ポテンシャルのコア半径などの物性量をもとに，その分野に精通した研究者が良い記述子をデザインする方策である [8, 9, 10, 11, 12, 13, 14]．このような発見的な記述子はしばしば「ハンドクラフト記述子」と呼ばれ，古くは 1960 年代から実施されており現在でも多くの成功を収めている．

2 つ目のカテゴリは物質の特徴を理論的に数値ベクトルへ射影する方策で，便宜上，本研究では「理論的記述子」と呼ぶ．ハンドクラフト記述子と違い，理論的記述子は計算式にそって一意的に作られるため，使用者の資質に依存せずに様々な問題へ適用できる柔軟性がある．このカテゴリに分類される手法には，原子隣接密度の類似度を記述する SOAP，構成原子核間のクーロンポテンシャルを行列表示した CM，動径対称関数による構成原子の局所構造の表現 [15, 16, 17]，原子の分布関数のフーリエ変換やウェーブレット変換による表現 [18, 19]，などの記述子が提案がされている．

さて記述子にはいくつかの条件が要求される．物質に並進と回転，原子ラベルの交換操作を施してもその性質は変わらないことに起因し，記述子も同様の操作で不変であることが求められる．例えば角度方向の積分をした原子の動径分布関数を使って回転不変性を取り入れる工夫があるが [18]，当然この平均化により固体構造の角度情報は犠牲になる．固体系の記述子はさらに厄介であり，周期性に起因するユニットセル選択の不変性が追加される [7]．固体系かつ単一元素に限定されない理論的記述子として SOAP や CM が挙げられるが，種類は非常に少ない．

3. 逆格子 3D ボクセル空間 (R3DVS) 記述子

ある結晶のユニットセルの基本並進ベクトルを $\mathbf{a}_i, i = 1, 2, 3$ とおき，その逆格子の基本並進ベクトルを $\mathbf{b}_i$ とおく．これらは $\mathbf{a}_i \cdot \mathbf{b}_j = 2\pi\delta_{ij}$ の関係をもつ．結晶内に分布する場の関数 $s(\mathbf{r})$ のフーリエ係数の絶対値は，

$$|s(\mathbf{g})| = \frac{1}{v_c}\left|\int_{v_c} \exp(-\mathrm{i}\mathbf{r}\cdot\mathbf{g})s(\mathbf{r})d\mathbf{r}\right| \quad (1)$$

である．ここで v_c はユニットセルの体積，$\mathbf{g}$ は逆格子ベクトルを表す．さて通常の計算，例えば第一原理計算で得られる場のデータは $\mathbf{r}$ に関して連続ではなく，$\mathbf{r} = (m_1/M_1)\mathbf{a}_1 + (m_2/M_2)\mathbf{a}_2 + (m_3/M_3)\mathbf{a}_3$ で区切られたボクセルデータである．それに対応

連絡先: 梶田晴司，〒 480-1192 愛知県長久手市横道 41-1 豊田中央研究所、fine-controller@mosk.tytlabs.co.jp

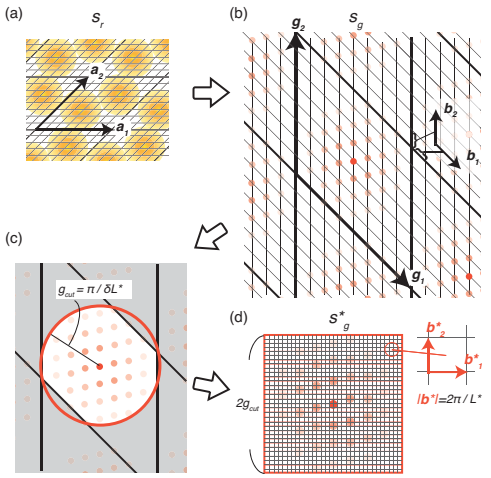


図 1: R3DVS 記述子作成の模式図

し逆格子ベクトルも同様に，$\mathbf{g} = m'_1\mathbf{b}_1 + m'_2\mathbf{b}_2 + m'_3\mathbf{b}_3$ となる．ここで整数 m_i, m'_i はボクセルのインデックス番号，M_i はインデックスの最大数を表し，$0 \leq m_i, m'_i < M_i$ である．離散化された場の関数を $s(\mathbf{r}) \sim s_r(m_1, m_2, m_3) = s_r(\mathbf{m})$，および $s(\mathbf{g}) \sim s_g(m'_1, m'_2, m'_3) = s_g(\mathbf{m}')$ と記す．式 (1) は以下のように離散化される．

$$|s_g(\mathbf{m}')| = \frac{\Delta}{v_c}\left|\sum_{\mathbf{m}} \exp[-2\pi \mathrm{i} \sum_{i=1}^{3} m_i m'_i / M_i] s_r(\mathbf{m})\right| \qquad (2)$$

ここで Δ はボクセルの体積である．

R3DVS 記述子のアルゴリズムを以下に記す．

1. 式 (2) に従いボクセルデータ s_r から s_g を生成する (図 1(a), (b))．
2. 逆格子空間の原点 $\mathbf{g} = 0$ を中心に半径 g_{cut} の球でくり抜く (図 1(c))．さらにその球に外接する立方体で s_g を囲み，その立方体に合わせて逆格子ベクトル $\mathbf{b}^*_i$ を取り直す．
3. $\mathbf{b}^*_i$ で規定されるボクセルメッシュに s_g の値を再配置させて s^*_g を作る (図 1(d))．

以上のプロトコルから得られる $|s^*_g|$ が R3DVS 記述子である．この記述子は構造の異なる結晶であっても場の関数を一定の立方格子ボクセル数で規格化できるため，CNNs といった機械学習手法の入力データとして使用できる．

本記述子の生成で使用するパラメータは，$g_{cut} = \pi/\delta L^*$ を定める δL^* と，$|\mathbf{b}^*_i| = 2\pi/L^*$ の L^* である．δL^* を小さく，L^* は大きくとれば記述子の精度は向上するが，ボクセル数が多くなるため記述子のデータ量と CNNs の学習時間が増加する．本計算では $\delta L^* = 0.4$ Å, $L^* = 12.8$Å に設定した．このパラメータによる R3DVS のボクセル数は 32^3 である．

4. 計算条件

4.1 データ

無機結晶構造データベース (Inorganic crystal structure database: ICSD) に登録されている酸化物の中で，構造が既知

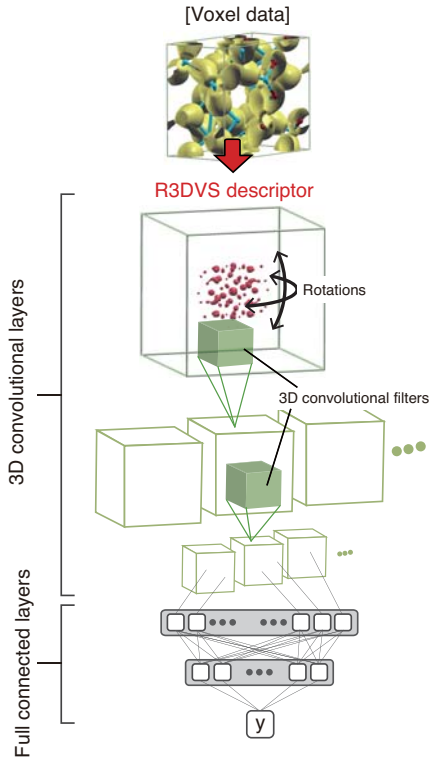


図 2: R3DVS 記述子と 3D CNNs 学習モデルの模式図

かつユニットセルに含まれる原子の数が 50 以下のものを 680 種選択した．この酸化物に対し密度汎関数理論にもとづく第一原理計算を VASP[20] で実施した．固体の全エネルギー E を構成する以下のエネルギー項を目的変数として使用する．

$$E = \sum_i \epsilon_i - E_H + \Delta E_{xc} + E_I$$

$$\Delta E_{xc} = E_{xc} - \int v_{xc}(\mathbf{r})\rho(\mathbf{r})d\mathbf{r} \qquad (3)$$

ここで ϵ_i，E_H，E_{xc}，v_{xc} および E_I はそれぞれ電子の i 番目の 1 電子軌道エネルギー，ハートリーエネルギー (古典的な電子-電子静電エネルギー)，交換・相関エネルギー，交換・相関ポテンシャル，原子核同士の静電エネルギーを表す [21]．$\rho(\mathbf{r})$ は電子密度分布である．これらエネルギー項に加え，固体の凝集エネルギーとバンドギャップも目的変数として採用する．

4.2 学習モデル

酸化物の価電子密度分布から R3DVS 記述子を生成し，図 2 に示す CNNs の入力データに用いた．回転不変性を CNNs に獲得させるため，ランダムに 3 次元回転させた R3DVS データを 30 枚生成して入力データを増やした．実装は python ライブラリ keras を用い [22]，バックエンドは tensorflow を使用した [23]．畳み込み層のフィルタ数は 16 枚，ボクセルフィルタのサイズは 3^3 に設定した．ネットワーク構造の詳細は文献 [7] 参照のこと。

SOAP 記述子はそれ自体をカーネルに用いた SOAP カーネルリッジ，CM 記述子に使用する回帰モデルはガウスカーネルリッジを採用し，それぞれの正則化パラメータは 3.0 および 0.01 と設定した．これらのカーネル回帰モデルは scikit-learn を使用して実装した [24]．

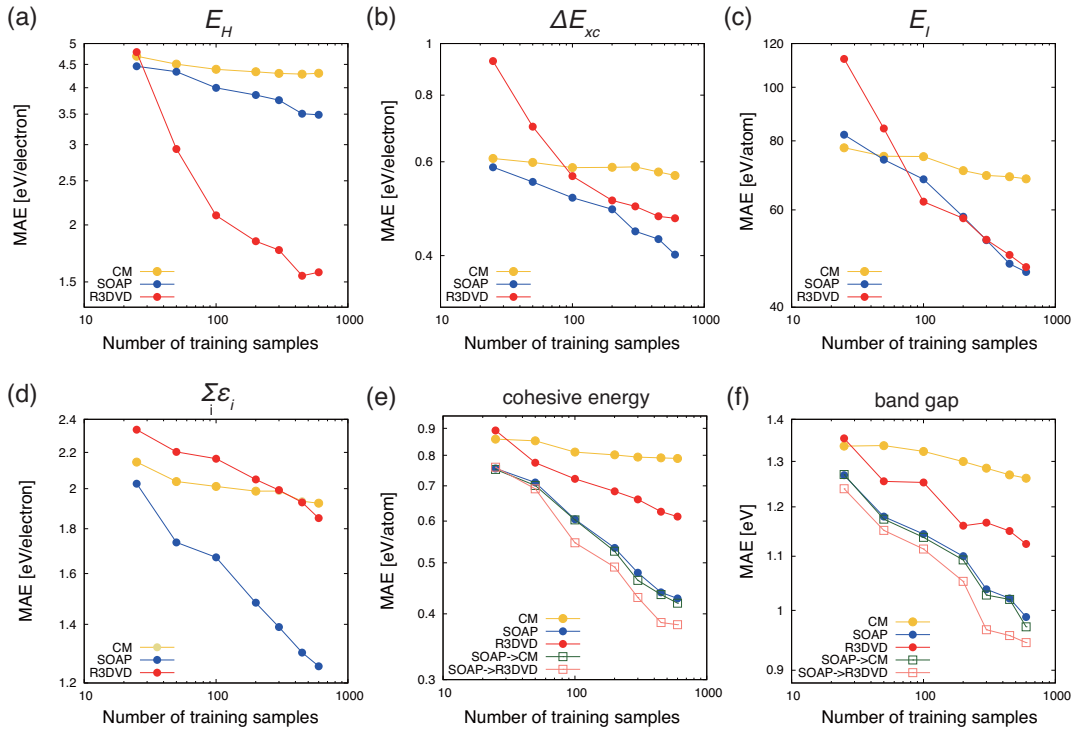


図 3: R3DVS と SOAP，CM 記述子による (a) ハートリーエネルギー (古典的な電子-電子の静電相互作用)，(b) 交換-相関相互作用項，(c) 原子核の静電エネルギー，(d) 一電子軌道エネルギーの和，(e) 凝集エネルギー (f) バンドギャップの回帰の平均絶対誤差 (Mean absolute errors; MAE).

5. 結果

680 種類の酸化物の中から 80 種をランダムサンプルしたものをテストデータとし，残りをトレーニング標本として用いた．CNNs の初期値依存性の影響を抑えるため学習は 5 回実施し，それぞれの予測値の平均を取る．この回帰テストを 20 回実施し，その回帰誤差の平均を図 3 に示す．

トレーニング標本数が増えるほど R3DVS, SOAP, CM 記述子による回帰性能は向上する．R3DVS 記述子は特にハートリーエネルギー (図 3(a)) の回帰性能が他よりも優れている．この理由は，R3DVS 記述子が電子密度分布から生成されており，電子間の静電エネルギーの予測に適するためである．交換・相関エネルギー項 ΔE_{xc}(図 3(b)) や原子核の静電エネルギー E_I(図 3(c)) は SOAP 記述子による回帰性能とほぼ同等だが，1 電子軌道エネルギーの和 $\sum_i \epsilon_i$(図 3(d)) の回帰性能は悪い．精度が悪化した原因は，1 電子軌道エネルギーには電子の運動エネルギーおよび電子と原子核との相互作用エネルギーが含まれているため，R3DVS 記述子が有する電子密度分布の情報だけでは表現できないためと考えられる．凝集エネルギー (図 3(e)) とエネルギーギャップ (図 3(f)) が SOAP 回帰よりも精度が悪いのも同様の理由と考えられる．

次に，複数の記述子を用いることで回帰精度が向上するか検討する．たとえ電子局在性が強いイオン結晶であっても実際の電子はある程度の広がりをもつため，点描像の SOAP はこの電子の広がりを記述するには表現力不足である．逆に R3DVS は電子密度分布を良く記述するが，局在性が強い原子核の存在は無視されている．この洞察に立脚し，点描像と場の描像を両方とり込むように記述子を同時使用する．

まずトレーニング標本を用いて SOAP 記述子による回帰モデル $\tilde{y}_{SOAP}$ を作り，トレーニング標本の目的変数 $y_{correct}$ と $\tilde{y}_{SOAP}$ との誤差 $\Delta y = y_{correct} - \tilde{y}_{SOAP}$ を記録しておく．次に Δy を目的変数として R3DVS 記述子を使った CNNs に学習させ，回帰モデル $\Delta\tilde{y}_{R3DVS}$ を作る．そしてテストで使用する予測値を $\tilde{y} = \tilde{y}_{SOAP} + \Delta\tilde{y}_{R3DVS}$ により算出する．これは SOAP 回帰を目的変数の主要項とみなし，R3DVS による CNNs 回帰で摂動項を表現する方策である．結果を図 3(e) と (f) の SOAP→R3DVS の凡例で記されるプロットで示す．期待通り凝集エネルギーとバンドギャップの回帰性能は，SOAP 回帰単独のものより向上する．比較のため SOAP 回帰と CM 回帰の組み合わせも検討したところ（図 3(e) と (f) の SOAP→CM の凡例）回帰性能にほとんど改善が見られなかった．以上より，点描像の SOAP と場の描像の R3DVS を併用すると相補的に作用し予測精度が向上することが確かめられた．

6. 結論

電子密度分布から生成した R3DVS 記述子は、特にハートリー項 (電子密度分布による静電エネルギー) に対し回帰性能が高かった．一方，電子の運動エネルギーや原子核ポテンシャルとの相互作用エネルギーが含まれる 1 電子軌道エネルギーの回帰性能は悪い．密度汎関数法によれば電子密度分布から電子の運動エネルギーは決定されるとはいえ，その運動エネルギー汎関数は未だ解析解が見つかっていない．また，原子核のポテンシャルもまた電子密度分布から導くことが難しい量である．つまり CNNs にとって電子密度分布の情報だけをもとに，1 電子軌道エネルギーを精度よく予測するのは難易度が高すぎると考えられる．原子を点と捉える SOAP と場の描像の R3DVS 記述子を併用すると予測精度は向上した．今回の結果

を踏まえると，点描像と場の描像の記述子どちらが優れているかではなく，互いに相補的な情報であるため，両記述子を共存させた予測モデルを作成することが肝要と結論される．

本検討では R3DVS の検証という立場のため，第一原理計算のエネルギー項を目的変数とした．しかし MI の実務上では計算が困難な物性値，例えば輸送係数などを予測するといった使い方が本来のものであろう．R3DVS 記述子により固体系の場の量が表現できるようになったため，様々な物性値の予測が可能となるだろう．

謝辞

SOAP のプログラムを提供いただいた、豊田中央研究所の陣内亮介博士に感謝する．

参考文献

[1] M. Rupp, A. Tkatchenko, K.-R. Muller, and O. A. von Lilienfeld, Phys. Rev. Lett. **108** 058301 (2012).

[2] K. Hansen, et al, J. Chem. Theory Comput. **9** 3404 (2013).

[3] F. Faber, A. Lindmaa, O. A. von lilienfeld, and R. Armiento, Int. J. Quant. Chem. **115** 1094 (2015).

[4] A. P. Bartók, R. Kondor, and G. Csányi, Phys. Rev. B **87** 184115 (2013).

[5] W. J. Szlachta, A. P. Bartók, and G. Csányi, Phys. Rev. B **90** 104108 (2014).

[6] S. De, A. P. Bartók, G. Csányi, and M. Ceriotti, Phys. Chem. Chem. Phys. **18** 13754 (2016).

[7] S. Kajita, N. Ohba, R. Jinnouchi, R. Asahi, Sci. Rep. **7** 16991 (2017).

[8] J. A. Van Vechten, Phys. Rev. **182** 891 (1969).

[9] A. Zunger, Phys. Rev. B **22** 5839 (1980).

[10] P. Villars, et al., J. Alloys Comp. **317-318** 26-38 (2001).

[11] P. Villars, et al., J. Alloys Comp. **367** 167-175 (2004).

[12] A. Seko, et al., Phys. Rev. Lett. **115** 205901 (2015).

[13] A. D. Sendek, et al., Energy Environ Sci. **10**(1), 306-320 (2017).

[14] F. A. Faber, A Lindmaa, O. A von Lilienfeld, and R. Armiento, Phys. Rev. Lett. **117** 135502 (2016).

[15] J. Behler and M. Parrinello, Phys. Rev. Lett. **98** 146401 (2007).

[16] J. Behler, Int. J Quant. Chem. **115** 1032 (2015).

[17] N. Artrith, and A. Urban, Comp. Mat. Sci. **114** 135 (2016).

[18] O. A. von Lilienfeld, R. Ramakrishnan, M. Rupp, A. Knoll, Int. J Quant. Chem. **115** 1084 (2015).

[19] M. Hirn, S. Mallat, N. Poilver, Multiscale Model Simul. **15**(2) 827 (2017).

[20] G. Kresse and J. Furthmüller, Phys. Rev. B **54** 11169 (1996).

[21] R. G. Parr and W. Yang, "Density-Functional Theory of Atoms and Molecules", Oxford University Press (1989).

[22] https://keras.io

[23] https://www.tensorflow.org

[24] http://scikit-learn.org/stable

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

電子顕微鏡像からのイオン伝導度の学習 ～畳み込みニューラルネットワークによる特徴可視化～

Visualization of SEM/EBSD Features of Ionic Conductivity with Convolutional Neural Networks

近藤瑠歩 *1 Ruho Kondo　山川俊輔 *1 Shunsuke Yamakawa　増岡優美 *1 Yumi Masuoka　田島伸 *1 Shin Tajima　旭良司 *1 Ryoji Asahi

*1豊田中央研究所
Toyota Central R&D Labs., Inc.

To automatically extract the features required to predict the material properties from microstructure, we utilized convolutional newral networks (CNNs). Training of CNNs was carried out by using experimentally obtained scanning electron microscope images and ionic conductivities. After training, the nodes, which placed after global average pooling (GAP), specifically activated by passing through the images with high/low ionic conductivities were searched. Then, the corresponding feature maps just before GAP operations were shown. We found that the CNNs focused on the reagion containing large voids and on the area without any crystal defects for the specific features for the material with high ionic conductivities while on the small voids for low ionic conductivities. Such observations agree with knowledge of materials engineering.

1. 緒言

深層学習を用いることで自然画像を高精度に認識できることは周知の事実であるが、同技術を電子顕微鏡像のような精密測定機器から得られるデータに適用した例は少ない。その原因は、電子顕微鏡像を得るのが高コストであり、多量のデータを集められないうえに、スタンダードなオープンデータセットも存在しないためである。また、電子顕微鏡像のような特殊な撮影方法で得られた画像データは、例えばコントラストに物理的な意味があるためコントラスト正規化ができないといった、データに関する専門的な知識が必要であることも深層学習普及の障害となっている。さらに、材料組織に機械学習を適用した既存研究 [Chowdhury 16, Cang 16, Lubbers 17] では材料組織の分類や再構成に用途が限られている一方で、材料開発の観点からは材料組織画像中に含まれる物性予測に重要な特徴を人が理解可能な形で得ることが求められる。

本研究では、燃料電池の電極材料であるイットリア安定化ジルコニア (YSZ) の電子顕微鏡像と、YSZ の酸素イオン伝導度の関連付けをターゲットとし、以下の手順で上述の問題にアプローチした。まず、代表体積要素の考えに基づいて電子顕微鏡像をデータ増強することで、データ不足を補った。次に、得られたデータセットを用いて電子顕微鏡像から酸素イオン伝導度を回帰予測する畳み込みニューラルネットワーク (CNN) を訓練した。最後に、CNN が高イオン伝導度 (または低イオン伝導度) の出力をする際に反応する箇所を可視化し、材料技術者の持つ知見と比較した。

2. データ

2.1 入力画像

焼結温度および焼結時間を変えて作成した 7 つの 8 mol%YSZ 試験片の SEM/EBSD(scanning electron microscope/electron back scatter diffraction patterns) 像を入力画像とした。撮像ステップサイズは 0.2 μm である。極点図を確認したところ、いずれの試験片も結晶方位が一様分布していたため、結晶方位の情報を含んだカラー画像の逆極点マップではなく、モノクロ画像の Image Quality(IQ) マップを使用した (図 1)。IQ マップでは、結晶粒界やボイドのような結晶格子の乱れが大きな部分で値が小さく (図中の黒い領域)、バルク部分のような結晶性の高い部分で値が大きくなる (図中の白い領域)。

図 1 に示すように本材料は多結晶材料であるため、代表体積要素 [Hill 63] の仮定が成り立つと考えられる。これは、周期性の高い多結晶体のような材料では適当な大きさの領域内にマクロな物性量を予測するのに十分な情報が含まれているという仮定である。この仮定が成り立つものとして、1 枚の IQ マップから適当な大きさの画像を複数枚切り抜き、データ増強を行った。この際、切り出す画像サイズを変えて回帰性能を評価し、適切な切り出しサイズの検討を行った。また、本研究で使用する YSZ は圧延や押出しといった集合組織を作る製造過程を経ていないため、画像の上下左右の物理的意味は希薄である。したがって、画像の回転や上下左右反転を行っても物性には影響しないと考えられる。そこで、切り出した画像を任意角度で回転させ、ランダムに上下左右反転させた。以上の操作より、1 枚の IQ マップから 100 枚の画像を作成した。

2.2 教師データ

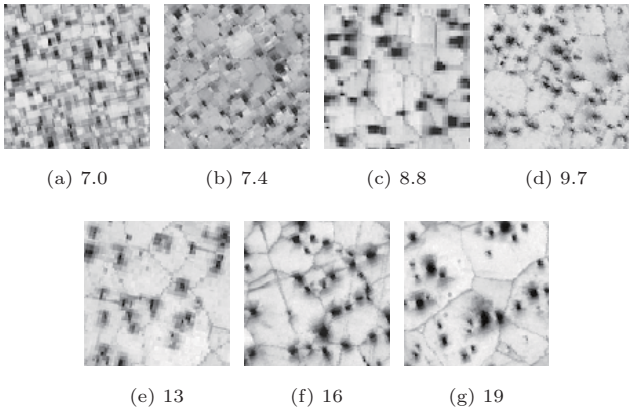
交流インピーダンス法で測定したイオン伝導度を教師データに用いた。この手法で得られたイオン伝導度はバルク材のデータであるが、代表体積要素の仮定が成り立つとすれば、前節の方法で作成した個々の切り出し画像はバルク材のイオン伝導度を予測するに十分な情報を含んでいる。そこで、それぞれの切り出し画像に与える教師データは、切り出し元の YSZ 試験片のバルクのイオン伝導度とした。

3. モデル

3.1 CNN アーキテクチャ

本研究では少量データの学習を行うため、自然画像認識で用いられているような大規模 CNN アーキテクチャから大幅にパラメータ数を削減する必要がある。そこで、図 2 に示す小規模な CNN アーキテクチャを使用した。CNN では全結合層でパラメータ数が爆発的に増えるため、全結合層の直前に Global

連絡先: 近藤瑠歩，豊田中央研究所，愛知県長久手市横道 41-1，r-kondo@mosk.tytlabs.co.jp



(a) 7.0 (b) 7.4 (c) 8.8 (d) 9.7

(e) 13 (f) 16 (g) 19

図 1: 切り出した EBSD IQ マップとイオン伝導度 (単位は mS/cm^2)

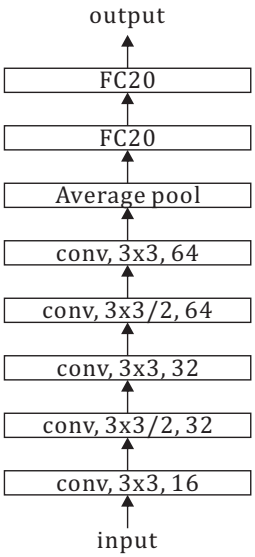


図 2: CNN アーキテクチャ。conv は 2 次元畳み込み層で、続く数字はフィルタサイズ/ストライド、フィルタ数。FC20 はノード数 20 の全結合層。

Average Pooling (GAP)[Lin 13] を採用した (図 2)。出力層以外の活性化関数は ReLU とし、出力層は線形とした。また、活性化関数適用前に Batch Normalization[Ioffe 15] を適用した。

ここで、i 番目のサンプルに対する GAP 入力の特徴マップを $F^{(i)}_{hwc}$、GAP 出力を $g^{(i)}_c$ と書くと、

$$g^{(i)}_c = \frac{1}{HW}\sum_{h,w} F^{(i)}_{chw} \tag{1}$$

と書ける。c、h、w はそれぞれチャンネル、高さおよび幅のインデックス、H および W は特徴マップの高さおよび幅である。

3.2 注視領域の可視化モデル

Class Activation Map[Zhou 16] を回帰問題に拡張した手法を用いて CNN の注視領域を可視化する [Kondo 17]。

まず、サンプル i の教師データを $y^{(i)}$ として

$$y^{(i)} = a_c g^{(i)}_c + b_c \tag{2}$$

と書く。ここで、a_c および b_c は学習パラメータである。$a_p > 0$ ならば g_p は教師データが大きいほどよく反応するノードであり、$a_q < 0$ ならば g_q は教師データが小さいほどよく反応するノードである。

次に、式 (2) を最適化して得られた a_c を用いて以下の量を定義する。

$$P_{mn} = \frac{1}{N(c|a_c > 0)M}\sum_i \sum_{c|a_c>0} F^{(i)}_{mnc} \tag{3}$$

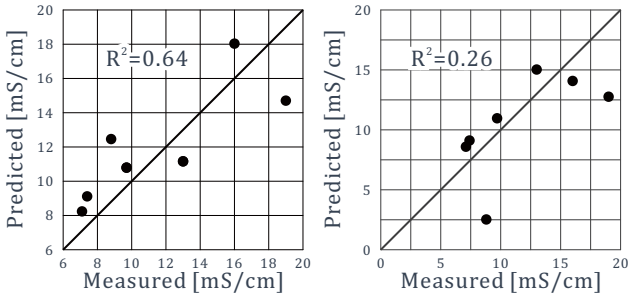
$$Q_{mn} = \frac{1}{N(c|a_c < 0)M}\sum_i \sum_{c|a_c<0} F^{(i)}_{mnc} \tag{4}$$

ここで、$N(x)$ は x の個数、M はサンプル数である。式 (1)、(3) および (4) より、P_{mn} は教師データが大きい入力データに対してよく反応する特徴マップであり、Q_{mn} は教師データが小さい入力データに対してよく反応する特徴マップであるといえる。

4. 結果

4.1 イオン伝導回帰

7 つの YSZ サンプルのうち 1 サンプルをテストデータとして使用し、残り 6 サンプルから切り出した画像とイオン伝導度のペアで教師あり学習を行った。学習後、除外したサンプルから切り出した画像すべてに対する予測イオン伝導度の平均値を計算した。除外するサンプルを順次変更し、計 7 サンプルに対する回帰予測平均値を得た。



(a) CNN (b) KRR

図 3: イオン伝導度回帰結果

図 3 に回帰予測の結果を示す。同図 (b) には平均ボイド径と平均ボイド面積を特徴量とした Kernel Ridge Regression (KRR) の結果を示す。KRR のカーネルはガウシアンカーネルとし、一つ抜き交差検証によって L^2 正則化の強さと特徴長さの最適値を決定した。

図 3 より、CNN は KRR よりも良好な回帰性能を示すことがわかる。なお、紙面の都合で割愛するが、両モデルで予測誤差の大きかったデータは、平均ボイド径と平均ボイド面積を軸にした特徴空間で外挿領域に位置していることを確認している。

4.2 注視領域

図 4 は 7 つの YSZ サンプルそれぞれに対する注視マップ P_{mn} および Q_{mn} のコンター図である。$P_{mn}(Q_{mn})$ の値が高い箇所はイオン伝導度が高い (低い) 材料に頻出する特徴が存在する場所である。同図より、ボイドおよび粒界の存在しない結晶性の高い箇所 (画像の白い領域)、および径の大きなボイ

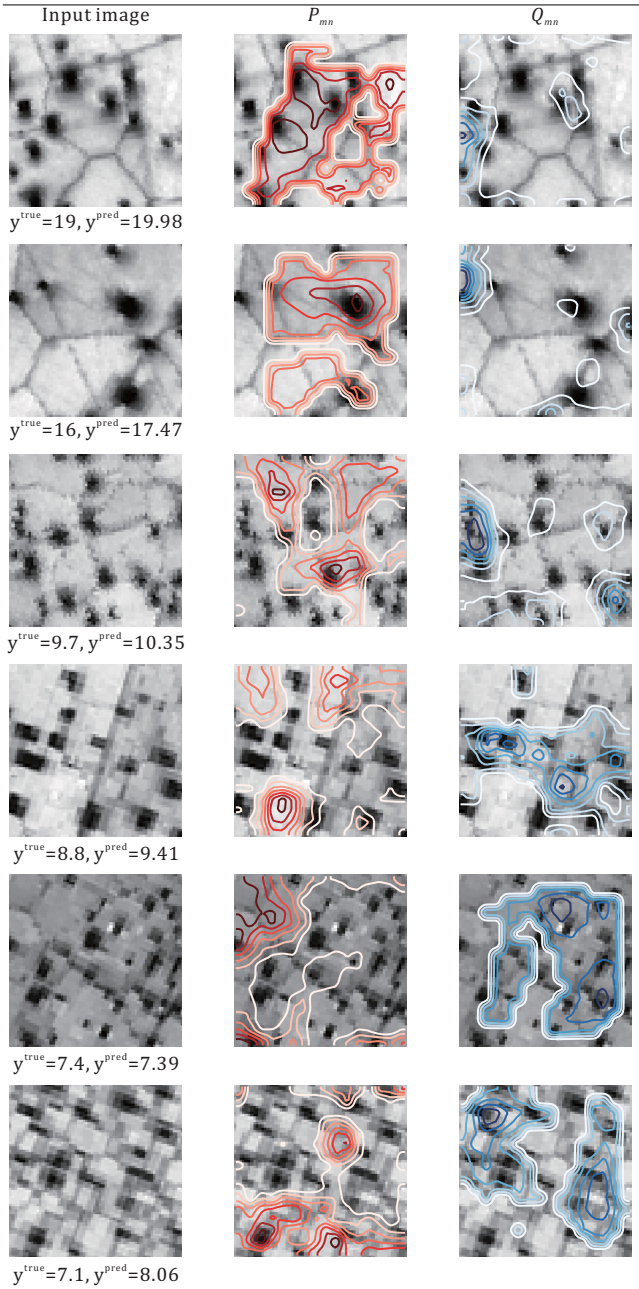


図 4: IQ マップに対する注視領域。Input image 下の数値は測定値 (y^{true}) と一つ抜き交差検証における予測値 (y^{pred})。

ド (画像中の大きな黒丸) が高イオン伝導体に特有の特徴であると CNN が認識していることがわかる。一方、低イオン伝導体の特徴は比較的径の小さなボイドであることがわかる。これらの知見は、ボイドが少ないほどイオン伝導度は大きくなる、および、焼結の進行と共にボイド数は減少するが個々のボイドは大きくなる、といった、従来材料技術者が持っていた知見 [Chen 02, Gibson 98] とよく一致する。

一方、既知の事実として、イオン伝導度は粒径にも依存することが知られている [Chen 02]。しかしながら、今回の可視化では粒界への注目は確認できなかった。この原因として、粒径とボイド数が強い相関をもっていることが考えられる (図 5)。CNN は近隣ピクセルの相関を優先的に収集するため、粒径のような大きな特徴を獲得するよりも、それより小さなボイドに関する特徴を優先してイオン伝導度との紐付けを行ったと考えられる。

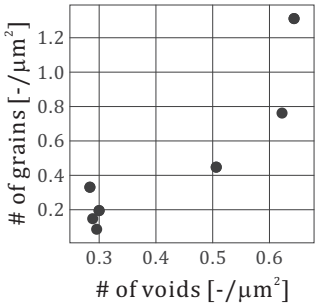


図 5: IQ マップにおけるボイド数と粒径の相関

5. 結言

本報では、材料系の典型的な計測データである電子顕微鏡から物性値を予測する CNN の訓練を行った。その結果、比較的少数のデータからでも良好な学習が行えることを示した。また、CNN の注視領域を可視化することで、CNN の予測根拠が材料技術者の知見と一致することを示した。

参考文献

[Cang 16] Cang, R., Ren, M. Y. (2016, August). Deep network-based feature extraction and reconstruction of complex material microstructures. In ASME 2016 International Design Engineering Technical Conferences and Computers and Information in Engineering Conference (pp. V02BT03A008-V02BT03A008). American Society of Mechanical Engineers.

[Chen 02] Chen, X. J., Khor, K. A., Chan, S. H., Yu, L. G. (2002). Influence of microstructure on the ionic conductivity of yttria-stabilized zirconia electrolyte. Materials Science and Engineering: A, 335(1-2), 246-252.

[Chowdhury 16] Chowdhury, A., Kautz, E., Yener, B., Lewis, D. (2016). Image driven machine learning methods for microstructure recognition. Computational Materials Science, 123, 176-187.

[Gibson 98] Gibson, I. R., Dransfield, G. P., Irvine, J. T. S. (1998). Sinterability of commercial 8 mol

[Hill 63] Hill, R. (1963). Elastic properties of reinforced solids: some theoretical principles. Journal of the Mechanics and Physics of Solids, 11(5), 357-372.

[Ioffe 15] Ioffe, S., Szegedy, C. (2015, June). Batch normalization: Accelerating deep network training by reducing internal covariate shift. In International conference on machine learning (pp. 448-456).

[Kondo 17] Kondo, R., Yamakawa, S., Masuoka, Y., Tajima, S., Asahi, R. (2017). Microstructure recognition using convolutional neural networks for prediction of ionic conductivity in ceramics. Acta Materialia, 141, 29-38.

[Lin 13] Lin, M., Chen, Q., Yan, S. (2013). Network in network. arXiv preprint arXiv:1312.4400.

[Lubbers 17] Lubbers, N., Lookman, T., Barros, K. (2017). Inferring low-dimensional microstructure representations using convolutional neural networks. Physical Review E, 96(5), 052111.

[Zhou 16] Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., Torralba, A. (2016, June). Learning deep features for discriminative localization. In Computer Vision and Pattern Recognition (CVPR), 2016 IEEE Conference on (pp. 2921-2929). IEEE.

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

予測メンテナンスとインフラ劣化学習モデル

Infra Machine Learning for Predictive Maintenance via Classification Models

安野　貴人[*1]
Yasuno Takato

[*1] 八千代エンジニヤリング株式会社
Yachiyo engineering, Co., Ltd.

Aging infrastructure that was developed during the period of high growth is beginning to become obvious. Visual inspection and sensing are carried out to monitor the state of deterioration in preventive maintenance. It is the standard procedure in Japan that bridges with important structures are inspected once in five years where they visually checks the proximity. A high accuracy and efficiency improvement of the bridge inspection is an urgent issue for the both local public municipalities and private enterprises. This paper proposes multi-grade classification models to visualize the weights of feature variables that aim the countermeasure. In addition, the author proposes a method of sensitivity analysis on deterioration progression in the future in response to unit change of degradation factors. Indeed, these methods applied to a bridge inspection data such as super structure steel corrosion and deck reinforced concrete crack.

1. はじめに

高度成長期に整備したインフラ施設の老朽化が顕在化し始めている.予防保全における劣化の状態監視のために,目視点検やセンシングが行われている.重要構造物である橋梁は,5 年に 1 回の頻度で近接の目視を行う点検要領が基準となっている.地方公共団体,民間事業者に関わらず,橋梁点検の高い精度と効率化は喫緊の課題である.本稿では,点検データを用いた多クラスの劣化判別モデルを提案する.これにより,劣化の要因となる特徴変数の重みを視覚化し,対策の照準を合わすことが可能となる.特徴変数の単位変化に対応して今後の劣化進行に関する感度分析の方法を提案する.実際に,橋梁部材の点検データに適用した結果を考察する.

2. 劣化学習モデル

2.1 予測メンテナンスのためのインフラ劣化学習

インフラの点検を効率化するための点検・モニタリング・診断技術に関しては, 例えば, 社会インフラの維持効率を向上する施設モニタリングサービス[日立 2014],社会インフラメンテナンスの技術開発の方向性[土木学会 2017], インフラ維持管理アセットマネジメント[COCN 2017],戦略的イノベーション創造プログラム[SIP 2017],コンクリート内部の鉄筋腐食検査[生嶋 2017], 河川堤防の変状検知[佐古 2017]等,多数の技術研究が見られる. また, 予測メンテナンスや故障解析の機械学習プロセスに関しては, 例えば, 製造プロセスの予知保全の解析技術[MathWorks],予測メンテナンス方法の提案[Kaggle 2017],プラントメンテナンスのタスク自動化テンプレート[Excel Templates]等の製造業の生産プロセスにおける提案が多くみられる.しかし, インフラ施設を対象に, 目視点検やモニタリングのデータを用いて, インフラの劣化状態を自動判定し, さらに, 今後の劣化傾向の予測をいかに行うかという老朽化対策の基盤となるモデル（以下,「インフラ劣化学習モデル」と呼ぶ）が確立されたとは言い難い. 本稿では,インフラ施設の点検データを用いた多クラスの劣化判別モデルと特徴変数の変化に対する劣化状態の感度分析の方法を提案する.

2.2 劣化状態の判別モデル

(1) 劣化状態の多クラス判別モデル

インフラ劣化学習のために,劣化状態が2～5段階である多クラスの判別を可能とする実践的なアルゴリズムをリストアップする.まず,汎用性がある一般化線形モデルGeneralized Linear Model（Multinomial family）に着目した[McCullagh 1983] [Hardin 2012].機械学習の典型的なアルゴリズムNaïve Bayes ,Decision Tree (以下,DTという),k-NN, Support Vector Machine (以下,SVCという), Neural Networkに着目した[Hastie 2009] [Efron 2016].また,アンサンブル手法のRandom Forest [Breiman 1998, 2001]に加え,Gradient Boosted Machineに着目した[Friedman 2001] [Schölkopf 2012].これら8つのアルゴリズムは, scikit-learn[Muller 2016],H2O[Cook 2016], MLTK[Murphy 2012], Rapid Miner[Hofmann 2014]のリソースを用いて迅速に数値計

連絡:安野貴人, 技術開発部, 〒111-8648 東京都台東区浅草橋 5-20-8 CS タワー, tk-yasuno@yachiyo-eng.co.com

算が可能であり,それ自体に新規性はない.本稿では,インフラ劣化学習モデルの実践を追求するため,それらの学習精度と計算時間等の有用性を比較する.

(2) 劣化の特徴変数のシナリオと劣化状態の感度分析

劣化の特徴変数の単位変化に対して,今後の劣化が加速するか減速するかという感度分析の方法を提案する.インフラ施設の諸元や規模,設置条件の外部環境は,大規模改修や更新をしない限り竣工時点から所与の特性である.点検時点から今後,起こりうる特徴変数の変化は,経年変化に伴う老朽化,修繕対策の実施の有無と対策時期が早いか遅いかである.5年間のスパンで, 時間の経過はもちろん,修繕の実施は,対処可能なシナリオである.以下では,他の条件を所与として,1）今後5年先の姿,経過年数が増えるケース,2）修繕を実施する年を早めるか,後方にするかのケースを劣化の特徴変数のシナリオに設定する.機械学習のモデルは,帰納的に計算して精度を高める利点がある.しかし,感度分析には,幾分の精度を犠牲にしてでも,劣化の特徴変数を単位変化させるパラメトリックな操作を行い,劣化状態のクラスがより進行するか,あるいは延命するかの変化を傾向把握したい.一般化線形モデルGeneralized Linear Model（Multinomial family,以下,GLMという）は,劣化状態のクラスと劣化要因となる特徴変数との間に,線形の関係を明示的に考慮できる.以下では, GLMを基盤に,経過年数と修繕実施の単位変化による劣化傾向の変化をシナリオ分析することとする.

3. モデル計算結果

3.1 劣化データと特徴変数

本稿では,橋長100m以上の橋梁195において,1988年から5年ごとに4回（Ⅰ～Ⅳ）,近接目視を行った損傷データ（主桁-鋼材-腐食4,864単位,床版-RC-ひび割れ8,778単位）を対象とする.近接の目視では,劣化の状態a,b,c,d,eによる5段階の判定を行った.劣化を説明する特徴変数は150変数である.内訳は,竣工年,橋長,上部工の形式,橋桁高さ,示方書の年次の橋梁諸元データに加え,海岸からの距離,桁下河川等,大型交通量の設置条件,点検時点の経過年数と径間別の健全度等の点検属性,塗装系や点検前の補修工事の有無,修繕工種等の修繕履歴で構成される.目視点検データの特性は,健全な状態a,bの割合が多く,c,dの割合が少ないというインバランスなデータである.なお,耐用限界に近い状態まで放置することがないため,e判定のデータは数単位（腐食5,ひび割れ1）であった.本計算では,劣化状態a,b,c,dの4クラス判別モデルを学習する.時系列の特性は,5年に1回の頻度で4回点検した点検パネルデータである.劣化状態の判定は,点検士が行いラベルを割り当てる.毎回,同じ点検士が行うとは限らず,人の判断にぶれや無難な判断への歪み等のノイズが含まれる可能性がある.

表 1 主桁-鋼材-腐食の 4 クラス判別モデルの交差評価

Steel Corrosion Classification Models	Accuracy (percent)	Correlation	Running time
Generalized Linear Model (Multi-nomial function)	75.36+/-1.24	0.610+/-0.022	5s
Naïve Bayes (Kernel density estimation, knum=10, bandw=0.3, grid=200)	64.69+/-2.87	0.365+/-0.050	<1s
k-Nearest Neighbor (k=3)	81.20+/-1.07	0.616+/-0.018	4s
Support Vector Classifier (Radial basis function, gamma=0.7, C=4.0)	**81.20+/-0.73**	**0.683+/-0.030**	26s
Deep Neural Network (hidden layers=2, 150×150units, Dropout=0.5, epoch=200)	79.22+/-1.26	0.626+/-0.030	2m13s
Decision Tree (max depth=50)	70.63+/-3.00	0.583+/-0.034	2s
Random Forest (ntree=100, max depth=47)	78.44+/-0.89	0.622+/-0.040	31s
Gradient Boosted Machine (ntree=200, max depth=50)	**82.49+/-0.91**	**0.672+/-0.014**	2m11s

表 2 床版-RC-ひび割れの 4 クラス判別モデルの交差評価

Reinforced Concrete Crack Classification Models	Accuracy (percent)	Correlation	Running time
Generalized Linear Model (Multi-nomial function)	67.89+/-0.47	0.502+0.013	7s
Naïve Bayes (Kernel density estimation, knum=10, bandw=0.3, grid=200)	61.11+/-2.72	0.411+/-0.47	1s
k-Nearest Neighbor (k=3)	80.61+/-0.91	0.716+/-0.20	8s
Support Vector Classifier (Radial basis function, gamma=0.65, C=4.0)	81.43+/-0.83	0.718+/-0.020	30s
Deep Neural Network (hidden layers=2, 150×150units, Dropout=0.5, epoch=200)	79.71+/-0.87	0.688+/-0.012	4m14s
Decision Tree (max depth=60)	**82.49+/-1.06**	**0.739+/-0.020**	2s
Random Forest (ntree=100, max depth=59)	78.72+/-0.36	0.713+/-0.014	34s
Gradient Boosted Machine (ntree=260, max depth=65)	**82.87+/-1.09**	**0.743+/-0.018**	5m4s

3.2 劣化学習の計算結果

表 1 と**表 2** に, 主桁-鋼材-腐食及び床版-RC-ひび割れのデータに 8 つのアルゴリズムを適用した結果を示す.Cross Validation（交差評価）では,劣化状態別の階層サンプリングにより 5-fold の評価を行った.このなかで,最高の精度を示したのは,Gradient Boosted Machine (以下,GBM と表す) である.主桁-鋼材-腐食は,Accuracy 82.49+/-0.91%,実績と予測との相関係数 0.672+/-0.014 の評価を得ている.また,床版-RC-ひび割れの学習結果は, Accuracy 82.87+/-1.09%,実績と予測の相関係数 0.743+/-0.018 の評価を得ている.

表 3 Gradient Boosted M.Confusion Matrix（主桁-鋼材-腐食）

	true a	true b	true c	true d	precision
pred. a	2444	313	61	**11**	86.4%
pred. b	267	1350	53	**19**	79.9%
pred. c	48	48	202	**3**	67.1%
pred. d	6	19	3	18	**39.1%**
recall	88.4%	78.0%	63.3%	**35.3%**	

表 4 Gradient Boosted M.Confusion Matrix（床版-RC-ひび）

	true a	true b	true c	true d	precision
pred. a	3020	333	88	**34**	86.9%
pred. b	415	2988	196	**50**	81.9%
pred. c	54	156	1027	**29**	81.1%
pred. d	17	63	34	265	69.9%
recall	86.1%	84.4%	76.4%	70.1%	

表 3 と**表 4** に,主桁腐食及び床版ひび割れに関する GBM の Confusion Matrix を示す.主桁腐食の d 判定は 50 単位のデータの少なさから,精度 39.1%,再現率 35.3%が低い.床版ひび割れ d 判定（300 以上）は,精度 69.9%,再現率 70.1%と良好な結果を得た.特に,a,b,c 判定と予測したが,実際に d 判定となる予測誤差（true d 列）は,最小化しなければならない.この問題は,予測誤差に対するコストの感度を明示的に考慮した判別モデルの再学習が可能である[Yasuno 2018].

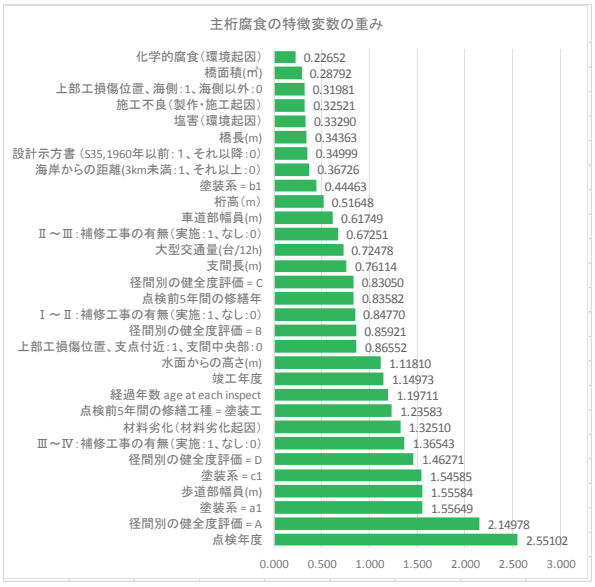


図 1 主桁腐食の特徴変数の重み（GLM：Multinomial family）

図 1 に,GLM の主桁腐食の劣化学習に用いた特徴変数 150 のうち上位 30 の重みを昇順に図示した.主桁-鋼材の腐食には,1）点検年,竣工年,点検時の経過年数という時間軸の経年変化,2）水面からの高さ,海岸からの距離（3km 未満）という橋梁が置かれた外部環境,3）点検前 5 年間における補修工事の有無,修繕工種（塗装工）,修繕の実施年（西暦）という修繕履歴,4）歩道幅員,支間長さ,橋長,橋面積,大型交通量という橋梁の規模,5）塗装系,損傷の位置（海側,支点,支間中央）,径間別の健全度という損傷部材の特性,6）材料劣化,塩害・化学的腐食（環境起因）という特徴変数が劣化状態のクラス判別に働いていることが読み取れる.

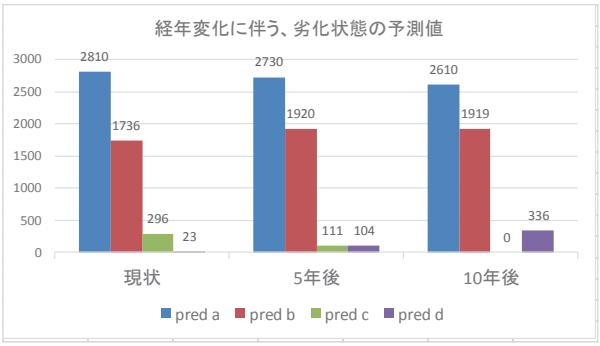


図 2 経過年数の変化に対する主桁腐食の劣化状態の予測値

さらに,主桁腐食の特徴変数を変化させた場合の劣化状態の予測値の感度分析を行った計算結果を示す.**図 2** に,経過年数と点検年度の特徴変数を 5 年後,10 年後と増加させた場合の劣化状態の予測値の変化を図示した.経年変化に伴い,健全な a 判定の数が減少し,c 判定の数が減少する代わりに,d 判定の数が増加する劣化傾向が表現されている.

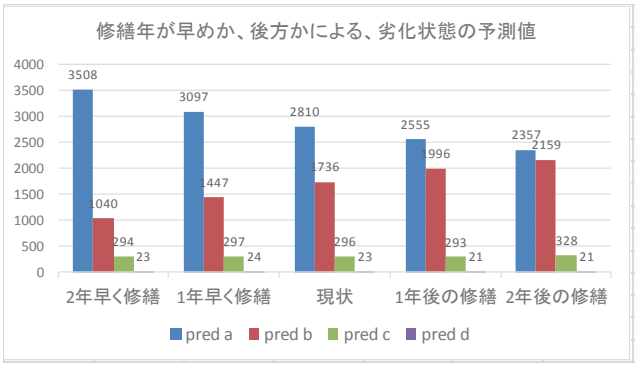


図 3 塗装修繕を早めるか遅くするかに対する劣化状態の予測

図 3 に,塗装修繕の年次を 1～2 年,早くするか,あるいは遅くするかに対して,劣化状態の予測値を算出した結果を図示した.早く修繕する場合に,b 判定の数が減少する代わりに a 判定の数が多い.予防的修繕は,劣化状態を加速させずに,回復するか延命して劣化にブレーキをかける状況が表現されている.一方,遅く修繕すると a 判定の数が減少し,b 判定の数が増加している.c 判定の劣化状態は,ほとんど変化がないものの,最も遅く 2 年後の修繕にした場合に限り,他の条件よりも劣化状態が増発する結果となっている.

4. おわりに

本稿では, インフラ劣化学習のために,管理者が定期的に収集する点検データを用いて,多クラスの劣化状態を判別するモデルを提案した.主桁鋼材腐食の精度は,GBM 82.49%, SVC 81.20%の評価を得た.床版 RC ひび割れの精度は,GBM 82.87%, DT 82.49%の評価を得た.レアな c,d 判定のデータ蓄積も進めば DT も迅速な計算ができて有望と言える.精度が 82%で頭打ちした理由は,目視点検データは人がラベルを貼った結果であり,判断のぶれや歪みのノイズが18%残ると解釈できる.この劣化学習のノイズを最小化する必要がある.さらに,GLM を基盤に,特徴変数の単位変化に対して,劣化クラス予測値の感度分析法を提案した.経年変化により劣化傾向が加速するか,あるいは,早めの予防修繕により劣化を減速できるか,または遅い事後修繕により劣化が増発する恐れがあるかの短期の劣化予測が可能となった.実際に,主桁-鋼材-腐食と床版-RC-ひび割れの２つの点検データを対象に,a,b,c,d の 4 クラスの判別モデルを劣化学習し,各モデルの計算結果から精度と計算時間を比較した.

今後の課題に言及する.本稿では,提案したインフラ劣化学習のモデルを橋梁の主桁-鋼材-腐食及び床版-RC-ひび割れの一定期間のデータセットに適用し,GBM,SVC,DT の 3 つの有望なモデルが得られた.今後,橋脚や支承等の異なる部材に応用範囲を広げることが可能と考える.他のインフラ施設においても鋼製腐食やコンクリートひび割れは,頻繁に現れる.今後,オンラインの連続監視とデータマイニングの機会を捉え,早期劣化や施工品質等の異常なクラスの検知を含めて,インフラ劣化学習モデルの実用新案に挑戦する.現状では,近接目視の判定は,損傷画像に着目し点検士が 5 段階のラベルを貼っている.CV の画像処理[Prince 2012] と転移学習[Geron 2017]を進めれば,劣化学習のノイズを縮小できると考える.今後,劣化学習モデルのバリエーション拡充と予測メンテナンスの資質向上と普及啓発に努めたい.

[謝辞]yec にて,インフラ劣化学習のプロトタイピングと技術研鑽の機会を得たことに感謝の意を表します.

参考文献

[日立 2014] 萩原正樹, 上松正史他: 社会インフラの維持効率を向上する施設モニタリングサービス, 社会インフラセキュリティ, Vol.96, No.3, pp190-191, 2014.

[土木学会 2017] 土木学会社会インフラメンテナンスシンポジウム, これからの社会インフラメンテナンスの技術戦略, 2017.1.

[COCN 2017] 産業競争力懇談会: インフラ維持管理アセットマネジメント, 2017.2.

[SIP 2017] 戦略的イノベーションプログラム SIP, (1)点検・モニタリング・診断技術, 2017.

[生嶋 2017] 生嶋健司他: コンクリート内部の鉄筋腐食検査装置の開発, SIP (1)6, 2017.

[佐古 2017] 佐古俊介他, 河川堤防の変状検知等モニタリングシステムの技術研究開発, SIP (1)30, 2017.

[MathWorks] MATLAB: 予知保全の解析技術, 予知保全のユーザー事例,予知保全システムの構築.

[Kaggle 2017] Kocaman, V.: Predictive Maintenance with GBoost, kaggle, 2017.

[Excel Templates] Maintenance Planning and Scheduling, Excel Templates for Plant Maintenance.

[McCullagh 1983] McCullagh, P. and Nelder, J.: *Generalized Linear Models*, Monographs on Statistics and Applied Probability, Chapman & Hall, 1983.

[Hardin 2012] Hardin, J.W. and Hilbe, J.M.: *Generalized Linear Models and Extensions 3rd edition*, Stata Press, 2012.

[Hastie 2009] Hastie, T., Tibshirani, R. and Friedman, J. : *The Elements of Statistical Learning ; Data Mining, Inference and Prediction*, 2nd edn. Springer, 2009.

[Efron 2016] Efron, B. and Hastie, T.: *Computer Age Statistical Inference: Algorithms, Evidence and Data Science*, Cambridge Univ. Press, 2016.

[Breiman 1998] Breiman, L.: Arcing Classifiers (discussion), *Annals of Statistics, 26*, pp.801-849, 1998.

[Breiman 2001] Breiman, L.: Random Forests, *Machine Learning, 45*, pp.5-32, 2001.

[Friedman 2001] Friedman, J.: Greedy Function Approximation: A Gradient Boosting Machine, *Annals of Statistics, 29(5)*, pp.1189-1232, 2001.

[Scholkopf 2012] Scholkopf, B. and Freund, Y.: *Boosting: Foundations and Algorithms*, MIT Press, 2012.

[Muller 2016] Muller, A.C. and Guido, S.: *Introduction to Machine Learning with Python: A Guide for Data Scientists*, O'Reilly, 2016.

[Cook 2016] Cook, D.: *Practical Machine Learning with H2O: Powerful, Scalable Techniques for Deep Learning and AI*, O'Reilly, 2016.

[Murphy 2012] Murphy, K.P.: *Machine Learning: A Probabilistic Perspective*, MIT Press, 2012.

[Hofmann 2014]Hofmann,M., Klinkenberg,R.: RAPID MINER: Data Minig Use Cases and Business Analytics Applications, *Data Mining and knowledge Discovery Series*, CRC, 2014.

[Prince 2012] Prince, S.J.D.: *Computer Vision: Models, Learning, and Inference*, Cambridge Univ. Press, 2012.

[Geron 2017] Geron, A.: *Hands-On Machine Learning with Scikit-Learn & TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*, O'Reilly, 2017.

[安野 2007] 安野貴人,SHM による劣化予測,コンクリート構造物のヘルスモニタリング,コンクリート技術 76,土木学会, 2007.

[安野 2007] 安野貴人他,土木構造物の維持管理と劣化進行のハザード形状,応用力学論文集 Vol.10, 2007.

[Yasuno 2010] Yasuno, T.: Neighbor-Park Management Method to Both Smoothen Long-run Budget and to Precaution Early-Deterioration Equipments, Social Management Systems, 2010.

[Yasuno 2018] Yasuno, T.: Dam Inflow Time Series Regression Models for Minimizing Loss of Hydro Power, *Data Mining for Energy Modeling and Optimization* (Forthcoming).

(2018.3.16)

[3Z2] [General Session] 13. AI Application

座長:井上 中順（東京工業大学）

Thu. Jun 7, 2018 3:50 PM - 5:30 PM Room Z (3F Matsu Take)

[3Z2-01] Mindful Driving:Analysis of the attention states during simulated driving using fNIRS

○Yusuke Fujiwara[1], Satoru Hiwa[2], Tomoyuki Hiroyasu[2] （1. Graduate School of Life and Medical Sciences, Doshisha University, 2. Faculty of Life and Medical Sciences, Doshisha University）

3:50 PM - 4:10 PM

[3Z2-02] Acceleration of Nonparametric Bayesian Double Articulation Analyzer

○Ryo Ozaki[1], Tadahiro Taniguchi[1] （1. Ritsumeikan University）

4:10 PM - 4:30 PM

[3Z2-03] Experimenal Images Identificaton with Simulation Images and Finetuning for Objects Identificaton of Ground Penetrating Radar Using Deep Learning

○Jun Sonoda[1], Tomoyuki Kimoto[2] （1. National Institute of Technology, Sendai College, 2. National Institute of Technology, Oita College）

4:30 PM - 4:50 PM

[3Z2-04] Efficiency of Traffic Flow with Mutual Concessions of Autonomous Cars Using Deep Q-Network

○Ichitaro Ogawa[1], Soichiro Yokoyama[1], Toyohasha Yanashita[1], Hidenori Kawamura[1], Akira Sakatoku[2], Tadashi Yanagihara[2], Tomohiko Ogishi[2], Hideaki Tanaka[2] （1. Hokkaido University, 2. KDDI Research Inc.）

4:50 PM - 5:10 PM

[3Z2-05] Fontender: A Method to Design Text by Font Fusion for Comic Creation

○Junki Saito[1], Satoshi Nakamura[1] （1. Meiji University）

5:10 PM - 5:30 PM

©The Japanese Society for Artificial Intelligence

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

マインドフル・ドライビング：fNIRSを用いた自動車運転中の注意状態の分析

Mindful Driving:Analysis of the attention states during simulated driving using fNIRS

藤原 侑亮 *1　日和 悟 *2　廣安 知之 *2
Yusuke FUJIWARA　Satoru HIWA　Tomoyuki HIROYASU

*1同志社大学大学院生命医科学研究科
Graduate School of Life and Medical Sciences, Doshisha University

*2同志社大学生命医科学部
Faculty of Life and Medical Sciences, Doshisha University

It is said that we are in a state of mind wandering for approximately 50% of the day. Mind wandering while driving sometimes cause traffic accidents. In order to perform mindful driving, our attention should be appropriately directed toward the objects surrounding the driver, but should not be captured by them. For that reason, it is important to detect mind wandering. In this study, drivers' mind wandering was defined from their behavior during simulated driving and their brain activity was measured and investigated using functional near-infrared spectroscopy (fNIRS). Fractional amplitude low-frequency fluctuation(fALFF) was used as an indicator of brain activity. From the results, mind wandering while driving can be detected by variations in the steering angle along with brain activity in the forehead.

1. 序論

近年，Well-being に注目が集まっている．Well-being とは，身体的，精神的，社会的に良好な状態であることを意味し，Well-being を実現するためには，マインドフルネスの概念が必要不可欠である．マインドフルネスとは，過去や未来にとらわれず現在の瞬間に意図的に非判断的な注意を向けることである．しかし，マインドフルネスと対極にあるマインドワンダリングは，過去の失敗などに意図せず注意を向けることで私たちの幸福感を低下させる．日常的にマインドフルな状態が期待されているが，その中でも，自動車運転時は運転と歩行者，道路標識などの対象物が多数存在することから，私たちは運転中において様々な対象に適切に意図的な注意を払い，またそれらに囚われない状態でいるべきである．そのため，マインドフルな状態で運転する必要があると考えられる．マインドフル・ドライビングにより，交通事故を削減し，運転をより楽しむことに貢献することが期待される．マインドフル・ドライビングのための重要な構成要素の一つは，マインドワンダリングを検出することである．ドライバが注意状態を知覚し，正しい対象へと注意を払うためには，ドライバの注意状態を評価し適切な方向へと導く運転支援システムが必要である．運転操作に必要な認知，判断，処理は脳内で行われることから，脳活動はドライバ状態を推定するための指標として広く用いられている．しかし，運転時のマインドワンダリング時の脳状態の変化は明らかにされていない [Baldwin 17]．そこで，本稿では運転時のマインドワンダリング状態を脳活動を用いて検出することを目的とした．シミュレータ環境下でドライバのマインドワンダリング状態を行動データから定義し，その時の脳活動を functional Near Infrared Spectroscopy（fNIRS）を用いて計測し，運転時のマインドワンダリング状態の脳活動を検討した．

2. 実験方法

2.1 実験概要

本実験では，ドライビングシミュレータ環境下でマインドワンダリングを誘発するために異なる二つの課題を同時に課す dual task を用いた．その時の脳活動を fNIRS で計測し，脳活動から運転時におけるマインドワンダリング状態を検討した．被験者は，運転免許を所有している健常男性 10 名（22.6 ± 1.4 歳，右利き）であった．fNIRS 装置はサンプリング周波数が 1.53Hz の OEG16（Spectratech 社製）を用いた．計測部位は前頭部 16CH で国際 10-20 法に従ってプローブを配置した．また，運転課題はドライビングシミュレータを用いて行った．

2.2 実験プロトコル

実験設計を図 **1** に示す．本実験はレスト 30s，タスク 480s，レスト 30s で構成される．dual task の主課題はドライビングシミュレータを用いた運転課題，副課題にはランダムな刺激に対して，可能な限り速く反応することで持続的注意を測定可能な Psychomotor Vigilance Task（PVT）を用いた．レスト区間では，ハンドルを握ったまま前方の画面を注視する．タスク区間では，運転課題としてオーバルコースでの運転を行う．また，運転中に PVT の音刺激がランダムな間隔で与えられ，その刺激に対してハンドル横に設置されたボタンプレスにより反応を示す．

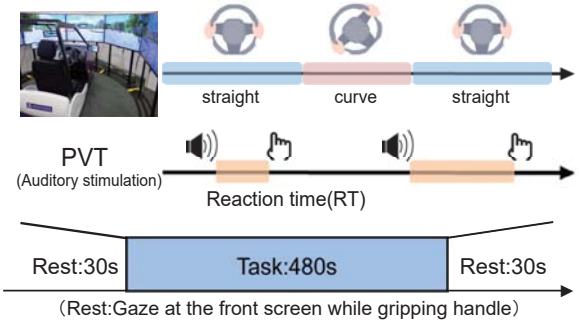


図 1: Experimental Design

3. 解析方法

3.1 行動データによる状態定義

今回行った dual task によって，被験者が PVT に注意を向けている時にはドライビングシミュレータ環境下でマインドワ

連絡先: 藤原侑亮，yfujiwara@mis.doshisha.ac.jp

ンダリング状態に陥っている可能性が考えられる．そこで，本実験では PVT で得られた反応時間（Reaction time:RT）から状態定義を行った．定義方法を図 **2** に示す．被験者毎に最も速い RT，最も遅い RT を算出し，その反応が行われた直前の区間をステアリング舵角変動と脳血流変化の解析対象区間として定めた．また，ステアリング舵角変化の指標として，変動係数を算出した．

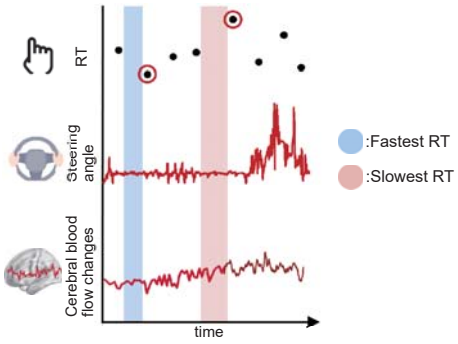


図 2: Definition of section by behavior data

3.2 脳活動の特徴量算出

fNIRS の計測チャンネルのすべては automatic anatomical labeling（AAL）に基づいて脳部位とは対応付けを行った．各チャンネルで得られた脳血流変化の時系列データから，脳活動の指標として fractional amplitude low-frequency fluctuation（fALFF）を算出した．fALFF は以下のように算出される．

$$fALFF(\text{低周波振動振幅}) = \frac{0.008 - 0.09[Hz] \text{ の振幅の和}}{\text{全周波数帯の振幅の和}}$$

fALFF は脳活動と考えられる周波数帯（0.008-0.09Hz）の振幅の和を測定された正の周波数帯で除算することで得られる [Zou 08]．周波数領域のデータに対して各チャンネルごとに fALFF を算出し，z 変換を行った（zfALFF）．各チャンネルの zfALFF は脳領域ごとに平均され，全被験者の脳領域ごとの zfALFF を算出した．

4. 結果・考察

最も速い RT と最も遅い RT の比較結果を図 **3** に示す．被験者毎に最も速い RT と最も遅い RT を算出し，比較を行った結果，有意水準 5%で有意差が見られた．このことから反応する直前の区間でドライバの状態が異なることが考えられる．速く反応するためには刺激呈示が行われるまで PVT に注意を向けることが必要となる．よって，RT が速い区間では本実験の主課題である運転課題でなく，副課題である PVT に注意が向いていたことから，マインドワンダリングしていた可能性が考えられる．また，RT が遅い区間では運転に注意が向いていることが考えられる．

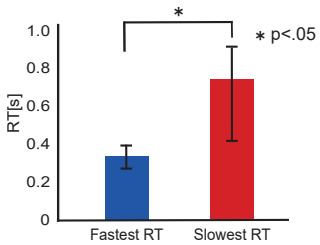


図 3: Comparison of RT

RT で定義した最も速い RT 区間と最も遅い RT 区間にあたるステアリング舵角変化と脳血流変化から算出した zfALFF の比較を行った．最も速い RT 区間と最も遅い RT 区間にあたる zfALFF のカラーマップを図 **4** に示す．最も速い RT 区間と最も遅い RT 区間で比較をお行った結果，最も速い RT 区間では，左中前頭回の zfALFF の値が有意に高かった（$p<0.05$）．左中前頭回は選択的注意に関係づけられ，注意対象を判断する時に活性化される [Hasenkamp 12]．また，自動車を走行コース内で安定して操作するためには，ある程度の舵角変動が必要と考えられるため，最も速い RT 区間における小さい舵角変動は，マインドワンダリングの傾向と推察される．一方，最も遅い RT 区間では，右上前頭回背側部の zfALFF の値が有意に高かった（$p<0.05$）．右上前頭回背側部は，注意の維持と転換時に活性化されることを報告している [Hasenkamp 12]．最も遅い RT 区間において舵角変動が大きいことから，この区間ではドライバは運転課題に注力していたことが考えられる．この推察は，注意維持に関連する右上前頭回背側部の高い zfALFF とも一致する．

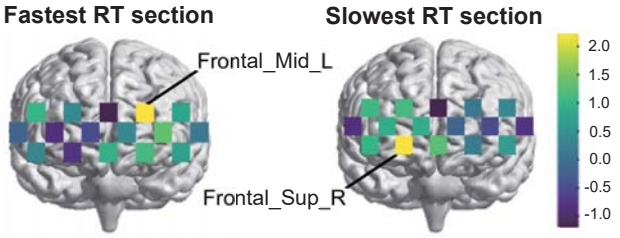


図 4: Colormap of zfALFF in section

5. 結論

本稿では，運転時のマインドワンダリング状態を検出するために運転課題を主課題、PVT を副課題とした dual task が用いられ，fNIRS によって脳血流変化が計測された．また，局所的自発性脳活動の指標として zfALFF が算出された．PVT における最も速い RT 区間では左中前頭回の zfALFF の値に有意差が見られ，最も遅い RT 区間では右上前頭回背側部の zfALFF の値に有意差が見られた．また．舵角の変動係数にも 2 区間で有意差が見られた．これらの実験結果は，運転時のマインドワンダリングがステアリング舵角変動と前頭部の脳活動を用いて検出でき得ることを示唆した．

参考文献

[Baldwin 17] Baldwin, C. L., Roberts, D. M., Barragan, D., Lee, J. D., Lerner, N., and Higgins, J. S.: Detecting and quantifying mind wandering during simulated driving, *Frontiers in human neuroscience*, Vol. 11, p. 406 (2017)

[Hasenkamp 12] Hasenkamp, W., Wilson-Mendenhall, C. D., Duncan, E., and Barsalou, L. W.: Mind wandering and attention during focused meditation: a fine-grained temporal analysis of fluctuating cognitive states, *Neuroimage*, Vol. 59, No. 1, pp. 750–760 (2012)

[Zou 08] Zou, Q.-H., Zhu, C.-Z., Yang, Y., Zuo, X.-N., Long, X.-Y., Cao, Q.-J., Wang, Y.-F., and Zang, Y.-F.: An improved approach to detection of amplitude of low-frequency fluctuation (ALFF) for resting-state fMRI: fractional ALFF, *Journal of neuroscience methods*, Vol. 172, No. 1, pp. 137–141 (2008)

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

ノンパラメトリックベイズ二重分節解析器の高速化に関する研究

Acceleration of Nonparametric Bayesian Double Articulation Analyzer

尾崎 僚 *1　　谷口 忠大 *1
Ozaki Ryo　　Taniguchi Tadahiro

*1立命館大学
Ritsumeikan University

In segmentation of time series data using unsupervised learning, it is important to pay attention to the structure of data. Nonparametric Bayesian double articulation analyzer (NPB-DAA) is a method of assuming only the double articulation structure and directly estimating the language model and the acoustic model from the acoustic feature. However, there are problems that conventional NPB-DAA spend a lot of time to analyze parameters, and only experiments using small speech data are performed. In this paper, we propose NPB-DAA with lookup table that introduced a lookup table to conventional NPB-DAA. Therefore, in this paper, we improved the speed of conventional NPB-DAA by introducing a lookup table in conventional NPB-DAA. In the experiment, we analyzed real speech that time length is about 1 minute 20 seconds and show that NPB-DAA with lookup table can estimate parameters 10 times faster than conventional NPB-DAA.

1. はじめに

幼児の語彙獲得の過程において，連続音声信号からの単語分割が重要なタスクであると知られている．また，人間の幼児は月齢 8ヶ月の段階において，音声信号を単語ごとに分割ができる [Saffran 26]．音声言語は，単独では意味を持たない音素と，音素の組み合わせによって意味を持つ単語を構成する二重分節構造を持つ．二重分節構造を持つ時系列データを解析する手法の一つに，谷口らの開発したノンパラメトリックベイズ二重分節解析器 (Nonparametric Bayesian Double Articulation Analyzer: NPB-DAA) がある [Taniguchi 16a]．[Taniguchi 16a] では，母音のみで構成された小規模な音声データの分節化が実現された．しかしながら，NPB-DAA は計算コストが非常に大きく，大規模な音声データの解析には非常に長い時間を要するという問題があった．

本研究では，NPB-DAA の高速化を図る．NPB-DAA の高速化の実現により，より大規模な音声データの解析が可能になることが期待される．NPB-DAA の計算コストが大きい理由として，同じ結果が得られる計算を何度も繰り返し計算していることが挙げられる．そこで，本研究では一度計算して求めた値をメモリに保存しておき，再計算のコストを省くルックアップテーブルを導入することで，NPB-DAA の高速化を実現する．本研究では，推論計算過程の効率化により，計算量オーダを 3 次オーダから 2 次オーダに削減し，実行時間を 90%削減した．

2. 先行研究

Taniguchi らは教示者による非分節な動作を，学習者が自律的に分節化し，模倣するための手法として二重分節解析器を提案した [Taniguchi 11]．この二重分節解析器は Sticky Hierarchical Dirichlet Process Hidden Markov Model (sticky HDP-HMM) と Nested Pitman-Yor Language Model (NPYLM) [Mochihashi 09] に基づく教師なし形態素解析器により構成される．しかしながら，sticky HDP-HMM と NPYLM の組み合わせによる二重分節解析器は，sticky HDP-HMM の認識誤りによって NPYLM の性能低下を引き起こすという問題があった．そこで，Taniguchi らは時系列データの離散符号列化と分節化のプロセスを統合した階層ディリクレ過程隠れ言語モデル (Hierarchical Dirichlet Process Hidden Language Model: HDP-HLM) と，そのパラメータの推論手法を導出し，これらによりノンパラメトリックベイズ二重分節解析器 (NPB-DAA) を提案した．また，母音のみで構成された小規模な音声データからの語彙獲得実験を行い，sticky HDP-HLM と NPYLM の組み合わせによる二重分節解析器と比べて，高い単語分割性能を示した [Taniguchi 16a]．

また，[Taniguchi 16b] では単語分割性能の向上を図るため，深層学習の一種である Deep Sparse Auto-encoder (DSAE) を用いて入力データを低次元化した特徴量を NPB-DAA の入力データとして扱った．Tada らは，子音も含めた音声データへの適用のため，動的特徴量を含めた特徴量の抽出方法を検討し，子音を含めた音声データからの教師なし語彙獲得を可能とした [Tada 17]．

しかしながら，NPB-DAA は，フレーム数を T，単語数の上限を N，1 単語の音素の最大数を L_{max}，1 単語の最大継続長を d_{max} としたとき，計算量が $\mathcal{O}(TN^2L_{max}d_{max}^3)$ と非常に大きい．実音声にして約 1 分 20 秒の音声データから得られた 3 次元・全 6311 フレームの特徴量からの教師なし語彙獲得に，Intel Xeon CPU E5-2630 v2 2.60GHz が 6 コア × 2CPU で構成された PC で 1 試行に約 2.7 時間必要であるため，音声認識の分野でよく用いられる TIMIT コーパス *1 といった大規模な音声データからの語彙獲得は行われてこなかった．そこで，本研究では NPB-DAA にルックアップテーブルを導入することで，NPB-DAA の高速化を実現する．

連絡先: 尾崎 僚，立命館大学 情報理工学研究科，滋賀県 草津市 野路東 1-1-1，ryo.ozaki@em.ci.ritsumei.ac.jp

*1 TIMIT Acoustic-Phonetic Continuous Speech Corpus: https://catalog.ldc.upenn.edu/ldc93s1

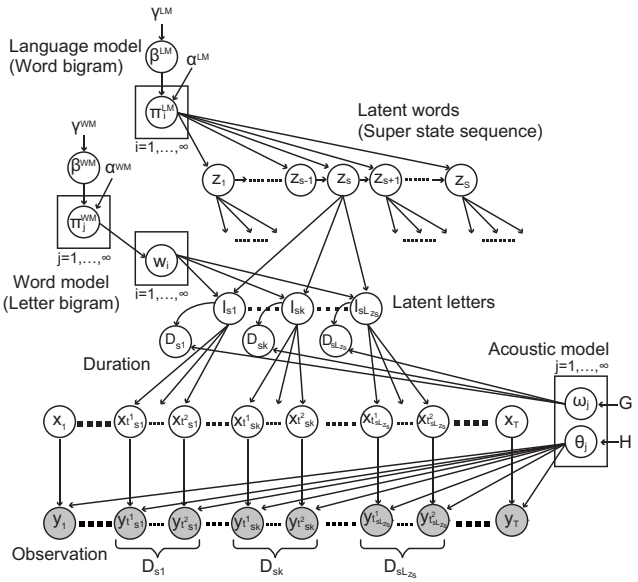


図 1: HDP-HLM のグラフィカルモデル [Taniguchi 16a]

3. NPB-DAA

3.1 階層ディリクレ過程隠れ言語モデル

HDP-HLM は，単語の生成確率を持つ言語モデル，文字列の生成確率を持つ単語モデル，音素信号列の生成確率を持つ音響モデルからなる生成モデルである．このモデルは，Matthew J らの提案した HDP-HSMM [Johnson 13] を拡張し，二重分節構造を含む系列データへの適用を可能としたモデルである．図 1 に HDP-HLM のグラフィカルモデルを示す．その他，生成過程等については， [Taniguchi 16a] を参照されたい．

3.2 ノンパラメトリックベイズ二重分節解析器

HDP-HLM のパラメータ推論手法として，NPB-DAA ではギブスサンプリングによるベイズ推定を行う．潜在変数のサンプリングでは，ブロック化ギブスサンプリングを用いる．また，潜在単語 w_i のサンプリングでは Sampling Importance Resampling (SIR) アルゴリズムを用いている．

3.2.1 潜在単語のサンプリング

潜在単語 z_s のサンプリングでは，HDP-HSMM の推論手法で用いられる backward filtering forward sampling の手続きを拡張して用いる．HDP-HLM における潜在単語 $z_s = i$ の backward message は下式で計算できる．

$$B_t(i) = \sum_j B^*_t(j) p(z_{s(t+1)} = j | z_{s(t)} = i) \quad (1)$$

$$B^*_t(i) = \sum_{d=1}^{T-t} B_{t+d}(i) p(D_{s(t+1)} = d | z_{s(t+1)} = i) \times p(y_{t+1:t+d} | i, d) \quad (2)$$

$$B_T(i) = 1 \quad (3)$$

ここで，$z_{s(t)}$ は時刻 t における潜在単語 z_s，$D_{s(t)}$ は時刻 t における潜在単語の持続時間を表す変数である．式 (2) における $p(y_{t+1:t+d}|i,d)$ は潜在単語 $z_s = i$ から観測系列 $y_{t+1:t+d}$ が得られる確率を表しており，潜在単語 $z_s = i$ の潜在音素列 w_i を $w_i = (l_1, l_2, \ldots, l_{L_i})$ と置くと，$p(y_{t+1:t+d}|i,d)$ は下式のようにして計算できる．

$$p(y_{t+1:t+d}|i,d) = \sum_{r \in R^{(L_i,d)}} \prod_{k=1}^{L_i} p(r_k|l_k) \times \prod_{m=1}^{r_k} p(y_{t+m+\sum_{k'=1}^{k-1} r_{k'}} | l_k) \quad (4)$$

$$R^{(L_i,d)} = \left\{ r \in \{1,2,\ldots\}^{L_i} \,\middle|\, \sum_{k=1}^{L_i} r_k = d \right\} \quad (5)$$

ここで，$R^{(L_i,d)}$ は L_i 次元で要素の和が d になるような自然数ベクトル r の集合を示す．式 (4) は動的計画法を用いて効率的に計算することができる．簡単のため，式 (4) の $y_{t+1:t+d}$ を $y_{1:T}$ と置き換えて考えると，下式によって再帰的に求められる．また，下式を forward message と定義する．

$$\alpha_t(k) = \sum_{d'=1}^{t-k+1} \alpha_{t-d'}(k-1) p(d'|l_k) \prod_{t'=1}^{d'} p(y_{t-t'+1}|l_k) \quad (6)$$

$$\alpha_0(0) = 1 \quad (7)$$

以上より，$B_t(i), B^*_t(i)$ を用いて，潜在単語 $z_{s(t+1)}$ および潜在単語 $z_{s(t+1)}$ の継続時間 $D_{s(t+1)}$ をサンプリングできる．詳しくは， [Taniguchi 16a] を参照されたい．

ここで，単語数を N，観測データ y の長さを T，単語の最大継続長を d_{max}，単語の最大音素数を L_{max} としたとき，forward message $\alpha_t(k)$ の計算量は式 (6) より $\mathcal{O}(L_{max} d^3_{max})$ である．また，backward message の計算量は $\mathcal{O}(TN^2 L_{max} d^3_{max})$ となる．

3.2.2 潜在単語の潜在音素列のサンプリング

同じ潜在単語の領域としてセグメント化された各領域を $y^{1:K} = \{y^1, y^2, \ldots, y^K\}$ としたとき，観測データ $y^{1:K}$ の生成モデルは HDP-HSMM とみなすことができる．そのため，推定された単語の潜在音素のサンプリングでは HDP-HSMM を用いる．しかし，HDP-HSMM における潜在音素のサンプリングは確率的であるため，同じ潜在単語としてセグメント化された観測系列 $y^{1:K}$ の潜在音素列が同じになるとは限らない．そのため，SIR に基づいた推定手順を導入する．$y^{1:K}$ における観測データに同じ潜在音素列を共有させるため，各観測データ $y^{1:K}$ からの潜在音素列 w の事後確率 $p(w|y^{1:K})$ は下式のように定義される．

$$p(w|y^{1:K}) \propto p(w) p(y^{1:K}|w) \quad (8)$$

$$= p(w|y^j) p(y^j) \prod_{i \neq j}^{K} p(y^i|w) \quad (9)$$

ここで，$p(y^j)$ は観測データの尤度を表しており，HDP-HSMM を用いて容易に求められる．$p(y^j|w)$ は式 (4) と同じ手順で求められる．また，$p(w|y^j)$ の推定も HDP-HSMM によって行うことができる．以上より，$p(w|y^j)$ を提案分布，$p(y^j) \prod_{i \neq j}^{K} p(y^i|w)$ を重みとして考えることで，SIR と同様の方法でサンプリングが可能となる．

ここで，同じ単語としてセグメント化された領域の数を K，提案分布から得られた音素列の最大音素数を L_{max}，単語の最大継続長を d_{max} としたとき，SIR の計算量は $\mathcal{O}(L_{max} d^3_{max} K^2)$ となる．

3.2.3 HDP-HLM のパラメータ更新

各観測データに対応した潜在単語列と潜在単語に対応した音素列がそれぞれサンプリングされた後，π^{LM} 等の言語モデルの各パラメータを潜在単語列に基づいて更新する．同様に，単語モデルの各パラメータについても潜在音素列に基づいて更新する．音響モデルのパラメータについては，それぞれの観測データ y_t によって決定された隠れ状態 x_t から更新する．

4. NPB-DAA with lookup table

4.1 尤度計算におけるメッセージ計算

従来の NPB-DAA では，潜在音素列 $w_i = (l_1, l_2, \ldots, l_{L_i})$ から観測 $y_{1:T}$ が得られる確率を forward message を用いて計算していた．この時，式 (6) の $\alpha_{t-d'}(k-1)$，$p(r_k = d'|\omega_{l_k})$，$\prod_{t'=1}^{d'} p(y_{t-t'+1}|\theta_{l_k})$ を $d' = 1$ から $d' = t-k+1$ まで縦に並べたような列ベクトルを $\mathbb{A}_t^k$，$\mathbb{D}_t^k$，$\mathbb{L}_t^k$ と置く．

$$\mathbb{A}_t^k = \left[\begin{array}{ccc} \alpha_{t-1}(k-1) & \cdots & \alpha_{k-1}(k-1) \end{array} \right]^T \quad (10)$$

$$\mathbb{D}_t^k = \left[\begin{array}{ccc} p(1|\omega_{l_k}) & \cdots & p(t-k+1|\omega_{l_k}) \end{array} \right]^T \quad (11)$$

$$\mathbb{L}_t^k = \left[\begin{array}{ccc} p(y_t|\theta_{l_k}) & \cdots & \prod_{t'=1}^{t-k+1} p(y_{t-t'+1}|\theta_{l_k}) \end{array} \right]^T \quad (12)$$

この時，式 (6) は下式で表せる．

$$\alpha_t(k) = \left[\begin{array}{ccc} 1 & \cdots & 1 \end{array} \right] \cdot \left(\mathbb{A}_t^k \circ \mathbb{D}_t^k \circ \mathbb{L}_t^k \right) \quad (13)$$

$$(14)$$

ここで，演算子 $\circ$ は要素毎の積を表す．また，演算子 $\cdot$ は内積演算を表す．この時 $\alpha_{t+1}(k)$ は，下式で表される．

$$\alpha_{t+1}(k) = \left[\begin{array}{ccc} 1 & \cdots & 1 \end{array} \right] \cdot \left(\mathbb{A}_{t+1}^k \circ \mathbb{D}_{t+1}^k \circ \mathbb{L}_{t+1}^k \right) \quad (15)$$

ここで，$\mathbb{A}_{t+1}^k, \mathbb{D}_{t+1}^k, \mathbb{L}_{t+1}^k$ それぞれに注目すると，

$$\mathbb{A}_{t+1}^k = \left[\begin{array}{c} \alpha_t(k-1) \\ \mathbb{A}_t^k \end{array} \right] \quad (16)$$

$$\mathbb{D}_{t+1}^k = \left[\begin{array}{c} \mathbb{D}_t^k \\ p(t-k+2|\omega_{l_k}) \end{array} \right] \quad (17)$$

$$\mathbb{L}_{t+1}^k = p(y_{t+1}|\theta_{l_k}) \left[\begin{array}{c} 1 \\ \mathbb{L}_t^k \end{array} \right] \quad (18)$$

より，それぞれ $\alpha_t(k)$ の計算で求めた $\mathbb{A}_t^k, \mathbb{D}_t^k, \mathbb{L}_t^k$ を再利用できる．

よって，従来は forward message の計算量が $\mathcal{O}(L_{max} d_{max}^3)$ であったのに対し，計算量を $\mathcal{O}(L_{max} d_{max}^2)$ に削減できる．

4.2 SIR の重み計算

潜在音素列 w のサンプリングでは，SIR が用いられており，式 (9) と定義されている．この時，各観測系列 $y^{1:K}$ から提案分布を用いてサンプリングされた w の候補をそれぞれ $\overline{w}^{1:K}$ とする．また，それぞれの候補 $\overline{w}^{1:K}$ の重みは下式で求められた．この時，$p(y^i|\overline{w}^j)$ を $\mathbb{W}_{j,i}$ と置き，$\mathbb{W}_{j,i}$ を $i, j = 1, \ldots, K$ まで並べた行列を $\mathbb{W}$ と置く．

$$\mathrm{weight}(\overline{w}^j) = p(y^j) \prod_{i \neq j}^{K} \mathbb{W}_{j,i} \quad (19)$$

$$\mathbb{W}_{j,i} = p(y^i|\overline{w}^j) \quad (20)$$

$$\mathbb{W} = \left[\begin{array}{ccc} \mathbb{W}_{1,1} & \cdots & \mathbb{W}_{1,K} \\ \vdots & \ddots & \vdots \\ \mathbb{W}_{K,1} & \cdots & \mathbb{W}_{K,K} \end{array} \right] \quad (21)$$

ここで，$\mathbb{W}_{j,i}$ の各要素はそれぞれ (6) の再帰式によって求められる．また，行列 $\mathbb{W}$ において，重み計算に用いられる要素は $i \neq j$ の時のみであるため，行列 $\mathbb{W}$ のうち計算が必要な要素数は $K(K-1)$ 個である．しかし，候補 $\overline{w}^a$ と $\overline{w}^b$ が同じ音素列であった時，それぞれの重みは

$$\mathrm{weight}(\overline{w}^a) = p(y^a) \mathbb{W}_{a,b} \prod_{i \neq a,b}^{K} \mathbb{W}_{a,i} \quad (22)$$

$$\mathrm{weight}(\overline{w}^b) = p(y^b) \mathbb{W}_{b,a} \prod_{i \neq a,b}^{K} \mathbb{W}_{b,i} \quad (23)$$

として求められる．また，$\overline{w}^a = \overline{w}^b$ より $\prod_{i \neq a,b}^{K} \mathbb{W}_{a,i} = \prod_{i \neq a,b}^{K} \mathbb{W}_{b,i}$ となるため，計算結果を再利用できる．これにより，従来は計算回数が $K(K-1)$ 回であったのに対して，$\overline{w}^{1:K}$ のうち重複しないものの個数を n 個，重複するものの種類の数を u 個とすると，計算回数を $n(K-1)+uK$ 回まで削減できる．

よって，forward message の計算量を $\mathcal{O}(L_{max} d_{max}^2)$ としたとき，従来では計算量が $\mathcal{O}(L_{max} d_{max}^2 K^2)$ であったのに対し，計算量を $\mathcal{O}(L_{max} d_{max}^2 K(n+u))$ に削減できる．

5. 実行時間の比較実験

本実験では，従来の NPB-DAA と NPB-DAA with lookup table を用いて，実行時間の比較を行う．また，本実験で用いた NPB-DAA with lookup table のソースコードは GitHub[*2] に公開した．

5.1 実験条件

実験に用いるデータは，母音のみで構成された，実音声にして約 1 分 20 秒程度の音声データから抽出された，全 6311 フレームの 3 次元の特徴量を用いる．

また，本実験は Intel Xeon CPU E5-2630 v2 2.60GHz が 6 コア × 2CPU で構成された計算機を用いる．本実験では，weak-limit 近似における最大単語数および最大音素数をそれぞれ 10 個とした．

上記の条件において，ギブスサンプリング 100 イテレーションを 1 試行とし，NPB-DAA および NPB-DAA with lookup table それぞれ独立に 20 回試行する．

5.2 実験結果

表 1 に NPB-DAA および NPB-DAA with lookup table の実行時間の平均および最大値と最小値をそれぞれ示す．表 1 より，NPB-DAA と NPB-DAA with lookup table を比較すると，実行時間を約 90%削減できていることが確認できる．

*2 https://github.com/EmergentSystemLabStudent/NPB_DAA/tree/ozakiDevelop

表 1: 実行時間の比較

Method		Execution time[sec] iteration	trial
NPB-DAA with lookup table	MIN	**2.8**	**732.2**
	AVG	8.7	869.3
	MAX	18.9	1136.1
NPB-DAA	MIN	36.7	6237.6
	AVG	98.7	9869.8
	MAX	310.9	13417.7

表 2: 単語数上限の変化に伴う実行時間の変化

Method		Execution time per trial[sec] Maximum number of words 10	20	30
NPB-DAA with lookup table	MIN	**732.2**	**1365.5**	**2247.4**
	AVG	869.3	1652.8	2464.3
	MAX	1136.1	1897.4	2678.0
NPB-DAA	MIN	6237.6	15704.3	22596.3
	AVG	9869.8	16316.6	24757.9
	MAX	13417.7	17211.9	26286.0

表 3: 音素数上限の変化に伴う実行時間の変化

Method		Execution time per trial[sec] Maximum number of letters 10	20	30
NPB-DAA with lookup table	MIN	**732.2**	**739.2**	**885.3**
	AVG	869.3	992.1	1003.5
	MAX	1136.1	1158.7	1145.6
NPB-DAA	MIN	6237.6	9151.9	9871.0
	AVG	9869.8	10285.2	10435.5
	MAX	13417.7	11804.6	11064.9

次に，weak-limit 近似における単語数および音素数の上限値の変化による実行時間の変化を調査するため，単語数上限および音素数上限をそれぞれ 20 個・30 個と変化させたものをそれぞれ 3 試行ずつ計測した結果を表 2 および表 3 に示す．表 2 より，単語数上限の変化に対して，NPB-DAA および NPB-DAA with lookup table ともに大きな増加傾向が確認された．表 3 より，音素数上限の変化に対して，NPB-DAA および NPB-DAA with lookup table ともに比較的小さな増加傾向がみられた．表 2 および表 3 より，NPB-DAA と NPB-DAA with lookup table を比較すると，実行時間を約 90%削減できていることが確認できる．

6. まとめ

本研究では，NPB-DAA にルックアップテーブルを導入した NPB-DAA with lookup table を提案し，実行時間の削減を行った．ルックアップテーブルの導入により，従来は計算量が $\mathcal{O}(TN^2L_{max}d_{max}^3)$ であったのに対し，計算量を $\mathcal{O}(TN^2L_{max}d_{max}^2)$ に削減できた．また，実時間において実行時間を約 90%削減できているを確認した．今後の方針として，TIMIT コーパスを用いた教師なし語彙獲得を行い，NPB-DAA with lookup table の性能調査等を行う．また，現状の NPB-DAA および NPB-DAA with lookup table はバージョンの古いライブラリに強く依存しており，移植性が低いことが問題点として挙げられる．そのため，より広く NPB-DAA を用いてもらうため，各種ライブラリのバージョンアップと整理が今後の課題である．

参考文献

[Johnson 13] Johnson, Matthew J. and Willsky, Alan S.: Bayesian Nonparametric Hidden Semi-Markov Models, Journal of Machine Learning Research, Vol.14, pp.673–701, Feb.2013

[Mochihashi 09] Daichi Mochihashi, Takeshi Yamada and Naonori Ueda: Bayesian Unsupervised Word Segmentation with Nested Pitman-Yor Language Modeling, Proceedings of the Joint Conference of the 47th Annual Meeting of the ACL and the 4th International Joint Conference on Natural Language Processing of the AFNLP: Volume 1 - Volume 1, pp.100–108, 2009

[Saffran 26] Saffran, Jenny R., Aslin, Richard N. and Newport, Elissa L.: Statistical Learning by 8-Month-Old Infants, American Association for the Advancement of Science, Vol.274, No.5294, pp.1926–1928, 1996.

[Tada 17] 多田 裕貴，幸 優佑，林　楓，萩原 良信，谷口 忠大: ノンパラメトリックベイズ二重分節解析器の TIDIGITS コーパスへの適用, The 31st Annual Conference of the Japanese Society for Artificial Intelligence, 2017

[Taniguchi 11] Tadahiro Taniguchi and Shogo Nagasaka: Double articulation analyzer for unsegmented human motion using Pitman-Yor language model and infinite hidden Markov model, 2011 IEEE/SICE International Symposium on System Integration, pp.250–255, Dec.2011

[Taniguchi 16a] Tadahiro Taniguchi, Shogo Nagasaka and Ryo Nakashima: Nonparametric Bayesian Double Articulation Analyzer for Direct Language Acquisition From Continuous Speech Signals, IEEE Transactions on Cognitive and Developmental Systems, Vol.8, No.3, pp.171–185, Sep.2016

[Taniguchi 16b] Tadahiro Taniguchi, Ryo Nakashima, Hailong Liu and Shogo Nagasaka: Double articulation analyzer with deep sparse autoencoder for unsupervised word discovery from speech signals, Advanced Robotics, Vol.30, No.11–12, pp.770–783, Apr.2016

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

ディープラーニングによる地中レーダの物体識別における シミュレーション画像と転移学習による実験画像の識別

Experimenal Images Identificaton with Simulation Images and Finetuning for Objects Identificaton of Ground Penetrating Radar Using Deep Learning

園田　潤 *1　　木本　智幸 *2
Jun Sonoda　　Tomoyuki Kimoto

*1仙台高等専門学校
National Institute of Technology, Sendai College

*2大分工業高等専門学校
National Institute of Technology, Oita College

In this study, to automatically detect underground objects from the ground penetrating radar (GPR) images by the deep neural network (DNN), we have generated GPR images for training the DNN using a fast finite-difference time-domain (FDTD) simulation with graphics processing units (GPUs). Also we have obtained characteristics of underground objects using the generated GPR images with a convolutional neural network (CNN) and finetuning using a modified VGG16 trained by the ImageNet. It is shown that the CNN and the VGG16 can identify four materials of experimental GPR images roughly 75 % and 80 % accuracy, respectively.

1. はじめに

2011 年の東日本大震災では現在でも 2546 名が行方不明者であり，警察やボランティア等が捜索活動を継続している．我々は，東日本大震災後の行方不明者捜索に地中レーダを使用しており [1]，地中物体を効率的に検出できるようになっているが，物体の種類や大きさの識別が困難な問題があった．また現在，トンネルや道路など社会インフラ劣化が問題になっており，このような社会インフラ点検にも地中レーダが有効であるが，同様に地中レーダ画像からの異常箇所の抽出は熟練技術者による判読であり，計算機による客観的な自動識別が必要である．

地中レーダ画像の物体識別では，手書き文字認識等の画像認識と同じように，ニューラルネットワークによる機械判定が研究されているが [2][3]，識別率のさらなる向上や，物体の有無だけなく材質や大きさの識別等のより高度な識別に課題があった．近年の計算機性能の向上とともにディープラーニングが注目されており，これらの課題を解決できる可能性があるが，実際の地中レーダ探査では多くの教師付学習データを用意するのは現実的に困難という問題があった．

我々はこれまでに，ディープラーニングで必要になる教師付学習用地中レーダ画像について，GPU を複数台使用する GPU クラスタを用いた FDTD 法により 100 万個程度を生成しており，生成した学習用地中レーダ画像を用いた畳み込みニューラルネットワーク CNN による物体識別特性を検討している [4]．この結果，CNN に一部 VGG[5] やドロップアウト構造等を導入したネットワークにより不均質な土壌においても地中物体の比誘電率や大きさを 80 %程度以上で識別できることを確認している [6]．

本稿では，これまでに確認している CNN を用いた FDTD シミュレーションによる地中レーダ画像の物体識別について，シミュレーション画像を用いた学習モデルによる実際の実験画像の識別を検討する．ここでは，ImageNet で学習済みの VGG16 を用いた転移学習の有効性について述べる．

連絡先: 園田　潤，独立行政法人国立高等専門学校機構 仙台高等専門学校，〒 989-3128 仙台市青葉区愛子中央 4-16-1，sonoda@sendai-nct.ac.jp　木本智幸，独立行政法人国立高等専門学校機構 大分工業高等専門学校，〒 870-0152，大分市牧 1666，kimoto@oita-ct.ac.jp

2. 学習・検証用地中レーダ画像の生成

地中レーダは，数百 MHz 帯の電波を地中に送信し，地中内の誘電率差で生じる反射波を地上で観測することで地中構造を推定するものである．実際の地中レーダでは，地中に大きさや材質が既知の物体を埋設して実験する必要があるため，教師付学習画像を生成するのは現実的には困難である．ここでは，学習用の教師付地中レーダ画像を FDTD 法による物理シミュレーションで生成し [4]，コンクリートブロックによるモデル実験により実際の地中レーダ画像の識別を検証するための実験画像を生成する．

図 1 にコンクリートブロックによるモデル実験の外観とパラメータを示す．モデル実験では，TDR で誘電率を測定した物体をブロック中に設置することで材質や大きさを制御できる．ここでは，深さ d に大きさ $w \times h = 6$ cm $\times\, \ell = 28$ cm の空洞，土，水をコンクリートブロック中に設置する．深さ d を 12, 18, 24 cm，幅 w を 7, 14, 21 cm と変化させ，900 MHz の地中レーダでレーダ画像を得る．モデル実験では，図 2 に示すような物体なしを含め 4 種類各 9 枚全 36 枚の地中レーダ画像が得られるが，枚数が少ないため左右に 2 枚ずつ平行移動することで 4 種類各 45 枚の全 180 枚の画像を生成する．一方，図 3 にモデル実験と同一モデルを用いた FDTD 法で生成したシミュレーションによる地中レーダ画像の例を示す．

3. シミュレーション画像と転移学習による地中レーダ画像の物体識別

図 3 の FDTD 法で生成したシミュレーションによる地中レーダ画像を図 4 の 5 層 CNN で学習させ，図 2 のモデル実

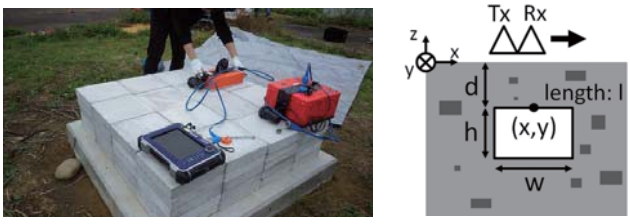
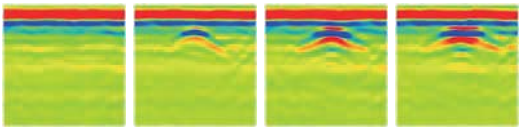
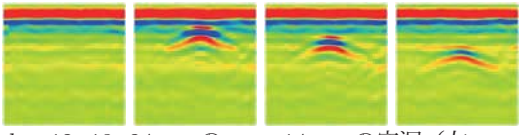


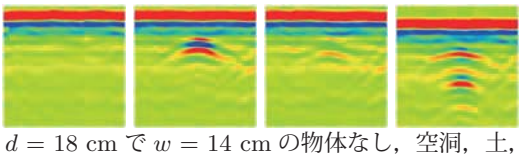
図 1: モデル実験とパラメータ



(a) $d = 12$ cm の $w = 0, 7, 14, 21$ cm の空洞

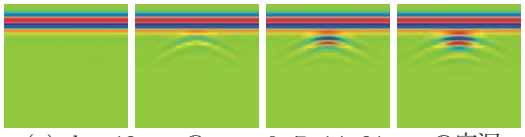


(b) $d = 12, 18, 24$ cm の $w = 14$ cm の空洞（左 $w = 0$）

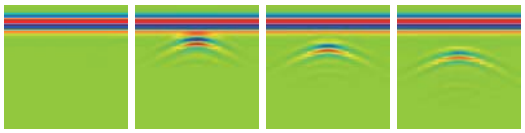


(c) $d = 18$ cm で $w = 14$ cm の物体なし，空洞，土，水

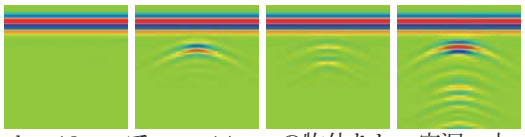
図 2: モデル実験によるレーダ画像の例@900 MHz



(a) $d = 12$ cm の $w = 0, 7, 14, 21$ cm の空洞



(b) $d = 12, 18, 24$ cm の $w = 14$ cm の空洞（左 $w = 0$）



(c) $d = 18$ cm で $w = 14$ cm の物体なし，空洞，土，水

図 3: シミュレーションによるレーダ画像の例

験で生成した地中レーダ画像の地中物体 4 種類の識別率を調べる．ここで，シミュレーションで生成した地中レーダ画像をランダムに各分類 1〜45 枚を学習させ，各分類 45 枚の実験画像の識別率を 20 回の試行の平均値により求める．ここでは，(1) 図 4 の 5 層 CNN とドロップアウト 0.5 の全結合層 2 層（転移学習なし），(2) ImageNet で学習済みの VGG16 を用いた転移学習の識別率を調べる．VGG16 は全結合層を 3 層（200 層+200 層+4 層）を追加し，200 層+200 層部分はドロップアウト 0.6 および Sigmoid 活性化関数を利用した．また，VGG16 の CNN 部分の結合荷重は，Imagenet を学習した結合荷重に転移学習を行った．

図 5 に学習した地中レーダ画像の枚数による地中物体 4 種類の材質の識別率を示す．この結果，(1) の転移学習なしの 5 層 CNN では各 45 枚の学習で識別率は 76 %であった．(2) の VGG16 による転移学習では 80 %に向上した．学習枚数による特性は図 5 より 10 枚程度で飽和しているが，いずれの学習枚数においても (2) の VGG16 の識別率は 5 %程度高いことが分かる．識別率が 80 %程度である理由は，図 2 に示したように土とコンクリートブロックの比誘電率差が小さいため反射波の振幅が小さくなり，物体なしと土の地中レーダ画像の類似度が高くなることから誤判定が生じるためである．一方，土を除いた物体なし，空洞，水の 3 種類での識別率は (1) で 90 %，

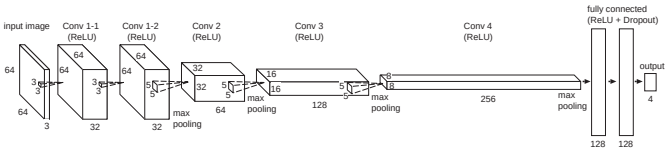


図 4: 学習と識別に使用する 5 層 CNN

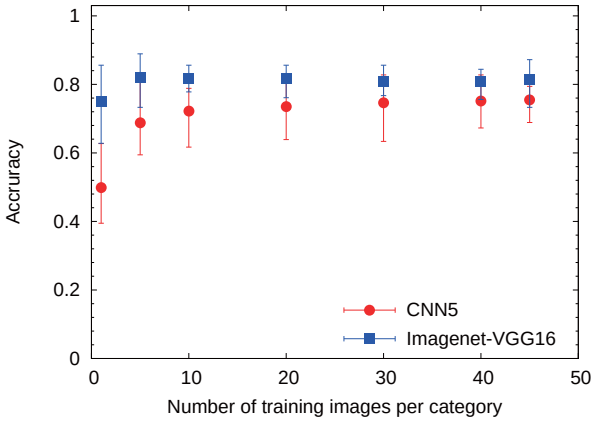


図 5: 地中物体の材質 4 種類の識別率

(2) で 92 %であった．土とコンクリートブロックのような周囲の媒質と対象物体の比誘電率差が小さい場合は，地中レーダの原理的に反射波が小さくなり識別率は低下するが，例えば，道路空洞調査のような問題では，空洞，水が入った空洞，その他の 3 分類程度でよい場合もあり，シミュレーションで生成した地中レーダ画像でも実際の地中レーダ画像を精度よく識別できる．シミュレーションで生成した地中レーダ画像が使用できれば，地中物体の大きさや形状等も自由に変えられるので，材質だけでなく大きさや形状の識別等も可能になる [6].

4. むすび

ディープラーニングよる地中レーダ画像の物体識別について，FDTD シミュレーションで生成した地中レーダ画像を学習させた場合の実験画像の識別について調べた．材質 4 種の地中物体の地中レーダ画像数十枚を学習させ実験画像を識別した結果，転移学習なしの 5 層 CNN では 75 %程度，ImageNet で学習済みの VGG16 を用いた転移学習では 80 %程度と 5 %程度向上した．今後は，震災不明者捜索等で実証実験を行う．

謝辞

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，科研費・基盤研究 (B) 15H02997 および基盤研究 (C) 17K00357 の支援による．

参考文献

[1] 園田，渡辺，米澤，金澤，信学技報 SANE, Nov. 2013.
[2] P. Gamba, et al., IEEE Geo. Remote Sens., 2000.
[3] T.Hara and A.Hirose, Neural Networks, 2004.
[4] 園田，木本，昆，信学総大 CS-2-4, 2016.
[5] K.Simonyan and A.Zisserman, arXiv:1409.1556.
[6] 園田，木本，信学技報 PRMU2017-91, 2017.

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

Deep Q-Networkを用いた自動運転車のゆずりあいによる交通流の効率化

Efficiency of Traffic Flow with Mutual Concessions of Autonomous Cars Using Deep Q-Network

小川一太郎 *1 Ichitaro Ogawa
横山想一郎 *1 Soichiro Yokoyama
山下倫央 *1 Tomohisha Yamashita
川村秀憲 *1 Hidenori Kawamura
酒徳哲 *2 Akira Sakatoku
柳原正 *2 Tadashi Yanagihara
大岸智彦 *2 Tomohiko Ogishi
田中英明 *2 Hideaki Tanaka

*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.
*2KDDI 総合研究所
KDDI Research Inc.

In recent years, the development of autonomous operation technology has been actively carried out in a various research institutions and companies. Many experiments are conducted in public road to confirm whether one autonomous car can drive safely. However, autonomous operation with inter-vehicle communication has not been much researched. In this paper, we implement mutual concessions of autonomous cars with Deep Q-Network (DQN), which is a deep neural network structure used for estimation of Q-value of the Q-learning method. To verify the effectiveness of mutual concessions, we develop an experiment environment for verification of autonomous operation with radio control (RC) cars. We implement mutual concessions of autonomous cars at the confluence in the roundabout. DQN is applied for the decision-making mechanism to decide velocity in the roundabout based on the position of others and the status of congestion. As a result of our experiment, we confirmed that the autonomous cars with DQN can realize high transfer efficiency in the roundabout.

1. はじめに

自動運転車が広く普及すると，人間が運転するために設計された現在の交通ルールが不適切な可能性がある．例えば合流時に優先車がいる場合，合流車は道を譲らなければならないが，自動運転車が優先車を決めれば待ち時間は発生しなくなるだろう．本研究では深層学習の一つである Deep Q-Network を使用して，自動運転車両同士が経路を譲り合ってもここの移動が阻害されることなく全体の効率を増加させることを目指す．

Deep Q-Network を導入できる自動運転システムアーキテクチャの開発を行った．本研究では自動運転車のみが多数存在している状況を想定して，交通流量を増加させることを目的としたシミュレーションを行う．ラジオコントロールカーを使用した物理シュミレーションを採用した．ラジオコントロールカーを使用した理由は，コンピュータ上の理想的な環境ではなくノイズなどの外乱が発生する状況で物理特性を再現可能であることと、実車両よりも非常に安価であるとこがあげられる．ラジオコントロールカーの制御を実現するため、行動をモジュール化することで層状に行動を決定するアーキテクチャを作成した．

本論文ではラウンドアバウトを含んだコースを作成し，ラウンドアバウト内の走行を Deep Q-Network で調整することで交通流量の増加方式を検討する．完成したシステムは日本の千葉県，幕張メッセで開催された CEATEC2017 の KDDI ブースにてビデオ中継で展示した．

2. 実験システム

ラジオコントロールカーを使用した交通流のシミュレーションシステムを作成した．現在 16 台までのラジオコントロールカーが走行可能である．ラジオコントロールカーは実際の自動車の 1/12 スケールであり図 1 に示している．16 台の走行のために 6m 四方のコースを作成した，図 2 に示している．全体のシステム構成を説明する．

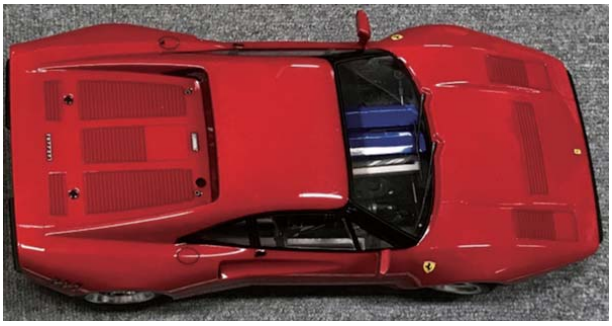


図 1: 1/12 スケール ラジオコントロールカー

2.1 ハードウェアの構成

ラジオコントロールカーにはそれぞれ RaspberryPi3 が取り付けられており，それを使用して制御する．ラジオコントロールカーの天井部には赤外線 (IR)LED が取り付けられており，位置認識と ID 認識に使用されている．上空に設置した赤外線カメラでラジオコントロールカーを含めたコース全体を撮影する．カメラ画像をイーサネットケーブル経由で PC に取り込み，画像中の IRLED による白色領域の重心位置を割り出す．検知した IRLED の座標に対してカメラ歪の補正，高さ補正を行い実座標の IRLED の位置に変換する．IRLED の位置関係からラジオコントロールカーの位置と方向，そして車 ID を求め，透視変換により実座標に変換する．

制御用 PC では車の位置情報から行動を決定する．計算される行動はセクション (ソフトウェアの構成) で解説する．計算された行動を WiFi 経由でラジオコントロールカーに搭載されている raspberrypi3 に送信する．RaspberryPi3 はラジオコントロールカーのサーボモーターと ESC を介したモーターにつながっており，PWM を使用してステアリング制御とアクセル制御を行う．走行時に制御用 PC で得られたデータをサー



図 2: 使用したコース

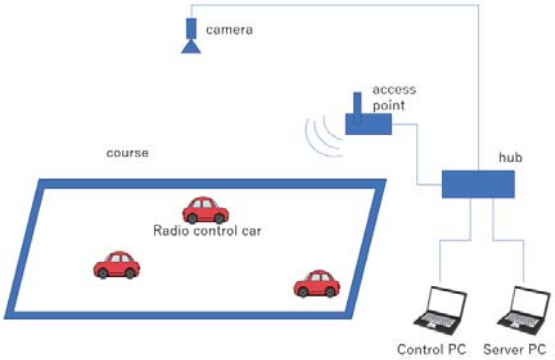


図 3: 装置の構成図

バー用 PC に送信し、MySQL 上に走行ログを保存する．走行データを使用してサーバー用 PC で NN の更新を行う．

装置の構成図を図 3 に示す．

2.2 ソフトウェアの構成

ラジオコントロールカーの走路をパスで表し bez 曲線で定義している．ラジオコントロールカーは自身が走行しているパスを参照でき，現在のパスが接続している次のパスも参照できるため経路選択を行いながら走行することができる．ラジオコントロールカーの位置と方向を得た後に，現在とその次のパスのうち最もラジオコントロールカーとの距離が近い点を走路中の現在位置として得る．ラジオコントロールカーの進行方向は現在位置から少し先の走路上のガイド点に向かって PID 制御を行うことで決定される．ラジオコントロールカー同士の協調行動は走行ラインに沿いながら速度を変化させることで実現している．速度は包括関係のモジュールで決められている．各モジュールを通して目標速度が求められた後，PID 制御で速度を調整する．以上の構成図を図 4 に示した．

2.3 Deep Q-Network による動作

以上のラジオコントロールカーの走行システムを使用して，Deep Q-Network を用いた行動制御を行う．Deep Q-Network を使用せずとも走行が可能なラジオコントロールカーの機能を、部分的に Deep Q-Network で置き換えることで実現する．各機能をモジュール化して置き換えることによって，部分的な判断を Deep Q-Network で行うことができ，ほかの機能に干渉しなくなる．今回はラウンドアバウト走行中の車の速度決定

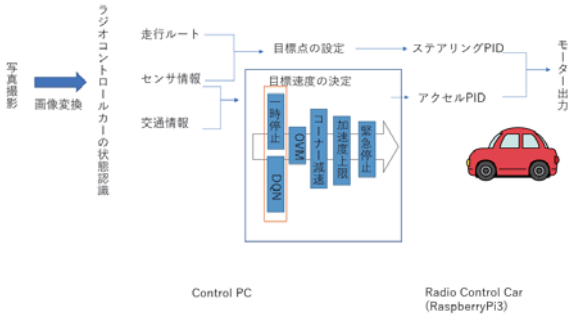


図 4: モーター値決定までの計算過程

モジュールのうちの一つとして Deep Q-Network を用いることで Deep Q-Network による推論は制御用 PC で行っている．学習はサーバー用 PC で行う．制御用 PC で集められた走行データはサーバー用 PC 中の MySQL に保存され，サーバー用 PC がそのデータを使用して学習を行う．サーバー用 PC で作成された NN のモデルを制御用 PC に送信し，更新することによって学習が完了となる．

2.4 Deep Q-Network

2.4.1 学習アルゴリズム

制御用 PC で得た走行データを，車ごとにサーバに送信する．サーバでは MySQL でデータを保存できるようになっており，システムの 1 ステップごとに「時刻，実験番号，車番号，データ番号，ログデータ」を保存する．DQN の学習はサーバ中のデータを使って行い，NN のモデルをアップデートすることで実現する．今回の研究ではラウンドアバウト内の車に対して，合流車がいる場合に速度調整をするという形で導入した．入力，出力に使用しているログデータ，報酬計算は表 1 に表した．NN のモデルは 10-10-10-10-3 である．活性化関数は

表 1: DQN が扱うデータ

種類	内容
入力	制御車の合流地点までの距離
	制御車の速度
	合流車の合流地点までの距離
	合流車の速度
	先行車と制御車の距離
	制御車の速度
	ラウンドアバウト内の車台数
	合流車の待ち台数
	コース全体の車台数
	車全体の平均速度
出力	高速 $0.65m/s$
	低速 $0.50m/s$
	停止 $0.00m/s$
報酬	全体の速度平均による加点
	停止が続いた時の減点
	緊急停止時の減点

ReLU，最適化関数は RMSProp.

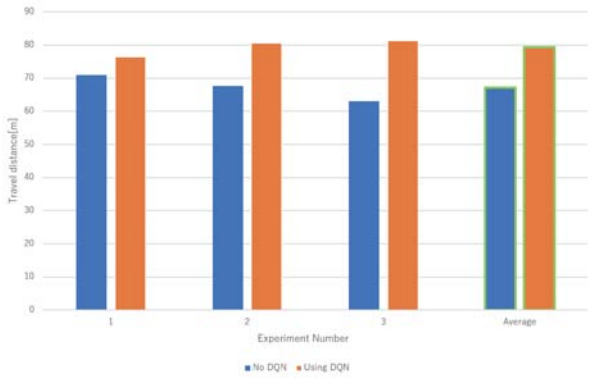


図 5: 実験結果 総走行距離

3. Deep Q-Network による走行

3.1 比較実験

公道の走行を再現した走行と，自動運転車のみの想定の走行を比較した．使用したコースは図 2 のようにラウンドアバウトと，その周辺の道路で構成されている．自動運転車のみの走行では道路ごとの優先順位を考慮せず，安全である限り前進を続ける走行である．この時，自動運転車のみの走行で，ラウンドアバウト内の速度調整を DQN を使用して行った．使用した学習データは 227,358 個で，ランダムサンプリングで 100 データを抜き出し，10 万回の学習を行った．比較の走行は 12 台同時走行で 3 回ずつ行った．1 回の走行で 5 分間走行を行い，後半 4 分間のデータのみを使用している．結果は表 5 に示した．２つの結果を比較すると自動運転車のみの走行のほうが交通流量が多くなっていた．

4. おわりに

本研究では，自動運転車のためのシミュレータを，ラジオコントロールカーを使用して作成した．DQN を使用して自動運転車の速度制御を行うことで交通流量の増加が見込めるか検証を行った．特にラウンドアバウトの合流時の速度調整を行うことで，交通流の増加が見込める結果となった．今回使用したシミュレータは一車線の走行が前提となり，走行ルートにある程度の制限がある．そのため今後の課題は，車線変更が行えるように拡張し走行経路を変更できるように拡張することであると考えている．

参考文献

[1] Satoshi Suzuki. and Keiichi Abe., Topological Structural Analysis of Digitized Binary Images by Border Following, CVGIP 30 1, pp 32-46 (1985)

[2] Zhengyou Zhang., A flexible new technique for camera calibration, IEEE Transactions on Pattern Analysis and Machine Intelligence, 22(11):1330-1334, 2000.

[3] Volodymyr Mnih. Koray Kavukcoglu. David Silver. et al. : Human-level control through deep reinforcement learning, Nature, Vol. 518, issue 7540, pp. 529-533, (2015)

[4] M. Bando, K. Hasebe, A. Nakayama, A. Shibata, and Y. Sugiyama, Jpn. J. Ind. Appl. Math. 11, 203 (1994).

[5] M. Bando, K. Hasebe, A. Nakayama, A. Shibata, and Y. Sugiyama, Phys. Rev. E 51, 1035 (1995).

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

Fontender: コミック創作のためのフォント融合による文字デザイン手法

Fontender: A Method to Design Text by Font Fusion for Comic Creation

斉藤絢基[*1]
Junki Saito

中村聡史[*1]
Satoshi Nakamura

[*1] 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

Comics consist of panels, drawn images, speech balloons, text, and so on. In this work, we focused on the difficulty to design text which used for the narration and quotes of characters. In order to support creators to design text, we propose a method to design text by font fusion algorithm with arbitrary existing fonts. In this method, users can change font type freely by indicating a point ion the font map. In addition, we implement the prototype system and discuss the usefulness of our system.

1. はじめに

個人によるコミックの創作および発信が盛んになりつつあり，日本では MediBang[MediBang 18]や LINE マンガ[LINE 18]といった，個人が作成したコミックを手軽に配信することができるサービスが増えている．ここでコミックにおいては，キャラクタや背景などの作画や，吹き出しやコマ割りなどのデザインなどが重要であるが，それらに加えて，文字のデザインもコミックの完成度を大きく左右する重要な要素である．

コミックにおいて，登場人物のセリフやナレーションなどで用いられている文字を適切なデザインに仕上げることは，読者に物語の雰囲気やキャラクタの心理描写などを効果的に伝えることを可能にする．例えば，図 1 のようなガクガクしたフォントを使用することで恐怖感を増長させたり，かわいいという印象を与えるためにポップ体を使用したりといったものがあげられる．図1のように，同じ文字でも場面の状況によってデザインを変える必要があり，殺伐とした雰囲気を与えたい場合にかわいさを感じさせるフォントを用いると，コミック創作者が伝えたい場面の雰囲気が読者に伝わりにくくなってしまう．



恐怖感を与えるフォント　　かわいさを感じさせるフォント

©菅野博士『ばらいそロード』
(Manga109[Matsui 15])

図 1 フォントの違いによる印象の差

場面の雰囲気やキャラクタの性格に合わせた文字デザインを行う際，コミック創作者が所持するフォントからイメージに合うものを選定する必要がある．しかし，日本語フォントはその文字数の多さから，英語フォントに比べバリエーションが少なく，また高価であるため，その場にあった文字デザインをすることは容易ではない．

そこで我々は，任意の既存のフォントを組み合わせて新たなフォントを作り出せるようにすることで，その場その場にあった文字デザインシステムを実現する．ここでは，我々がこれまで提案してきたフォント融合アルゴリズム[斉藤 18]をもとに，フォントの組み合わせ度合いを自在に変化させることによって，新たなフォントを生成する手法を提案する．具体的には，ユーザが入力した 2 つの印象語を軸とした 2 次元平面上に既存のフォントを配置し，ユーザの選択した平面上の位置に応じて複数のフォントをブレンドして提示する．ユーザはこの手法を使用することにより，コミックの任意のシーンにマッチした文字のデザインを行うことができると期待される．本研究では，複数のフォントを任意に組み合わせ新たなフォントを獲得する手法を提案し，コミックで使用する文字のデザインを支援するプロトタイプシステムを実装する．

2. 関連研究

文字デザインを支援する研究としては，加納ら[加納 17]の研究が挙げられる．同研究では，オノマトペによる手書き文字の形状変換手法を提案し，コミックの物語を演出する際によく用いられるオノマトペの文字デザインを行っている．また佐藤ら[佐藤 16]は，ユーザの手書き文字を数式として表現し，そこにサイン波などの数式を付与することで，手軽にアニメーションを生成できる手法を提案し，生成したアニメーションを電子コミック上のセリフやオノマトペとして提示するシステムを実現している．これらの研究に対し，本研究は既存のフォントを変形することで，新たな字形を獲得するものである．

既存のフォントを変形し，新たな字形を獲得する研究はいくつか行われており，Suveeranont ら[Suveeranont 10]は，ユーザが手描きでスケッチした文字に任意のフォントを融合することで，新たなフォントを生成するシステムを提案している．しかし同システムは，スケッチした文字とフォントを融合する際，対応するストロークをユーザが調整する必要があった．これに対し，Campbell ら[Campbell 14]は，似た形状のフォント同士が近くなるように 2 次元平面上にフォントを配置することで，対応するストロークを自動で決定することを可能にする手法を提案している．しかし同手法では，融合可能なフォントの組み合わせが限定されてしまうという問題がある．本研究では，ユーザの負担をかけることなく，ユーザが求める印象に応じて既存のフォントを融合

連絡先：斉藤絢基，明治大学総合数理学部先端メディアサイエンス学科，東京都中野区中野 4 丁目 21-1，03-5343-8334，ev40577@meiji.ac.jp

し，新たなフォントを獲得できる手法を取ることで，一般ユーザの文字デザイン支援を行うものである．

3. Fontender

はじめにでも述べた通り，文字のデザインはコミックにおいて重要な要素の一つである．本研究では，この文字デザインにおいて，任意のフォントを組み合わせつつ自在な表現を可能とする．具体的には，ユーザが入力した 2 つの印象語を軸とした 2 次元平面上に，既存のフォントを配置し，ユーザの選択する平面上の位置によってブレンドするフォントの種類やブレンド割合が変化するというインタフェースを設計する．これにより，ユーザの求める直感的で微細な印象に合致したフォントを獲得できると期待される．

3.1 フォントのブレンド手法

我々は以前の研究[斉藤 18]で，フォントの芯線および太さの情報を数式として捉え，その数式同士を融合することでフォントのブレンドを実現した．ここでは，文字は半径の変化する円の軌跡によって表現できると仮定し，芯線上の点が中心座標となるような円の軌跡を描くことでフォントを表現する．

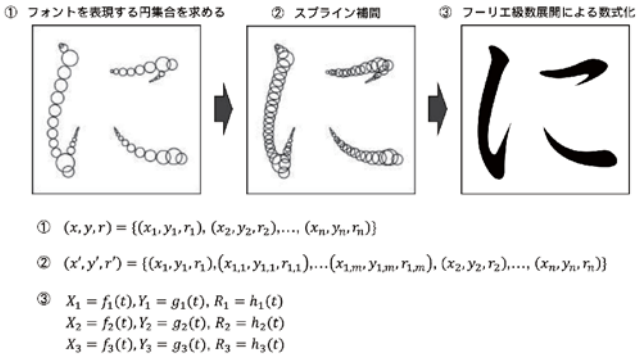


図 2 フォントの数式化の手順

具体的には，図 2 のように，まずフォントを描く円の集合を求め，次にフォントを滑らかに表現するため，得られた円の集合をできるだけ接続するように 3 次スプライン補間を行い，間を埋める円を生成する．その後，補間された円の中心座標を順に通る平面曲線の数式をフーリエ級数展開により求める．同図 2 のtにおける$(f(t), g(t))$がフォントの芯線上の点となり，その点からフォントで表示された文字の外縁に内接する点までの距離が太さ情報$h(t)$となる．

得られたフォントの各ストロークは，それぞれ$(x, y, \mathrm{r}) = (f(t), g(t), h(t))$のように$t$の式で表すことができる．ここでそれぞれのフォントのストロークの数式を

$$\begin{cases} x = f_i(t) \\ y = g_i(t) \\ \mathrm{r} = h_i(t) \end{cases} \quad -\pi \leq t \leq \pi$$

と表わし，N種類のフォントを任意の割合α_1 ～α_nで融合するとすると，ブレンドしたフォントのストロークの数式は

$$\begin{cases} x = \sum_{i=1}^{N} \alpha_i f_i(t) \\ y = \sum_{i=1}^{N} \alpha_i g_i(t) \\ r = \sum_{i=1}^{N} \alpha_i h_i(t) \end{cases} \qquad \sum_{i=1}^{N} \alpha_i = 1$$

と表わすことができる．このブレンド割合を変更することで，任意のフォントを作り出すことが可能となる．

3.2 フォントに対する印象推定

Fontender では，フォントの印象語を入力として使用可能とするため，既存のフォントの印象値および人に与える印象の因子構造を求める必要がある．

印象値および印象の因子構造を求めるため，実験協力者 17 名（20～23 歳の大学生）に対し，フォントに対する印象評価を行ってもらった．評価するフォントは図 3 に示す合計 18 種類を使用した．印象評価については，和文フォントの印象調査 [井上 84][井上 85]で使用された形容詞対の中から35対を選定し，SD 法による 7 段階評定（-3～+3）で評価を行なってもらった．

得られたデータから，どのような印象構造が形成されるのかを確認するために，全 18 種類のフォントに対して，主因子法，プロマクス回転による因子分析を行った．共通性が 0.35 を下回った形容詞対や，複数の因子に付加する形容詞対を除外する手続きを行い，最終的に 18 形容詞対，4 因子が抽出された（表 1）．第 1 因子は，「やわらかい」「丸い」などの項目に正の負荷があるほか，「はっきりした」「緊張した」などの項目に負の負荷が高いことから，「柔和性因子」と命名した．また，第 2 因子は「良い」「快い」「好き」「美しい」の全てにおいて，高い正の負荷が見られることから，「魅力性因子」と命名した．同様に，第 3 因子は「楽しい」「明るい」に高い正の負荷が見られることから，「楽観性因子」，第 4 因子は「迫力のある」「派手な」に高い正の負荷が見られることから，「活動性因子」とそれぞれ命名した．これら 4 因子における累積寄与率は 67.1%であった．なお，4 章にて説明



図 3 評価対象フォント一覧

表 1 因子分析結果

因子名	形容詞対	因子1	因子2	因子3	因子4	共通性
柔和性	かたい-やわらかい	**0.873**	0.223	0.125	-0.059	0.809
	四角い-丸い	**0.864**	0.239	0.026	0.004	0.717
	ぼんやりした-はっきりした	**-0.852**	0.030	0.255	0.172	0.628
	緩んだ-緊張した	**-0.852**	-0.065	-0.048	0.000	0.735
	フォーマルな-カジュアルな	**0.805**	-0.029	0.024	0.084	0.717
	鋭い-鈍い	**0.695**	-0.052	-0.016	-0.064	0.481
	冷たい-暖かい	**0.681**	0.209	0.202	0.008	0.613
	模倣的な-独創的な	**0.669**	0.132	-0.046	0.232	0.632
	不安定な-安定した	**-0.659**	0.263	0.181	-0.086	0.623
	大人っぽい-子供っぽい	**0.654**	-0.311	0.228	-0.082	0.696
魅力性	悪い-良い	0.116	**0.905**	-0.105	0.027	0.682
	不快な-快い	0.127	**0.869**	0.000	-0.077	0.736
	嫌い-好き	0.111	**0.857**	0.040	0.099	0.720
	醜い-美しい	-0.201	**0.703**	0.015	-0.001	0.620
楽観性	苦しい-楽しい	0.128	-0.048	**0.817**	-0.031	0.719
	暗い-明るい	0.060	0.008	**0.777**	0.026	0.655
活動性	もの足りない-迫力のある	-0.131	0.110	-0.051	**0.847**	0.658
	地味な-派手な	0.125	-0.089	0.053	**0.746**	0.670
	寄与率(%)	33.3	17.6	8.4	7.8	
	累積寄与率(%)				67.1	

するプロトタイプシステムは，因子分析にて抽出された 4 つの因子と，18 種類の形容詞対を指定可能とするものである．

4. プロトタイプシステム

4.1 実装

コミックの一部に対して文字デザイン支援のためのプロトタイプシステムを実装した（図 4）．本システムは，大きく分けると成形部と選定部の 2 つの部分からなり，選定部でフォントのブレンドを行い，ブレンド結果を成形部でプレビューするというものである．なお，本システムは Processing にて実装した．

提案システムでは，まず成形部に画像を読み込み，次にユーザが入力した 2 つの印象語をもとに，2 次元平面上に既存のフォントを配置する．ここで，4 章の因子分析で得られた因子名および形容詞対を入力する印象語として使用するため，対象とするすべてのフォントの印象値を 17 名分の評価値を平均した値が -1〜+1 になるように正規化した．また，各因子の印象値に対しても，各因子に属する形容詞対の印象値の総和が -1〜+1 になるように正規化した．

ユーザは，調節部の下部にある，因子名または形容詞選択インタフェースを利用して，印象語を設定することができる．なお．因子名を選択できるモードと形容詞を選択できるモードを切り替えられるよう，トグルボタンを設置した．ユーザが最初に選択した印象語が 2 次元平面の横軸，次に選択した印象語が2次元平面の縦軸となり，それ以上の選択は受け付けないようにした．このとき，ユーザが選択した 2 つの印象語を軸として，18 種類のフォントを印象値に応じて配置した．なお，横軸は右向きを正とし，縦軸は上向きを正とする．

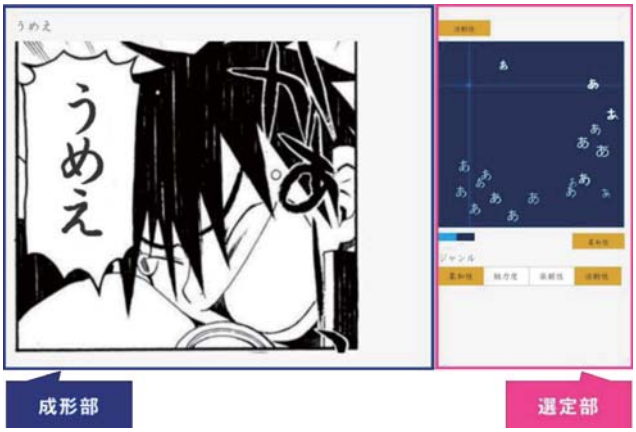


図 4 プロトタイプシステム概要

18 種類のフォントが配置されると，ユーザはブレンドフォントを生成できるようになる．具体的には，2 次元平面上でマウスポインタの位置を変更することにより近接している 4 つのフォントを，それぞれのマウスポインタまでの距離に応じて融合割合を変化させ，ブレンドする．なお，融合割合比はマウスポインタまでの距離の逆数の比とし，最も近いフォントが最も多く反映されたフォントとなる．また，ブレンド結果は成形部にリアルタイムに表示した．ブレンドするフォントを 4 つとしたのは，成形部にリアルタイムにブレンド結果を表示する際，違和感のない速度を保つためである．

4.2 システム使用例

図 5 は，プロトタイプシステムを用いて「しあわせだ」の文字を，デザインしている様子である．図 5(a)は，「好き」「暖かい」度合いが共に高くなるように，図 5(b)は，「好き」「暖かい」度合いが共に低くなるように，それぞれ文字デザインを施したものである．同図(a)に着目すると，丸みを帯び女性らしさを感じさせる形状となっている．一方，同図(b)は，太さがあり力強さを感じさせる形状となっている．

現時点での実装では太さの変化について平滑化を行えていないため，部分的に文字にノイズが残ってしまっている．

4.3 応用可能性

コミック創作における文字デザインは，ナレーションやキャラクタのセリフなどを対象としたフォント選定の他に，描き文字のデザインもコミックの完成度を左右する重要な要素である．描き文



(a)「好き」「暖かい」度合いが共に高いフォント生成例



(b)「好き」「暖かい」度合いが共に低いフォント生成例

図 5 文字デザイン例（選択した印象語：「好き」「暖かい」）



図 6 描き文字デザイン支援例

字とは，擬音語や擬態語などを手書きで装飾するコミックならではの文字で，描き文字のデザインは手書きで行われることが多い．しかし，キャラクタや背景の作画には長けていても，文字デザインの知識や経験はなく，思い通りの仕上がりにできないという問題を抱えるユーザも少なくない．こういった問題は提案手法を応用することで，解決することが可能であると考える．提案手法は，フォントの芯線と太さを数式化することで，フォントを表現し，高速に複数のフォントを融合することを可能にしているため，同様に手書き文字との融合も行うことができる．実際に，本提案手法で生成したフォントと手書き文字を融合した例を図 6 に示す． これは，Manga109[Matsui 15]内の小林ゆきの「あっけら貫刃帖」から抜粋したコマに対し，「ぷは」の文字を加筆したものである．同図(b)は，「柔和性」「楽観性」を軸とした二次元平面上の同図(a)の位置を選択し，生成されたフォントをコマ上に付加したものである．一方，同図(d)は著者が手書きでコマ上に書いた「ぷは」の文字で，同図(c)は，(b)のフォントで書かれた文字と，(d)の手書きで書かれた文字をそれぞれ 50%の割合で融合した文字をコマ上に付加したものである．著者はコミック上で使用する描き文字のデザイン経験はないため，手書きのみでデザインするとコミックのイメージに合っていない仕上がりになったという印象を受ける．しかし作成したフォントを融合することによって，イメージに合った文字デザインに近づけることができたと考える．

5. まとめと今後の展望

本研究では，コミック創作における文字デザインを支援するため，既存のフォントをユーザの目的の印象に合うようにブレンドし，新たなフォントを生成する手法を提案した．また，提案手法を用いた文字デザイン支援のためのプロトタイプシステムを実装し，いくつかの条件下で例を提示することで本手法が有効である可能性が示唆された．

今後は，コミックで使用する文字全般のデザイン支援を行えるようシステムを改良していく予定である．具体的には，フォントのブレンド結果のログを残し，前後の文字を簡単に比較できる機能や，フォントのブレンド結果やフォントと手書きの融合結果をアウトライン化し，ユーザが微調整できる機能を実装する予定である．

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

[MediBang 18] メディバン（MediBang）- マンガ・イラスト・ノベルの投稿&SNS サイト, 2018.

[LINE 18] LINE マンガ インディーズ, 2018.

[Matsui 15] Matsui, Y., Ito, K., Aramaki, Y., Yamasaka, T. and Aizawa K.: Sketch-based Manga Retrieval using Manga109 Dataset, arXiv, 2015.

[加納 17] 加納政芳, 遠藤和也, 中村剛士: オノマトペによる手書き文字変換手法のコミックへの応用, 第 31 回人工知能学会全国大会, 2017.

[佐藤 16] 佐藤剣太, 中村聡史, 鈴木正明: 電子コミックの表現を豊かにする手書きアニメーション生成手法, 第 30 回人工知能学会全国大会, 2016.

[Suveeranont 10] Suveeranont, R. and Igarashi, T.: Example-Based Automatic Font Generation, Proceedings of Smart Graphics 2010, Lecture Notes in Computer Science, 2010.

[Campbell 14] Campbell, N. D.F. and Kautz, J.: Learning a Manifold of Fonts, In ACM Transactions on Graphics (SIGGRAPH), 2014.

[斉藤 18] 斉藤絢基, 中村聡史: 動的なフォント融合による文字デザイン支援手法, 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.

[井上 84] 井上正之, 鎧沢勇: 文字形態から受ける印象と品質評価要因の検討, 電子情報通信学会論文誌, 1984.

[井上 85] 井上正明, 小林利宜: 日本における SD 法による研究分野とその形容詞対尺度構成の概観, 教育心理学研究, 1985.

Special session | Plenary session | Invited talk

[3A0] 「人工知能は未来の経済をどう変えるか？」(井上 智洋)

Thu. Jun 7, 2018 11:30 AM - 12:40 PM Room A (4F Emerald Hall)

[3A0-01] 「人工知能は未来の経済をどう変えるか？」

Tomohiro Inoue （1. 駒澤大学経済学部 准教授）

11:30 AM - 12:40 PM

©The Japanese Society for Artificial Intelligence

11:30 AM - 12:40 PM (Thu. Jun 7, 2018 11:30 AM - 12:40 PM Room A)

[3A0-01] 「人工知能は未来の経済をどう変えるか？」

Tomohiro Inoue （1. 駒澤大学経済学部 准教授）

人工知能は未来の雇用，経済成長，所得分配にどのような影響を与えるだろうか？そのような問題を論じるには，特化型ＡＩと汎用ＡＩに分けて考える必要がある． 特化型ＡＩは「技術的失業」をもたらすが，これは局所的かつ一時的な失業で済むはずだ． それに対し，汎用ＡＩが出現すれば全体的かつ長期的な失業がもたらされる可能性がある． その一方で爆発的な経済成長をもたらす可能性もある． さらに，所得格差を拡大させるので，ベーシックインカムのような新たな所得再分配の仕組みが必要となる．

©The Japanese Society for Artificial Intelligence

Special session | Other | Participants' networking meeting

[3A3] 参加者交流会

Thu. Jun 7, 2018 6:00 PM - 7:30 PM Room A (4F Emerald Hall)

[3A3-01] Participants' networking meeting

6:00 PM - 7:30 PM

©The Japanese Society for Artificial Intelligence

6:00 PM - 7:30 PM (Thu. Jun 7, 2018 6:00 PM - 7:30 PM Room A)

[3A3-01] Participants' networking meeting

©The Japanese Society for Artificial Intelligence

Special session | Night / Luncheon | Luncheon seminar

[3F4] ランチョンセミナー4((株)電通）

Thu. Jun 7, 2018 12:50 PM - 1:40 PM Room F (4F Garreria)

[3F4-01] AI時代の「クリエーティビティ」を探る

福田 宏幸 （株式会社電通）

12:50 PM - 1:40 PM

©The Japanese Society for Artificial Intelligence

12:50 PM - 1:40 PM (Thu. Jun 7, 2018 12:50 PM - 1:40 PM Room F)

[3F4-01] AI時代の「クリエーティビティ」を探る

福田 宏幸 （株式会社電通）

©The Japanese Society for Artificial Intelligence

Special session | Tutorial | Tutorial

[3I1] 「"深層学習時代の" ゼロから始める自然言語処理」(荒瀬 由紀)

座長:小林 一郎（お茶の水女子大学）

Thu. Jun 7, 2018 1:50 PM - 3:30 PM Room I (2F Royal Garden A)

[3I1-01] 「"深層学習時代の" ゼロから始める自然言語処理」

Yuki Arase （1. 大阪大学大学院情報科学研究科）

1:50 PM - 3:30 PM

©The Japanese Society for Artificial Intelligence

1:50 PM - 3:30 PM (Thu. Jun 7, 2018 1:50 PM - 3:30 PM Room I)

[3I1-01] 「"深層学習時代の" ゼロから始める自然言語処理」

Yuki Arase （1. 大阪大学大学院情報科学研究科）

©The Japanese Society for Artificial Intelligence

Special session | Tutorial | Tutorial

[3I2] 「実践 Deep Learning – いまさら聞けない入門編」(2) (中山 浩太郎)

座長:植野 研（株式会社東芝）

Thu. Jun 7, 2018 3:50 PM - 5:30 PM Room I (2F Royal Garden A)

[3I2-01] 「実践 Deep Learning – いまさら聞けない入門編」（後編）

Kotaro Nakayama （1. 東京大学 工学系研究科 技術経営戦略学専攻）

3:50 PM - 5:30 PM

©The Japanese Society for Artificial Intelligence

3:50 PM - 5:30 PM (Thu. Jun 7, 2018 3:50 PM - 5:30 PM Room I)

[3I2-01] 「実践 Deep Learning – いまさら聞けない入門編」（後編）

Kotaro Nakayama （1. 東京大学 工学系研究科 技術経営戦略学専攻）

©The Japanese Society for Artificial Intelligence

Special session | Night / Luncheon | Luncheon seminar

[3I4] ランチョンセミナー6(インテル(株))

Thu. Jun 7, 2018 12:50 PM - 1:40 PM Room I (2F Royal Garden A)

[3I4-01] 高い電力効率、低遅延で演算処理を高速化する手法 ～インテル® FPGAとXeon® プロセッサー～

12:50 PM - 1:40 PM

©The Japanese Society for Artificial Intelligence

12:50 PM - 1:40 PM (Thu. Jun 7, 2018 12:50 PM - 1:40 PM Room I)

[3I4-01] 高い電力効率、低遅延で演算処理を高速化する手法 ～インテル® FPGAと Xeon® プロセッサー～

©The Japanese Society for Artificial Intelligence

Special session | Night / Luncheon | Luncheon seminar

[3L4] ランチョンセミナー5(日本マイクロソフト(株))

Thu. Jun 7, 2018 12:50 PM - 1:40 PM Room L (3F Sapphire Hall Asuka)

[3L4-01] マイクロソフトの深層学習への取り組み

田丸 健三郎 （日本マイクロソフト株式会社）

12:50 PM - 1:40 PM

©The Japanese Society for Artificial Intelligence

12:50 PM - 1:40 PM (Thu. Jun 7, 2018 12:50 PM - 1:40 PM Room L)

[3L4-01] マイクロソフトの深層学習への取り組み

田丸 健三郎 （日本マイクロソフト株式会社）

©The Japanese Society for Artificial Intelligence

Special session | Proposed session | Student session

[3M1] 「最新の人工知能技術は，未解決問題をどう解決に導くか」(溝口 理一郎，松尾 豊)

Thu. Jun 7, 2018 1:50 PM - 3:30 PM Room M (2F Amethyst Hall Hoo)

[3M1-01] 「最新の人工知能技術は，未解決問題をどう解決に導くか」

Riichiro Mizoguchi, Yutaka Matsuo （1. 北陸先端科学技術大学院大学，2. 東京大学）

1:50 PM - 3:30 PM

©The Japanese Society for Artificial Intelligence

1:50 PM - 3:30 PM (Thu. Jun 7, 2018 1:50 PM - 3:30 PM Room M)

[3M1-01] 「最新の人工知能技術は，未解決問題をどう解決に導くか」

Riichiro Mizoguchi, Yutaka Matsuo （1. 北陸先端科学技術大学院大学，2. 東京大学）

©The Japanese Society for Artificial Intelligence

Special session | Industrial session | Industrial session

[3M2] インダストリアル(4)

座長:脇谷 勉（本田技術研究所）

Thu. Jun 7, 2018 3:50 PM - 5:30 PM Room M (2F Amethyst Hall Hoo)

[3M2-01] Industrial session (4)

3:50 PM - 5:30 PM

©The Japanese Society for Artificial Intelligence

3:50 PM - 5:30 PM (Thu. Jun 7, 2018 3:50 PM - 5:30 PM Room M)

[3M2-01] Industrial session (4)

(1)「機械学習エンジン"VALIS-Engine"による高効率なデジタル広告の実現とユーザー理解の促進」
舘野 啓（ソネット・メディア・ネットワークス株式会社）
(2)「東芝の AI技術」
小坂谷 達夫（(株)東芝）
(3)「コンペティションによる AI開発の可能性」
高田 朋貴（株式会社 SIGNATE）
(4)「不動産画像データ活用の最先端」
清田 陽司（ LIFULL）
(5)「日本ユニシスの「人に寄り添う人工知能」を目指した技術開発とそのビジネス適用」
脇森 浩志（日本ユニシス株式会社）
(6)「人工知能のビジネス応用の現状 ～異常検知・需要予測など～」
安達 章浩（株式会社 ALBERT）

©The Japanese Society for Artificial Intelligence

Special session | Proposed session | Proposed session

[3N1] KS-7 機械知能の理解にむけて ー物理学との対話を通してー

Thu. Jun 7, 2018 1:50 PM - 3:30 PM Room N (2F Sakurajima)

[3N1-01] KS-7 機械知能の理解にむけて ー物理学との対話を通してー

1:50 PM - 3:30 PM

©The Japanese Society for Artificial Intelligence

1:50 PM - 3:30 PM (Thu. Jun 7, 2018 1:50 PM - 3:30 PM Room N)

[3N1-01] KS-7 機械知能の理解にむけて ー物理学との対話を通してー

今後私達は，人と異なる多様な高度機械知能と共存することになる．その際に，知能についてより一般性の高以下たちで理解することが望ましい．物理学では現象の記述から本質的な理解に進む歴史が繰り返されている．本企画では物理学の専門家を招きつつ，ものごとの「理解」という側面から講演やパネル討論を行う．これを通じて，機械知能を理論的な理解に至る手がかり求めつつ，物理学から見たAIが拓く新たな理解についても議論したい．
http://www.sig-agi.org/sig-agi/events/understand

©The Japanese Society for Artificial Intelligence

Special session | Proposed session | Proposed session

[3N2] KS-4 インセンティブ設計科学

Thu. Jun 7, 2018 3:50 PM - 5:30 PM Room N (2F Sakurajima)

[3N2-01] KS-4 インセンティブ設計科学

3:50 PM - 5:30 PM

©The Japanese Society for Artificial Intelligence

3:50 PM - 5:30 PM (Thu. Jun 7, 2018 3:50 PM - 5:30 PM Room N)

[3N2-01] KS-4 インセンティブ設計科学

インセンティブ設計科学は，人間と AIが共存する社会のために，より良い社会のしくみを設計する新たな学問領域である．本セッションでは，インセンティブ設計科学の有望な応用事例に関する専門家である，公立はこだて未来大学 川越敏司先生 (オークション)，東京工業大学 田中圭介先生 (ビットコイン)，大阪大学 安田洋祐先生 (マッチング) の講演を行うと共に，パネルディスカッションにて本領域の今後の展望などを議論する．
http://agent.inf.kyushu-u.ac.jp/kiban-a-2017/events/ks4-jsai2018/

©The Japanese Society for Artificial Intelligence