Wed. Jun 5, 2019

Room C

General Session | General Session | [GS] J-12 Human interface, education aid

[2C1-J-12] Human interface, education aid: design and creation

Chair:Kazuhisa Seta Reviewer:Jun Ichikawa
9:00 AM - 10:00 AM Room C (4F International conference hall)

[2C1-J-12-01] Game-Based Story Generation Systems Using Player's Emotion and Action
○Shusuke Sato[1], Kaoru Sumi[1] (1. Future University Hakodate)
9:00 AM - 9:20 AM

[2C1-J-12-02] Decision Making for Model Based Design by Reinforcement Learning
○Tatsuhide Sakai[1], Takahiro Inabe[2] (1. Great Wall Motor, 2. Sakiyomi AI labo)
9:20 AM - 9:40 AM

[2C1-J-12-03] Development of New Value Creation and Evaluation System in Breakdance Using Deep Learning
○Naoyuki Hirasawa[1], Daichi Shimizu[2] (1. no new folk studio Inc., 2. Graduate School of Education, The University of Tokyo)
9:40 AM - 10:00 AM

Room D

General Session | General Session | [GS] J-11 Robot and real worlds

[2D1-J-11] Robot and real worlds: interaction of human, robot, and their environment

Chair:Yoshimasa Tawatsuji Reviewer:Masakazu Hirokawa
9:00 AM - 10:40 AM Room D (301B Medium meeting room)

[2D1-J-11-01] Evaluating the skill of robots guiding humans via a competitive task utilizing VR
○Yoshiaki Mizuchi[1], Tetsunari Inamura[1,2] (1. National Institute of Informatics, 2. SOKENDAI (The Graduate University for Advanced Studies))
9:00 AM - 9:20 AM

[2D1-J-11-02] Impression Effects of Collaborative Learning with Robots which Acts using Body Motion and Facial Expression
○Felix Jimenez[1], Tomohiro Yoshikawa[2], Takeshi Furuhashi[2], Masayoshi Kanoh[3] (1. School of Information Science and Technology, Aichi Prefectural University, 2. Graduate School of Engineering, Nagoya University, 3. School of Engineering, Chukyo University)
9:20 AM - 9:40 AM

[2D1-J-11-03] Influence of Eye Blink Mimicry and Interoceptive Awareness on Human-Robot Interaction
○Yuri Etani[1], Yukie Nagai[2], Konstantinos Theofilis[2], Masako Myowa[1] (1. Kyoto University, 2. National Institute of Information and Communications Technology)
9:40 AM - 10:00 AM

[2D1-J-11-04] Puppies or Flies: The Training Interaction Changes the Animacy Perception of Drones
○Watanabe Yuta[1], Onishi Yuya[1], Tanaka Kazuaki[2], Nakanisi Hideyuki[1] (1. Osaka University, 2. Kyoto Institute of Technology)
10:00 AM - 10:20 AM

[2D1-J-11-05] Emotions and Symbol Emergence in Robotics
○Takayuki Nagai[1] (1. Osaka University)
10:20 AM - 10:40 AM

Room E

General Session | General Session | [GS] J-1 Fundamental AI, theory

[2E1-J-1] Fundamental AI, theory: quantum computing and search

Chair:Takahisa Toda Reviewer:Yoichi Sasaki
9:00 AM - 10:20 AM Room E (301A Medium meeting room)

[2E1-J-1-01] Development of convolution filter embedded quantum autoencoder by quantum simulator
○Shiba Kodai[1], Hiroto Hakamata[2], Katsuhisa Sakamoto[1,2], Kouichi Yamaguchi[1,2], Tomah Sogabe[1,2] (1. The University of Electro-Communications , 2. i-PERC, The University of Electro-Communications)
9:00 AM - 9:20 AM

[2E1-J-1-02] Total Quantum Search of Optimal Solution in Quantum Computing
○Tomah Sogabe[1], Koudai Shiba[1], Katsuyoshi Sakamoto[1,3], Kouichi Yamaguchi[1,3], Dinesh Malla[2] (1. The University ofElectro-Communications, 2. Grid Inc., 3. i-Powered Energy Research Center,The University ofElectro-Communications)

©The Japanese Society for Artificial Intelligence

9:20 AM - 9:40 AM

[2E1-J-1-03] Mechanism Design for Facility Location via SAT Solving

○Nodoka Okada[1], Yuho Wada[1], Taiki Todo[1], Makoto Yokoo[1] (1. Univ. of Kyushu)

9:40 AM - 10:00 AM

[2E1-J-1-04] Reusing a Search Tree in Novelty-Based Pruning

○Ryo Ishibashi[1], Koichi Moriyama[1], Atsuko Mutoh[1], Tohgoroh Matsui[2], Nobuhiro Inuzuka[1] (1. Nagoya Institute of Technology, 2. Chubu University)

10:00 AM - 10:20 AM

General Session | General Session | [GS] J-6 Web mining

[2E5-J-6] Web mining 2

Chair:Kotaro Nakayama Reviewer:Masahiro Ito
5:20 PM - 6:20 PM Room E (301A Medium meeting room)

[2E5-J-6-01] Common Characteristics Found in Twitter Data and Human Behavior on Retweet

○Shigeo Shioda Shioda[1], Keisuke Nakajima[1] (1. Chiba University)

5:20 PM - 5:40 PM

[2E5-J-6-02] Resonance Structure of Online Flaming: The Epicenter of Information Sharing on Online Flaming

○Kohei Koyama[1], Kimitaka Asatani[1], Takeshi Sakaki[1], Ichiro Sakata[1] (1. The University of Tokyo)

5:40 PM - 6:00 PM

[2E5-J-6-03] Identifying Know-How Sites by Classifier Learning with Features of Topic Distribution within a Site

○Yohei Ohkawa[1,2], Tatsuya Maeda[1], Tengyang Chen[1], Takehito Utsuro[1], Yasuhide Kawada[3] (1. University of Tsukuba, 2. AVILEN Inc., 3. Logworks Co., Ltd.)

6:00 PM - 6:20 PM

General Session | General Session | [GS] J-12 Human interface, education aid

[2E3-J-12] Human interface, education aid: Shikake

Chair:Naohiro Matumura Reviewer:Yoko Nishihara
1:20 PM - 3:00 PM Room E (301A Medium meeting room)

[2E3-J-12-01] Development of 200 people game in big lecture hole in an university

○toyohisa nakada[1] (1. Niigata University of International and Information Studies)

1:20 PM - 1:40 PM

[2E3-J-12-02] Study on the Effect of a Questionnaire Appealing to Feeling Guilty on Umbrellas Theft Prevention

○Souta Matsui[1], Naohiro Matsumura[1] (1. Osaka University)

1:40 PM - 2:00 PM

[2E3-J-12-03] How face-to-face communication with photo similarities effects conversations

○Machiko Katori[1], Daisuke Uriu[1,2], Masahiko Inami[1,2], Atsushi Hiyama[1,2] (1. Graduate School of Information Science and Technology, the University of Tokyo, 2. Research Center for Advanced Science and Technology, the University of Tokyo)

2:00 PM - 2:20 PM

[2E3-J-12-04] Voice User Interface as a Method to Enhance Users' Activities on an LMS

○Toshihiro Kita[1], Chikako Nagaoka[1], Naoshi Hiraoka[1] (1. Research Center for Instructional Systems, Kumamoto University)

2:20 PM - 2:40 PM

[2E3-J-12-05] A Virtual City that Makes Children a Skilled Data Analyzer

○Takayuki Shiose[1], Ryosuke Kimura[2], Takashi Kondo[2], Makoto Matsuura[3], Tomoko Matsuura[3], Megumi Kotake[4], Mai Ogasawara[4] (1. Kyoto University, 2. Gocco., Inc., 3. NPO cobon, 4. Kodomo-Mirai Tankyusha, LLC.)

2:40 PM - 3:00 PM

Room G

General Session | General Session | [GS] J-13 AI application

[2G5-J-13] AI application: trust, value, and ethis

Chair:Arisa Ema Reviewer:Shinobu Hasegawa
5:20 PM - 7:00 PM Room G (302A Medium meeting room)

[2G5-J-13-01] Effect on reliability given by consideration of artificial intelligence judge

○Ryotaro KANZAKI[1], Ryo NAKAJIMA[1], Aya INOUE[1], Ryo TANAKA[1], Miona KOJIMA[1] (1. Doshisha University)

5:20 PM - 5:40 PM

[2G5-J-13-02] Impact on confidence in artificial intelligence by sharing secrets using trust

©The Japanese Society for Artificial Intelligence

games

○Daiki Nagata[1], Kae Shinoda[1], Chisato Numada[1], Katsuhiro Isokawa[1], Kyouka Hamanaka[1] （1. Doshisha university）

5:40 PM - 6:00 PM

[2G5-J-13-03] Artificial Intelligence : The Christian Perspective from an Engineer who are Christians

○Sachio Horie[1] （1. Nagoya Univercity）

6:00 PM - 6:20 PM

[2G5-J-13-04] Analysis of Legal Precedents of Tax Cases based on Factors and Legal Topos

Hayato Hirata[2], ○Katsumi Nitta[1] （1. National Institute of Advanced Industrial Science and Technology , 2. Asahi University）

6:20 PM - 6:40 PM

[2G5-J-13-05] Who have the Right of AI ?

○Kiyoshi Ono[1] （1. INTEC Inc.）

6:40 PM - 7:00 PM

Room H

General Session | General Session | [GS] J-2 Machine learning

[2H1-J-2] Machine learning: modeling in businesses

Chair:Makoto Kawano Reviewer:Kohei Miyaguchi
9:00 AM - 10:20 AM Room H (303+304 Small meeting rooms)

[2H1-J-2-01] Causal Analysis Model of TV Show Attractiveness using Latent Representation Models

○Yuki Nishimura[1], Shimpei Kanazawa[1], Tianxiang Yang[1], Masayuki Goto[1] （1. Waseda University）

9:00 AM - 9:20 AM

[2H1-J-2-02] Customer Classification Through Time Series Order Data Analysis in High-end Barbecue Beef

○Kiyotaka Shin[1], Xueyin Qu[1], Aiko Suge[1], Yasuo Yamashita[1], Hiroshi Takahashi[1] （1. Graduate School of Business Administration, Keio University）

9:20 AM - 9:40 AM

[2H1-J-2-03] An Estimation Model of Exhibits Price for Second-hand Fashion Items Based on Sales History Data

○Izumi Kuwata[1], Tomoya Sugisaki[1], Kenta Mikawa[2], Masayuki Goto[1] （1. Waseda University, 2. Shonan Institute of Technology）

9:40 AM - 10:00 AM

[2H1-J-2-04] Productivity Improvement through Yield Prediction and Machine Combination Optimization

Yoshiaki Suzuki[1], ○Manabu Kano[1], Akira Soga[2], Takeshi Yanagimachi[2], Ryo Murao[2], Masaya Takaki[2] （1. Kyoto University, 2. Toshiba）

10:00 AM - 10:20 AM

General Session | General Session | [GS] J-2 Machine learning

[2H3-J-2] Machine learning: selective preprocess

Chair:Yoji Kiyota Reviewer:Satoshi Oyama
1:20 PM - 3:00 PM Room H (303+304 Small meeting rooms)

[2H3-J-2-01] Surround Inhibition Mechanism by Deep Learning

○Mamoru Sugamoto[1], Naoaki Fujimoto[2], Muneharu Onoue[3], Tsukasa Yumibayashi[4], Akio Sugamoto[5] （1. apprhythm inc., 2. Tama Art U., 3. Geelive, Inc, 4. Otsuma Women’s U., 5. Ochanomizu U. and OUJ）

1:20 PM - 1:40 PM

[2H3-J-2-02] Adaptive Learning Rate Adjustment with Short-Term Pre-Training in Data-Parallel Deep Learning

○Kazuki Yamada[1], Haruki Mori[1], Tetsuya Youkawa[1], Yuki Miyauchi[1], Shintaro Izumi[1], Masahiko Yoshimoto[1], Hiroshi Kawaguchi[1] （1. Kobe University）

1:40 PM - 2:00 PM

[2H3-J-2-03] Adaptability of Cognitive Satisficing Algorithm in Nonstationary Environments

○Yuto Hanayasu[1], Kenshi Saito[2], Yuki Yoshii[1], Yu Kono[1], Tatsuji Takahashi[1] （1. School of Science and Engineering, Tokyo Denki University, 2. Graduate School of Tokyo Denki University）

2:00 PM - 2:20 PM

[2H3-J-2-04] A proposal of a new variable selection method utilizing gene's distribution information and solutions search progress rate of Real-coded genetic algorithms

○Takahiro OBATA[1], Setsuya KURAHASHI[1] （1. University of Tsukuba）

2:20 PM - 2:40 PM

[2H3-J-2-05] Feature Oriented Attention to Extract Attribution for Multivariate Time-Series Data

○Shuhei Asano[1], Keisuke Kiritoshi[1], Tomonori

©The Japanese Society for Artificial Intelligence

Izumitani[1] (1. NTT Communications Corporation)
2:40 PM - 3:00 PM

Room I

General Session | General Session | [GS] J-9 Natural language processing, information retrieval

[2I5-J-9] Natural language processing, information retrieval: classification and evaluation

Chair:Hirotoshi Taira Reviewer:Kugatsu Sadamitsu
5:20 PM - 7:00 PM Room I (306+307 Small meeting rooms)

[2I5-J-9-01] Unsupervised Ensemble of Ranking Models for News Comments Using Pseudo Ranking Evaluation
○Soichiro Fujita[1], Hayato Kobayashi[2,3], Manabu Okumura[1] (1. Tokyo Institute of Technology, 2. Yahoo Japan Corporation, 3. RIKEN AIP)
5:20 PM - 5:40 PM

[2I5-J-9-02] A Discussion of the Relation between Assembly Member's Utterance and Next Election Outcome
○Yasutomo Kimura[1], Akihiko Kawaura[2], Yuzu Uchida[3] (1. Otaru University of Commerce, 2. Doshisha University, 3. Hokkai-Gakuen University)
5:40 PM - 6:00 PM

[2I5-J-9-03] A Study of Patent Publications Classification Using Machine Translation and Rough Set Theory
○Masaki Kurematsu[1] (1. Iwate Prefectural University)
6:00 PM - 6:20 PM

[2I5-J-9-04] The Simplest Document Classifier
○Yoshitaka Shirai[1], Yutaka Hirata[1] (1. Chubu Univercity)
6:20 PM - 6:40 PM

[2I5-J-9-05] Automatic Scoring and Scoring Support System using LSTM and Attention
○Kohei Takai[1], Kengo Taketani[1], Junpei Hayakawa[2], Yasukuni Mori[3], Hiroki Suyari[3] (1. Department of Applied and Cognitive Informatics, Graduate School of Science and Engineering, Chiba University, 2. Department of Informatics and Imaging Systems, Faculty of Engineering, Chiba University, 3. Graduate School of Engineering, Chiba University)
6:40 PM - 7:00 PM

Room J

General Session | General Session | [GS] J-13 AI application

[2J3-J-13] AI application: consumption and living

Chair:Toshihiro Kamishima Reviewer:Yuiko Tsunomori
1:20 PM - 3:00 PM Room J (201B Medium meeting room)

[2J3-J-13-01] A study on cost reductions in labeling annotation of food images
○Naoki Kobayashi[1], Mitsunori Nanno[1] (1. FiNC Technologies, Inc.)
1:20 PM - 1:40 PM

[2J3-J-13-02] How can we predict the accuracy of weather forecast with machine learning?
○Masahide Funaki[1] (1. Niigata University)
1:40 PM - 2:00 PM

[2J3-J-13-03] Visualization of conceptual model of cooking workspace
○Ryutaro Hama[1], Azusa Mori[1], Yukari Takaku[1], Atsushi Harada[1], Atsushi Hashimoto[2] (1. LIXIL Corporation, 2. Kyoto University)
2:00 PM - 2:20 PM

[2J3-J-13-04] Clustering time-series data of cooking using object detection
○Azusa Mori[1], Ryutaro Hama[1], Atsushi Harada[1], Yukari Takaku[1], Atsushi Hashimoto[2] (1. LIXIL Corporation, 2. Kyoto University)
2:20 PM - 2:40 PM

[2J3-J-13-05] Comparison of Anomaly Detection Performance by Outlier Detection Methods for Household Power Consumption
○Miho Hashimoto[1], Yutaro Yagi[1], Takahiro Nishigaki[1], Takashi Onoda[1] (1. Aoyama Gakuin University)
2:40 PM - 3:00 PM

Room L

General Session | General Session | [GS] J-9 Natural language processing, information retrieval

[2L1-J-9] Natural language processing, information retrieval: fusion with image

Chair:Chiaki Miyazaki Reviewer:Tomoya Yoshikawa
9:00 AM - 10:00 AM Room L (203+204 Small meeting rooms)

[2L1-J-9-01] Evaluation uncertainties in Image-Caption Retrieval
○Kenta Hama[1], takashi matsubara[1], uehara

©The Japanese Society for Artificial Intelligence

kuniaki[1] (1. Kobe University)
9:00 AM - 9:20 AM

[2L1-J-9-02] A Study on Behavior of Deep Neural Text-to-Image Generative Model
○Chihiro Fujiyama[1], Ichiro Kobayashi[1] (1. Ochanomizu University)
9:20 AM - 9:40 AM

[2L1-J-9-03] Towards Building a Logical Inference System for Text and Visual Information
Riko Suzuki[1], ○Masashi Yoshikawa[2], Hitomi Yanaka[3], Koji Mineshima[1], Daisuke Bekki[1] (1. Ochanomizu University, 2. Nara Institute of Science and Technology, 3. RIKEN Center for Advanced Intelligence Project)
9:40 AM - 10:00 AM

General Session | General Session | [GS] J-9 Natural language processing, information retrieval

[2L3-J-9] Natural language processing, information retrieval: knowledge supply

Chair:Takeshi Morita Reviewer:Jun Sugiura
1:20 PM - 3:00 PM Room L (203+204 Small meeting rooms)

[2L3-J-9-01] Response Generation based on Embedding Representation of Knowledge and Topics
○Jie Zeng[1], Yutaka Takase[2], Yukiko Nakano[2] (1. Graduate School of Science and Technology, Seikei University, 2. Faculty of Science and Technology, Seikei University)
1:20 PM - 1:40 PM

[2L3-J-9-02] Monotonicity Dataset Creation on Crowdsourcing
Hitomi Yanaka[1,2], ○Daisuke Bekki[2], Koji Mineshima[2], Satoshi Sekine[1], Kentaro Inui[3,1] (1. RIKEN Center for Advanced Intelligence Project, 2. Ochanomizu University, 3. Tohoku University)
1:40 PM - 2:00 PM

[2L3-J-9-03] Collecting Examples of Know-How Question Answering from Column Pages on the Web
○Tatsuya Maeda[1], Tengyang Chen[1], Yohei Ohkawa[1], Takehito Utsuro[1], Yasuhide Kawada[2] (1. University of Tsukuba, 2. Logworks Co., Ltd.)
2:00 PM - 2:20 PM

[2L3-J-9-04] V-TA: Dialogue System for Practical Training on Software Development
○Masayuki Otani[1], Taku Kawabata[2], Koji Abe[1], Hirofumi Yamamoto[1], Shiro Takata[1], Yoshihiko Akamatsu[2], Fujiko Yamamura[2] (1. Kindai University, 2. JIEC Co.,Ltd.)
2:20 PM - 2:40 PM

[2L3-J-9-05] A Comparison of Multileaving Methods on News App Personalization
○Kojiro Iizuka[1], Takeshi Yoneda[1], Yoshifumi Seki[1] (1. Gunosy Inc.)
2:40 PM - 3:00 PM

General Session | General Session | [GS] J-9 Natural language processing, information retrieval

[2L4-J-9] Natural language processing, information retrieval: conversion and generation

Chair:Ichiro Kobayashi Reviewer:Yuzuru Okajima
3:20 PM - 4:40 PM Room L (203+204 Small meeting rooms)

[2L4-J-9-01] A sentence style conversion method using LSTM-RNN
○Kenta Shimoji[1], Kazuhiro Morita[1], Masao Fuketa[1] (1. Tokushima University)
3:20 PM - 3:40 PM

[2L4-J-9-02] Text simplification using newspaper articles
Naoki Koto[1], ○Hidetsugu Nanba[1], Toshiyuki Takezawa[1] (1. Hiroshima City University)
3:40 PM - 4:00 PM

[2L4-J-9-03] Keyword Conditional Variational Autoencoder for advertising headline generation
○Hiroyuki Fukuda[1] (1. DENTSU INC.)
4:00 PM - 4:20 PM

[2L4-J-9-04] Generating Emoji with Conditional Variational Autoencoders and Word Embedding
○Atsuki Yamaguchi[1], Katsuhide Fujita[1] (1. Tokyo University of Agriculture and Technology)
4:20 PM - 4:40 PM

General Session | General Session | [GS] J-9 Natural language processing, information retrieval

[2L5-J-9] Natural language processing, information retrieval: data collection

Chair:Koichiro Yoshino Reviewer:Hidekazu Oiwa
5:20 PM - 6:20 PM Room L (203+204 Small meeting rooms)

[2L5-J-9-01] Trial production of distributed representation dictionary based on multi attributional description including common knowledge
○Hajime Murai Murai[1] (1. Future University Hakodate)
5:20 PM - 5:40 PM

©The Japanese Society for Artificial Intelligence

[2L5-J-9-02] A Collection of Sets of Metaphorical Mappings Annotated with Story World Calls

○Suguru Matsuyoshi[1], Akira Utsumi[1] （1. The University of Electro-Communications）

5:40 PM - 6:00 PM

[2L5-J-9-03] Construction of Coherent Translation Evaluation Dataset in Machine Translation

○Kaori Abe[1], Jun Suzuki[1,2,3], Masaaki Nagata[3], Kentaro Inui[1,2] （1. Tohoku University, 2. Center for Advanced Intelligence Project (AIP), 3. NTT Communication Science Laboratories）

6:00 PM - 6:20 PM

Room M

General Session | General Session | [GS] J-10 Vision, speech

[2M5-J-10] Vision, speech: movement of bodies and objects

Chair:Eiki Ishidera Reviewer:Yoko Nishihara
5:20 PM - 7:00 PM Room M (Front-right room of 1F Exhibition hall)

[2M5-J-10-01] Improving object detection performance using objects' relative positions

○Yuichi Sasaki[1] （1. Fashion Pocket, Inc.）

5:20 PM - 5:40 PM

[2M5-J-10-02] Large-Scale Performance Evaluation Experiments on Name and Location Prediction of Spatial Concept Transfer Leaning Model

○Keishiro Taguchi[1], Kazuya Asada[1], Satoshi Ishibushi[1], Yoshinobu Hagiwara[1], Tadahiro Taniguchi[1] （1. Ritsumeikan University）

5:40 PM - 6:00 PM

[2M5-J-10-03] Evaluation of bidirectional method between motion and context for human motion recognition

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

6:00 PM - 6:20 PM

[2M5-J-10-04] A Study on Evaluation Model on Stroke Order Similarity

○Ryoske Fujii[1], Naoki Mori[1], Makoto Okada[1] （1. Graduate School of Engineering, Osaka Prefecture University）

6:20 PM - 6:40 PM

[2M5-J-10-05] Gesture Recognition by Multi-task Learning using Parallel Residual Adapters

○Noeru Suzuki[1], Kosuke Kikui[2], Yuta Itoh[3], Hisashi Kashima[1], Makoto Yamada[1] （1. Kyoto University, 2. Keio University, 3. Tokyo Institute of Technology）

6:40 PM - 7:00 PM

General Session | General Session | [GS] J-13 AI application

[2M3-J-13] AI application: consumption and market

Chair:Kazunori Matsumoto Reviewer:Jun Ichikawa
1:20 PM - 2:40 PM Room M (Front-right room of 1F Exhibition hall)

[2M3-J-13-01] Promotion of unmanned stores through automatic AI accounting

○kanae matsuo[1], kana kawatani[1], tomoki ishida[1], ruriko tsubota[1] （1. doshisha university）

1:20 PM - 1:40 PM

[2M3-J-13-02] A Context-Aware Recommender System for AR-based Shopping Support

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

1:40 PM - 2:00 PM

[2M3-J-13-03] Discrepancy prediction between the results purchase and pre-listening of the face-to-face sales

○Takumi Uchida[1,2], Kenichi Yoshida[2] （1. Recruit Communications Co., Ltd., 2. University of Tsukuba Graduate School）

2:00 PM - 2:20 PM

[2M3-J-13-04] Verification of Consumer Behavior Model Focusing on Point System

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

2:20 PM - 2:40 PM

Room N

General Session | General Session | [GS] J-13 AI application

[2N3-J-13] AI application: medical diagnosis

Chair:Koji Morikawa Reviewer:Yoshikuni Sato
1:20 PM - 2:20 PM Room N (Front-right room of 1F Exhibition hall)

[2N3-J-13-01] Denoising autoencoder-based modification method for RRI data with premature atrial

©The Japanese Society for Artificial Intelligence

contraction

○Shota Miyatani[1], Koichi Fujiwara[2], Manabu Kano[1] (1. Kyoto University, 2. Nagoya University)

1:20 PM - 1:40 PM

[2N3-J-13-02] Character-level Text Generations with Attention for Chest X-ray Diagnosis

○Kenya Sakka[1], Kotaro Nakayama[1,2], Nisei Kimura[1], Taiki Inoue[1], Ryohei Yamaguchi[1], Yoshimasa Kawazoe[1], Kazuhiko Ohe[1], Yutaka Matsuo[1] (1. The University of Tokyo, 2. NABLAS Inc.)

1:40 PM - 2:00 PM

[2N3-J-13-03] Detecting patient mix-up on blood samples with machine learning

○Tomohiro Mitani[1], Shunsuke Doi[2], Shinichiroh Yokota[2], Takeshi Imai[1], Kazuhiko Ohe[1,2] (1. Graduate School of Medicine, The University of Tokyo, 2. The University of Tokyo Hospital)

2:00 PM - 2:20 PM

General Session | General Session | [GS] J-13 AI application

[2N4-J-13] AI application: medicine

Chair:Koji Morikawa Reviewer:Yoshikuni Sato
3:20 PM - 5:00 PM Room N (Front-right room of 1F Exhibition hall)

[2N4-J-13-01] Advantages of 3D-ResNet in Cerebral Aneurysm Detection using MRA Images

○Terasaki Yuki[1], Hajime Yokota[2], Hiroki Mukai[2], Shoma Yamauchi[2], Ryuna Kurosawa[3], Joji Ota[3], Takuro Horikoshi[2], Yasukuni Mori[4], Hiroki Suyari[4] (1. Graduate School of Chiba University, 2. Dept. Radiology, Chiba University Hospital, 3. Dept. Radiology, Chiba University , Hospital, 4. Graduate School of Engineering, Chiba University)

3:20 PM - 3:40 PM

[2N4-J-13-02] Classification of esophageal cancer CT images using deep learning

○Takumi Seto[1], Masashi Takeuchi[2], Masahiro Hashimoto[2], Yui Ito[1], Naoaki Ichihara[2], Hirohumi Kawakubo[2], Yuko Kitagawa[2], Hiroaki Miyata[2], Masahiro Jinzaki[2], Yasubumi Sakakibara[1] (1. Keio University Faculty of Science and Technology, 2. Keio University School of Medicine)

3:40 PM - 4:00 PM

[2N4-J-13-03] Development of Epileptic Seizure Prediction Algorithm by Combining Heart Rate Variability Analysis and Autoencorder

○Koichi Fujiwara[1,2], Fumiya Sakane[2], Miho Miyajima[3], Toshitaka Yamakawa[4], Taketoshi Maehara[3] (1. Nagoya University, 2. Kyoto University, 3. Tokyo Medical and Dental University, 4. Kumamoto University)

4:00 PM - 4:20 PM

[2N4-J-13-04] Diagnosis of head CT image by on-premise deep learning

○Tetsuya Shiraishi[1], Yuriko Hijikata[1] (1. Saitama Sekishinkai Hospital)

4:20 PM - 4:40 PM

[2N4-J-13-05] Lesion Detection in Computed Tomography Images using YOLOv3 and Domain Knowledge

Akira Saigo[1], ○Naoki Hayashi[2], Kotaro Ito[2] (1. Recruit techonologies Co.,Ltd., 2. NTTDATA Mathematical Systems Inc.)

4:40 PM - 5:00 PM

General Session | General Session | [GS] J-13 AI application

[2N5-J-13] AI application: medicine and healthcare

Chair:Yasutomo Yamamoto Reviewer:Koji Kozaki
5:20 PM - 6:40 PM Room N (Front-right room of 1F Exhibition hall)

[2N5-J-13-01] Fall Risk Evaluation Using Mahalanobis Distance and Factor Analysis

○Takao Naito[1,2], Masato Kobe[1], Makoto Kunigoh[1], Kotaro Yamasue[2], Osamu Tochikubo[2], Yoshihiro Ishikawa[2], Hiroshi Takeda[3] (1. Fuji Xerox, 2. Yokohama City University, 3. Osaka University)

5:20 PM - 5:40 PM

[2N5-J-13-02] Emotional responses of the elderly people must be realized by the artificial intelligence

○Tomoyuki Yambe[1], Makoto Yoshizawa[1], Yusuke Inoue[1], Akihiro Tamada[1], Yasuyuki Shiraishi[1] (1. Tohoku University)

5:40 PM - 6:00 PM

[2N5-J-13-03] Current Trends, Issues, and Potentiality of AI Technology in Psychiatry

○Shin Ikeda[1] (1. Okayama Psychiatric Medical

©The Japanese Society for Artificial Intelligence

Center）
6:00 PM - 6:20 PM

[2N5-J-13-04] proposal of Prediction method of ECG via 1D-CNN
〇Shigeki Shimizu[1], Kouta Anai[1], Naoto Yamada[1]（1. Toyota Technical Development Corporation）
6:20 PM - 6:40 PM

Room O

General Session | General Session | [GS] J-7 Agents

[2O4-J-7] Agents: human interaction

Chair:Hirotaka Osawa Reviewer:Yoshimasa Tawatsuji
3:20 PM - 4:20 PM Room O (Front-left room of 1F Exhibition hall)

[2O4-J-7-01] Fostering Empathy for Computer Agents through Synchronized Movements
〇Naohiro Eda[1], Katie Seaborn[2], Seito Matsubara[3], Ken Sakuma[3], Atsushi Hiyama[2,3], Masahiko Inami[3]（1. The Faculty of Engineering,The University of Tokyo, 2. RIKEN Center for Advanced Intelligence Project, 3. Graduate School of Information Science and Technology, The University of Tokyo）
3:20 PM - 3:40 PM

[2O4-J-7-02] Drawing interaction between human and recurrent neural network
〇Hikaru Yanagida[1], Shingo Murata[2,3], Kentaro Katahira[4], Shinsuke Suzuki[5], Tetsuya Ogata[1], Yuichi Yamashita[6]（1. Department of Intermedia Art and Science, School of Fundamental Science and Engineering, Waseda University, 2. Principles of Informatics Research Division, National Institute of Informatics, 3. Department of Informatics, School of Multidisciplinary Sciences, The Graduate University for Advanced Studies (SOKENDAI), 4. Department of Cognitive and Psychological Sciences, Graduate School of Informatics, Nagoya University, 5. Creative Interdisciplinary Research Division, Frontier Research Institute for Interdisciplinary Sciences, Tohoku University, 6. Department of Functional Brain Research, National Institute of Neuroscience, National Center of Neurology and Psychiatry）
3:40 PM - 4:00 PM

[2O4-J-7-03] Influence of polite greetings on attachment of a voice agent
〇Ken Sasaki[1], Miho Kitamura[2], Keiichi Kurata[3], Katsumi Watanabe[1]（1. Graduate School of Fundamental Science and Engineering, Waseda University, 2. Waseda Institute for Advanced Study, 3. DENSO CORPORATION）
4:00 PM - 4:20 PM

General Session | General Session | [GS] J-13 AI application

[2O1-J-13] AI application: dynamics in finance

Chair:Setsuya Kurahashi Reviewer:Hiroto Yoneno
9:00 AM - 10:40 AM Room O (Front-left room of 1F Exhibition hall)

[2O1-J-13-01] Extraction of Important Sentences in Financial Documents Based on Business Confidence Information Using LSTM with Self-Attention Mechanism
〇Shuhei Yamaoka[1], Seiichi Ozawa[1], Takehide Hirose[2], Masaaki Iizuka[2]（1. Kobe University, 2. Sumitomo Mitsui DS Asset Management Company, Limited）
9:00 AM - 9:20 AM

[2O1-J-13-02] Relationship between Liquidity and Costs of Arbitrage Trading for Stocks and ETF --- Investigation by Agent-Based Model ---
〇Takanobu Mizuta[1]（1. SPARX Asset Management Co., Ltd.）
9:20 AM - 9:40 AM

[2O1-J-13-03] Analysis of Inter-bank Network's Temporal Change Using Clustering Structure Change Detection
〇Yuta Niki[1], Kiyoshi Izumi[1], Hiroyasu Matsushima[1], Hiroki Sakaji[1], Takashi Shimada[1]（1. School of Engineering, The University of Tokyo）
9:40 AM - 10:00 AM

[2O1-J-13-04] Analysis of Limit Orders by High-Frequency Traders in Tokyo Stock Exchange
〇Masanori HIRANO[1], Kiyoshi IZUMI[1], Hiroyasu MATSUSHIMA[1], Hiroki SAKAJI[1], Takashi SHIMADA[1]（1. School of Engineering, The University of Tokyo）
10:00 AM - 10:20 AM

[2O1-J-13-05] Extraction of Future-oriented Sentences from Annual Securities Reports

©The Japanese Society for Artificial Intelligence

○Shunya Kodera[1], Yoshinori Tanaka[1], Fumihito Sato[1], Hiroaki Sakuma[1], Hiroki Sakaji[2], Kiyoshi Izumi[2] （1. NIKKO RESEARCH CENTER, INC., 2. Graduate School of Engineering, The University of Tokyo）

10:20 AM - 10:40 AM

General Session | General Session | [GS] J-13 AI application

[2O3-J-13] AI application: investments

Chair:Takanobu Mizuta Reviewer:Shinobu Hasegawa
1:20 PM - 2:40 PM Room O (Front-left room of 1F Exhibition hall)

[2O3-J-13-01] Analysis of Posted Price as a Determinant of Office Rent

○Yoshiteru Osawa[1], Yoshinao Ebina[1], Mayuko Tahara[2], Katsutaka Bunya[2], Takahiro Hoshino[2,3] （1. Mitsubishi UFJ Trust and Banking Corporation, 2. Faculty of Economics, Keio University, 3. RIKEN Center for Advanced Intelligence Project）

1:20 PM - 1:40 PM

[2O3-J-13-02] Analysis of Chain Bankruptcy Using Multilayer Networks Simulation among Banks and Companies

○Ryo Hamawaki[1], Junnichi Ozaki[2], Kiyoshi Izumi[1], Takashi Shimada[1], Hiroyasu Matsushima[1], Hiroki Sakaji[1] （1. The University of Tokyo, 2. Tokyo Institute of Technology）

1:40 PM - 2:00 PM

[2O3-J-13-03] What is a Hedge or Safe Haven Asset for Bitcoin Investors?

○Ryuta Sakemoto[1,2], Alden Ho[1], Yoshihiko Ichikawa[1] （1. YJFX, Inc, 2. Keio Economic Observatory Keio University）

2:00 PM - 2:20 PM

[2O3-J-13-04] Construction of Causal Networks for Risk Finding Considering Word Polarities

○Hiroaki IGARASHI Igarashi[1], Hiroki Sakaji[1], Kiyoshi Izumi[1], Takashi Shimada[1], Shintaro Suda[2] （1. the University of Tokyo, 2. Mitsubishi UFJ Trust Investment Technology Institute Co., Ltd.(MTEC)）

2:20 PM - 2:40 PM

Room P

General Session | General Session | [GS] J-2 Machine learning

[2P1-J-2] Machine learning: conquests of limits

Chair:Takuma Otsuka Reviewer:Yuiko Tsunomori
9:00 AM - 10:20 AM Room P (Front-left room of 1F Exhibition hall)

[2P1-J-2-01] Toward Deep Satisficing Reinforcement Learning

○Kuniaki Satori[1], Yutaka Yoshida[1], Takumi Kamiya[1], Tatsuji Takahashi[1] （1. Tokyo Denki University）

9:00 AM - 9:20 AM

[2P1-J-2-02] Imbalanced Classification with Near-misses for Binary Decision-making

○Akira Tanimoto[1,2,3], So Yamada[1], Takashi Takenouchi[2,4], Hisashi Kashima[2,3] （1. NEC, 2. Riken, 3. Kyoto University, 4. Future University Hakodate）

9:20 AM - 9:40 AM

[2P1-J-2-03] Learning Model Discrepancy in Physics-guided Neural Networks

Junya Tanaka[1], Tomohiko Tomita[2], Masayuki Numao[1], ○Ken-ichi Fukui[1] （1. Osaka University, 2. Kumamoto University）

9:40 AM - 10:00 AM

[2P1-J-2-04] Collaborative filtering based on distributed expression considering differences in evaluation trends

○Ryousuke Goto[1], Hideki Fujinami[1], Tianxiang Yang[1], Masayuki Goto[1] （1. Facutly of Science and Engeneering, Waseda University）

10:00 AM - 10:20 AM

General Session | General Session | [GS] J-2 Machine learning

[2P3-J-2] Machine learning: advances in neural networks

Chair:Masayuki Okamoto Reviewer:Masakazu Hirokawa
1:20 PM - 3:00 PM Room P (Front-left room of 1F Exhibition hall)

[2P3-J-2-01] Proposal of optimization method of local receptive field using gradient descent

○So Tazume[1], Masanao Ochi[1], Ichiro Sakata[1], Junichiro Mori[1] （1. The University of Tokyo）

1:20 PM - 1:40 PM

[2P3-J-2-02] Acceleration of Neural Architecture Search by Policy Gradient with Credit Assignment

○Rei Sato[1,2], Youhei Akimoto[1,2], Jun Sakuma[1,2] （1. University of Tsukuba, 2. RIKEN Center for Advanced Intelligence Project）

©The Japanese Society for Artificial Intelligence

1:40 PM - 2:00 PM

[2P3-J-2-03] Progressive Data Increasing as Initialization of Neural Network

○Ryosuke Sato[1], Masanari Kimura[1] (1. Ridge-i Inc.)

2:00 PM - 2:20 PM

[2P3-J-2-04] Efficient learning in machine language instruction sequence classification by transfer learning

○Yuhei Otsubo[1,2], Akira Otsuka[2], Yoshihiro Iwata[1], Mamoru Mimura[3], Takeshi Sakaki[4] (1. National Police Agency, 2. Institute of Information Security, 3. National Deffense Academy, 4. University of Tokyo)

2:20 PM - 2:40 PM

[2P3-J-2-05] A Style Transfer Method using Wasserstein Autoencoder

○Hidekmoto Nakada[1], Hideki Asoh[1] (1. National Insitutite of Advanced Industrial Science and Technology)

2:40 PM - 3:00 PM

General Session | General Session | [GS] J-2 Machine learning

[2P4-J-2] Machine learning: industries and finance

Chair:Keisuke Otaki Reviewer:Junpei Komihyama

3:20 PM - 4:40 PM Room P (Front-left room of 1F Exhibition hall)

[2P4-J-2-01] Efficient estimation for red-zone in silicon wafers for solar cells using Level Set Estimation

○Shota Hozumi[1], Kota Matsui[2], Kentaro Kutsukake[2], Toru Ujihara[4], Ichiro Takeuchi[1,2,3] (1. Nagoya Institute of Technology, 2. RIKEN, 3. Center for Materials Research by Information Integration, National Institute for Materials Science, 4. Nagoya Universary)

3:20 PM - 3:40 PM

[2P4-J-2-02] Generating airfoil shape using conditional variational auto-encoder

○Kazuo Yonekura[1], Hitoshi Hattori[1], Takafumi Nishizu[1] (1. IHI Corporation)

3:40 PM - 4:00 PM

[2P4-J-2-03] Solar radiation prediction using RBF Network for Campus

○Yuta Hashiba[1], Shoichi Urano[1] (1. Meiji University)

4:00 PM - 4:20 PM

[2P4-J-2-04] A study of hybrid prediction model considering risk reduction for economic indicators forecasting

○Kodai Ogihara[1], Shoichi Urano[1] (1. Meiji University)

4:20 PM - 4:40 PM

General Session | General Session | [GS] J-2 Machine learning

[2P5-J-2] Machine learning: medicine and heathcare

Chair:Jun Ozawa Reviewer:Yoshikuni Sato

5:20 PM - 7:00 PM Room P (Front-left room of 1F Exhibition hall)

[2P5-J-2-01] Prediction of depressive tendencies from health data considered unassociated with depressive states

Shiori Yamaguchi[1], ○Hiroki Tanaka[1], Hayato Maki[1], Shigehiko Kanaya[1,2], Nobutaka Suzuki[3], Satoshi Nakamura[1,2] (1. Nara Institute of Science and Technology, Graduate School of Science and Technology, 2. Nara Institute of Science and Technology, Data Science Center, 3. Kanazawa University, Graduate School of Medical Sciences)

5:20 PM - 5:40 PM

[2P5-J-2-02] Data Transformation method for Comprehensive Classification to Blood Test Data

○Takumi Yoshida[1], Matsui Tohgoroh[1] (1. Chubu University)

5:40 PM - 6:00 PM

[2P5-J-2-03] Medical image recognition of MRI brain images using deep logistic GMDH-type neural network and convolutional neural network

○Tadashi Kondo[1], Shoichiro Takao[1], Sayaka Kondo[2], Junji Ueno[1] (1. Tokushima University, 2. Tokushima medical informatics laboratory)

6:00 PM - 6:20 PM

[2P5-J-2-04] Mental Disorder Diagnosis using fMRI Images by Deep State-Space Model

○Koki Kusano[1], Tetsuo Tashiro[1], Takashi Matsubara[1], Kuniaki Uehara[1] (1. Kobe University)

6:20 PM - 6:40 PM

[2P5-J-2-05] Semi-supervised learning based target gene selection for medical data

○Akito Seki[1], Hirotaka Akita[1], Hisashi Kashima[1,2],

©The Japanese Society for Artificial Intelligence

Makoto Yamada[1,2] (1. Kyoto University, 2. RIKEN AIP)

6:40 PM - 7:00 PM

Room Q

General Session | General Session | [GS] J-2 Machine learning

[2Q1-J-2] Machine learning: models for prediction

Chair:Koh Takeuchi Reviewer:Hikaru Kajino

9:00 AM - 10:40 AM Room Q (6F Meeting room, Bandaijima bldg.)

[2Q1-J-2-01] The Cox hazard model using Factorization Machines

○Kanata Satake[1], Makoto Yamada[1,2], Kota Matsui[2], Shigeyuki Matsui[2,3], Hisashi Kashima[1,2] (1. Kyoto University, 2. RIKEN Center, 3. Nagoya University)

9:00 AM - 9:20 AM

[2Q1-J-2-02] LTV Prediction Based on RFM and Customer Characteristics

○Yusaku Imai[1], Yuki Tajima[1] (1. Dentsu Digital Inc.)

9:20 AM - 9:40 AM

[2Q1-J-2-03] Study on the relationship between data non-linearity and dam inflow discharge prediction accuracy

○Masazumi Amakata[1], Takuto Yasuno[1], Junichiro Fujii[1], Yuri Shimamoto[1], Junichi Okubo[1] (1. Yachiyo Engineering Co.,Ltd.)

9:40 AM - 10:00 AM

[2Q1-J-2-04] Comparison of Deep Time Series Prediction Models Utilizing Linear Regression Model

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

10:00 AM - 10:20 AM

[2Q1-J-2-05] The Effects of Element and Input Length on Accuracy in Aquaculture Seawater Temperature Prediction Model

○Masahito Okuno[1], Takanobu Otsuka[1] (1. Nagoya Institute of Technology)

10:20 AM - 10:40 AM

General Session | General Session | [GS] J-2 Machine learning

[2Q3-J-2] Machine learning: explainability, knowledge acquisition

Chair:Yasuhiro Sogawa Reviewer:Shohei Higashiyama

1:20 PM - 3:00 PM Room Q (6F Meeting room, Bandaijima bldg.)

[2Q3-J-2-01] Investigation of the influence of over training on CNN focusing on change of heat map which brings interpretability

○Yoshihisa Furusawa[1], Yoshimasa Tawatsuji[3,2], Tatsunori Matsui[2] (1. Waseda University, 2. Faculty of Human Sciences, Waseda University, 3. Graduate School of Human Sciences, Waseda University)

1:20 PM - 1:40 PM

[2Q3-J-2-02] Visualization of cluster structure transition in deep learning

○Chihiro Watanabe[1] (1. NTT Communication Science Laboratories)

1:40 PM - 2:00 PM

[2Q3-J-2-03] Explanation of frequency domain features contributing to EEG classification

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

2:00 PM - 2:20 PM

[2Q3-J-2-04] Model-agnostic Explainer using Feature Patterns

○Kohei Asano[1], Jinhee Chun[1], Takeshi Tokuyama[1] (1. Tohoku University)

2:20 PM - 2:40 PM

[2Q3-J-2-05] Visualization of learning process for Convolution Neural Network

○Soichi Sakai[1], Yoichi Takenaka[2] (1. Graduate School of Informatics, Kansai University, 2. School of Informatics, Kansai University)

2:40 PM - 3:00 PM

General Session | General Session | [GS] J-2 Machine learning

[2Q4-J-2] Machine learning: bayesian network

Chair:Togoro Matsui Reviewer:Masakazu Hirokawa

3:20 PM - 4:20 PM Room Q (6F Meeting room, Bandaijima bldg.)

[2Q4-J-2-01] Learning huge Bayesian network structures by RAI algorithm with transitivity

Kazunori Honda[1], Kazuki Natori[1], ○Shouta Sugahara[1], Takashi Isozaki[1], Maomi Ueno[1] (1. The University of Electro-Communications)

3:20 PM - 3:40 PM

[2Q4-J-2-02] Learning huge Augmented Naive Bayes Classifier

○Naruchika Kikuya[1] (1. The University of Electro-Communications)

3:40 PM - 4:00 PM

©The Japanese Society for Artificial Intelligence

[2Q4-J-2-03] Exact Learning Augmented Naive Bayes Classifier

○Shouta Sugahara[1], Maomi Ueno[1] (1. The University of Electro-Communications)

4:00 PM - 4:20 PM

General Session | General Session | [GS] J-2 Machine learning

[2Q5-J-2] Machine learning: advanced models

Chair:Masataro Asai Reviewer:Hikaru Kajino

5:20 PM - 7:00 PM Room Q (6F Meeting room, Bandaijima bldg.)

[2Q5-J-2-01] Bayesian Inverse Reinforcement Learning for Demonstrations of an Expert in Multiple Dynamics

○Yusuke Nakata[1], Sachiyo Arai[1] (1. Chiba University)

5:20 PM - 5:40 PM

[2Q5-J-2-02] Constructing a Recommender System using Variational Neural Networks

○Tomoki Ohtsuki[1], Shinsuke Sugaya[1], Ohnishi Yuki[1,2] (1. BizReach, Inc., 2. Purdue University)

5:40 PM - 6:00 PM

[2Q5-J-2-03] A Meta-Learning Perspective on Generative Query Network

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

6:00 PM - 6:20 PM

[2Q5-J-2-04] Variational Auto-Encoder On Stiefel Space

○Takaaki Sanjoh[1], Junpei Komiyama[2], Masashi Toyoda[2], Masaru Kitsuregawa[2,3] (1. The University of Tokyo, 2. Institute of Industrial Science, The University of Tokyo, 3. National Institute of Informatics)

6:20 PM - 6:40 PM

[2Q5-J-2-05] A Study of Pseudo-Simultaneous Systems

○Kotone Itaya[1,2], Naoyuki Sakai[3,4], Koichi Takahashi[1,3,4], Hiroshi Yamakawa[3,4] (1. RIKEN BDR, 2. Graduate School for Media and Governance, Keio University, 3. DWANGO AI Laboratory, Dwango, 4. The Whole Brain Architecture Initiative)

6:40 PM - 7:00 PM

©The Japanese Society for Artificial Intelligence

[2C1-J-12] Human interface, education aid: design and creation

Chair:Kazuhisa Seta Reviewer:Jun Ichikawa

Wed. Jun 5, 2019 9:00 AM - 10:00 AM Room C (4F International conference hall)

[2C1-J-12-01] Game-Based Story Generation Systems Using Player's Emotion and Action

○Shusuke Sato[1], Kaoru Sumi[1] （1. Future University Hakodate）

9:00 AM - 9:20 AM

[2C1-J-12-02] Decision Making for Model Based Design by Reinforcement Learning

○Tatsuhide Sakai[1], Takahiro Inabe[2] （1. Great Wall Motor, 2. Sakiyomi AI labo）

9:20 AM - 9:40 AM

[2C1-J-12-03] Development of New Value Creation and Evaluation System in Breakdance Using Deep Learning

○Naoyuki Hirasawa[1], Daichi Shimizu[2] （1. no new folk studio Inc., 2. Graduate School of Education, The University of Tokyo）

9:40 AM - 10:00 AM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

感情と行動を利用したゲームベースの物語生成システム

Game-Based Story Generation Systems Using Player's Emotion and Action

佐藤 秀輔[*1]
Shusuke Sato

角 薫[*1]
Kaoru Sumi

[*1] 公立はこだて未来大学 システム情報科学研究科
Future University Hakodate School of System Information Science

Abstract: In this research, we developed a game-based story generation system that automatically expands contents by real-time player's emotion and action. When a player plays actions in the created virtual space, the system automatically generates contents according to the action of the player. The idea of this system is as follows. 1) We set unrealistic and magical tool, and the player operates the tool by using the hand controller. 2) The system gets real-time emotions of the player through webcam and FACS (Facial Action Coding System), and outputs a reaction as part of the content according to emotion. 3) The system outputs the text according to the player's action and emotion. We evaluated the usefulness of the system by conducting experiments with elementary and university students as subjects. From the result of the questionnaire, generated story by the system was evaluated as interesting. According to the impression of the story based on the SD method, we could extract three factors of non-immersion feeling, non-novelty and narrativity.

1. はじめに

本研究では，プレイヤの行動とリアルタイムの感情を用いてコンテンツを展開するゲームベースの物語自動生成システムを開発した．

物語生成の研究は例えば以下のようなものが知られている．Dramatica[1]は，質疑応答形式で物語生成の支援を行う脚本制作ツールの一つである．仮想空間に適応させたインタラクティブドラマの研究である Façade[2]は，ゲームに対するプレイヤのインタラクションをテキストで表現することでシステムに対する態度や感情を表現することを可能にした研究である．これらの研究はテキストベースの物語生成であり，仮想空間を用いてユーザの行動をベースとしたものはない．感情と物語は強い結びつきがあることがわかっている[3]．NPC（Non-Player Character）間のインタラクションに応じて，あらかじめ NPC に設定された感情が変動することで物語生成する研究[4][5]もある．しかし，これらの研究では，プレイヤの実際の感情を用いていない．

また，ゲームで感情を利用している研究は以下のものがある．テストプレイヤにセンサーを付けゲームをプレイしてもらい，緊張度のデータを取得し，それに応じて敵の出現パターンなど調整する研究[6]がある．実際のゲームに組み込む際には，テストプレイヤのゲーム内での行動を認識した際に緊張度の割り出しを行いプレイヤの感情の推測している．感情情報を用いた研究では，プレイヤの感情を用いてゲームのレベルデザインを行う研究[7]がある．プレイヤ視点，デザイナー視点で感情を用いたレベルの生成を試みている．ここでアンケートによりゲーム使用中の感情のデータを収集し，ゲームのプレイログや編集ログから感情の推測行っている．また,読者の感情を推測する研究[8]では，物語を単位時間あたりで切り出し，その切り出した物語の中での登場人物の行動により感情を推測する Dramatis というシステムを開発した．このような形でプレイヤの感情を推測しながらゲームデザインなどを行うことはあるが，本研究のようにゲームプレイ中に何らかの手法でリアルタイムのプレイヤの感情を取得しリアルタイムに反映させるゲームはない．

連絡先：佐藤秀輔，公立はこだて未来大学 システム情報科学研究科，北海道函館市亀田中野町 116 番地 2，0138-34-6448，sato.fun0619@gmail.com

以上のように，本研究のようなゲーム内での自由な行動をもととしリアルタイムでの感情を用いたバイオフィードバック型の物語自動生成の研究はほとんどない．そのため本研究では，リアルタイムでの感情や行動を利用することで様々な物語を体験，生成できるシステムを提案する．プレイヤの実際の感情を用いることでプレイヤの物語の体験を利用し物語として生成できるのではないかと考えた．

2. 感情を利用した物語生成システム

本システムではプレイヤの感情と行動を利用してゲームベースでの物語を生成する．感情の取得では FACS(Facial Action Coding System)[9]を利用した表情認識システムである Affdex を用いて感情の取得を行った．FACS とは，視覚的に識別可能な表情動作の最小単位を組み合わせた感情を取得するものである．Affdex では 7 種類の感情(喜び，恐怖，嫌悪，悲しみ，怒り，驚き，軽蔑)を取得できる．行動の取得では Oculus Touch を用いて取得を行った．Oculus Touch とは，卓上に置かれた 2 つのセンサーを用いることで 3 次元の仮想空間上でその位置をトラッキングできるコントローラーである．身体運動を促すゲームは感情的覚醒につながることが示唆されたという実験結果[10]があるため，Oculus Touch を用いて直感的に体を動かすことで感情の覚醒につながる可能性があると考え使用した．

表情を用いた感情の取得を行った点としては，感情取得に特殊なセンサーを用いた場合，センサーを使うということで緊張し，より正確な感情が取得できない可能性が考えられるからである．そこで，特殊なセンサーを用いずカメラから取得できる画像よりプレイヤの感情を推測できる表情を用いた感情取得を行う．将来的に感情を用いたゲームが台頭してくる場合,映像を用いたセンシングはプレイヤへの制約が少なく，自由な意思に基づいて，自由に行動ができることを利点である[11]．そのため本研究で提案するシステムでは表情により感情を取得することで，ゲーム内の行動と合わせた結果が出力されるように設計した．

プレイヤが仮想空間上で何らかの道具を利用することにより話が展開されている状況を設定し，そのプロトタイプとして任意の仮想空間と道具を設定した．プレイヤはある特定の仮想空間上でオブジェクトに対しアクションを行う．仮想空間は日常に近い閉鎖空間をイメージし作成した．プレイヤはその仮想空間上

で現実ではありえないような道具を使用することで物語を生成していく. 今回は, 図 1 の様なオフィスをイメージした仮想空間を作成した. オフィスには休憩スペース(図1左側)と, オフィススペース (図1右側) の 2 つがあり, それぞれは壁で仕切られていない. 休憩スペースには自動販売機がある空間になっている. 本システムでは, 対象のオブジェクトの中から様々なものが取れる道具を作成した. 今回の空間では, 机と自動販売機が道具の対象として設定してあり, それぞれの中からオブジェクトの知識に応じた物体が取り出せるようになっている. 表1では自動販売機の知識を例に挙げている. 取り出せる物体は, その時のプレイヤの感情によって変化する. 例えば, 自動販売機に対し道具を用いてインタラクションを行い, 喜び(Joy)の表情が取得できた場合, システムではお金を取り出すことができる. それを用いて自分の行動, 感情を用いた物語の生成する. 図 2 にシステムの概要図を示す.

物語を考える際, 起承転結の承と転の部分を様々なプレイヤの行動などをもとに吟味し面白いと感じる流れを収集することができると考えた. 結の部分に関しては, 様々な動作を取れるのでそれに応じた物語の結末を用意した. それらの結末に対する分岐は, 自分がどのような動作を行うかによって物語内のパラメータを変化させる. このパラメータは行動に対する善悪の度合いや, 自分の行動に関する空腹度などが設定されている. このように物語のはじめから物語の終わりまでをシステムを使用することで, 一つの物語の作成を行う. 物語は, 黒い丸の書かれた紙を用いることで展開を行っていく. この黒い丸の書かれた紙は, 黒い部分に触れている箇所が物体を通り抜けるようになる道具である. 生成される物語の例として, ものを取り出すことに夢中になり背後に近づいてきた人に見咎められるといった内容の物語ができる. これは,「The Black Hole」と呼ばれるショートムービーから着想を得て, このような物語設定になっている.



図1 仮想空間として用意された休憩スペースとオフィススペース

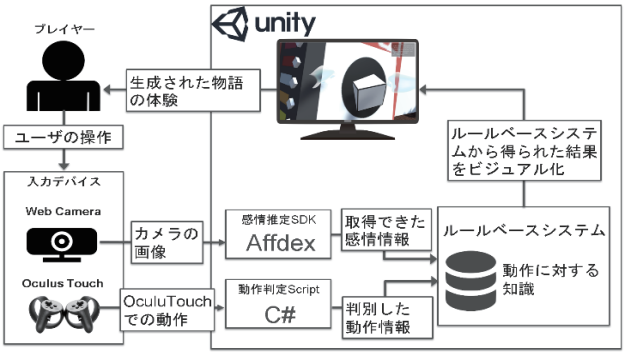


図2 システム概要図

表1 オブジェクトの知識の例(自動販売機)

ColaCan	コーラ	Fear Disgust Sadness Surprise
Gold	お金	Joy Anger Contempt
cockroach	虫	None

2.1 感情取得

カメラを用いてある一定の間隔で取得された画像により表情認識し, 感情を取得できる. 本システムでは, システムで設定した一定の動作をした時に感情の取得が行われる. しかし, 動作をした一瞬の感情を取得するだけでは不十分だと考え, 動作前に取得された 30 回の感情情報によりそのときの感情を推定した. 手法としては, 動作が取得できるまでの感情情報についてそれぞれ 30 件を上限として順に保存を行う. 動作が取得されたら, その 30 件の値をそれぞれの感情の値の合計を算出し, 感情の内どの感情が強く表れていたのかでどの感情だったかの判定を行う. また, 今回は感情情報の値に閾値を設定しており合計した値がどれも 100 を超えなかった場合感情がなかったと判断した.

2.2 文章生成

生成される文章は, (1) 表情を用いて取得された感情, (2) Unity 上で取得されたオブジェクト, (3) オブジェクトの知識から感情情報によって選択された物体, (4) Oculus Touch を用いて行った動作, 上記の 4 つの情報から生成されている文章と, システム側から自動的に付与される文章の 2 通りがある.

生成される文章はある程度型のある文章構造に上記の4つの情報を当てはめることで生成される. 文章の生成例を挙げるとすると,「恐る恐る自動販売機からジュースを取り出した. 」という文章が生成され図 3 のように表示されたとする. バーチャルハンドは Oculus Touch を使用することで表示されており, プレイヤの実際の手の動きと同じ動きをするものである.「恐る恐る」の部分にあたるのが表情を用いて感情取得できた値によって生成される文である. 感情の判定としては, 常に感情情報を取得し続け, 文章が生成される段階で取得していた感情情報の中から直近の 30 フレーム分の感情でどの感情が一番強かったのか判定を行う. そのようにして取得できた感情でどの感情も閾値を超えない場合は感情がないとして判断される.「自動販売機」という箇所は, Unity 上で動作を行った対象のオブジェクトである.「ジュース」という部分は, 自動販売機というオブジェクトの知識から取得できた感情で重みづけを行いその知識からの判断を行う.「取り出した」という部分に関しては, Oculus Touch を用いてどのような動作を行ったかどうかを判断し, 出力される. 取り出したという動作以外では, 置く, 投げる, 手に入れる, 飲食をするという動作の判定を行う. 動作の判定には Oculus Touch の加速度, 仮想空間上のキャラクターのどの部分にオブジェクトを当てたのかで判定を行う.



図3 バーチャルハンドで道具を使って自動販売機からジュースを取り出す

本システムでは，物語の起承転結を考慮し生成する．この物語の起承転結とは，物語の導入の部分が起，プレイヤ操作における部分が承と転，最後にプレイヤがどのような動作を行ったかにより展開される結末の部分が結にあたる．システム側から付与される文章としては，物語の起にあたる部分と結にあたる部分である．起の部分はすべて同じであり，結の部分はプレイヤの動作によって異なる結が展開される．

3. システムの評価実験

本実験の目的は，本システムで生成した物語を評価すること，本システムの面白さや操作性，今後の有用性の評価を行うことである．また，本システムでできた物語の面白さや自然さなどSD 法を使った印象評価やアンケート調査を用いて評価を行った．本実験は，公立はこだて未来大学にて大学生 20 歳から 24 歳の男性 18 名を対象として行った．予備実験の時とは違い大学生 1 名ずつで本システムを一度だけ使用してもらった．

3.1 実験材料

本実験材料として，本システムを利用して生成された物語の評価を行うためアンケートを作成した．アンケートは，生成された物語に対するものとシステムに関する側面のものであった．アンケートの各項目は Q3 以外では「とても思わない」「思わない」「どちらでもない」「思う」「とても思う」の 5 段階評価を用いた．また，Q3 については「感情情報の付与された物語」「どちらでもない」「感情情報の付与されていない物語」の 3 段階で評価を行った．アンケートの各項目は以下の表 3 の通りである． また，実験材料として生成された物語全体の印象を測定するため，SD 法によるアンケートも作成した．表 4 は SD 法の尺度の一覧とアンケート上での位置である．各尺度におけるプラスの印象の項目は網賭けを用いて記載した．各尺度に対する選択肢は，「非常に」「かなり」「やや」「どちらでもない」「やや」「かなり」「非常に」の 7 段階評価を用いた．

表3 アンケートの項目

Q1	生成された物語の面白さ	Q6	手軽に物語が作れたか
Q2	生成された物語の自然さ	Q7	自分の行動から物語ができていると感じたか
Q3	感情情報が付与された文章は場面の想像がしやすいか	Q8	もう一度システムを使ってみたいか
Q4	チュートリアルのわかりやすさ	Q9	別のシチュエーションでも使ってみたいか
Q5	システムの操作しやすさ		

表4 SD 法の各項目

アンケート用紙上で左側	アンケート用紙上で右側
自然な	不自然な
理性的な	感情的な
面白い	つまらない
様々な	単調な
めちゃくちゃな	物語性のある
飽きやすい	夢中になる
動的な	静的な
個性的な	ありふれた
能動的な	受動的な
読みにくい	読みやすい

3.2 実験結果の処理方法

アンケートの結果の処理方法としては，「とても思わない」から「とても思う」までをそれぞれを 1 点から 5 点まで順に点数付けを行い集計した．Q3 の項目では「感情情報の付与された物語」という選択肢を 1 点とし，それ以外を 0 点として点数付けを行い集計し，それらの結果が有意であったのか調査をするため 1 変量の χ^2 検定を行った．SD 法の結果の処理方法は，左側にある「非常に」から右側にある「非常に」までを-3 点から 3 点まで順に点数付けを行い集計した．そして， SD 法の結果より因子を抽出し本システムで生成された物語の印象を調査するために重みなし最小二乗法のプロマックスによる因子分析を試みた．なお，全ての分析は IBM SPSS Statistics 25 を用いた．

3.3 実験結果

各アンケート項目を集計し，1 変量の χ^2 検定を行ったところ，物語の面白さ，場面の状況の想像性，物語生成の手軽さ，行動から物語が作成できているか，もう一度作ってみたいか，別の仮想空間でも使用したいかといった項目で有意な差があり，本システムは手軽に物語生成ができるとわかった．SD 法を行った結果を集計しセマンティックプロフィールをプロットした（図 4）．また，重みなし最小二乗法のプロマックスによる因子分析を行った結果を表 5 に示した．因子分析の結果を元に因子解釈を行ったところ非没入感，非斬新性，物語性といった 3 つの因子を抽出することができた(表 6)．

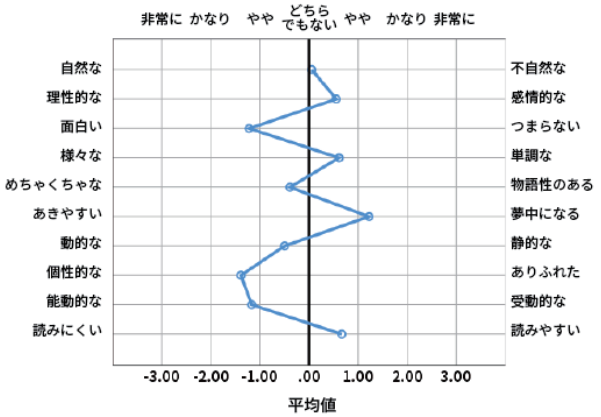


図 4 セマンティックプロフィール

表5 因子負荷量一覧

形容詞		1 因子	2 因子	3 因子
様々な	単調な	0,929	-0.279	0.261
動的な	静的な	0.922	-0.024	-0.241
面白い	つまらない	0.550	0.290	-0.043
飽きやすい	夢中になる	-0.533	-0.439	-.050
理性的な	感情的な	-0.317	-0.199	-0.240
能動的な	受動的な	0.063	0.903	0.658
個性的な	ありふれた	0.091	0.658	-0.042
自然な	不自然な	0.134	-0.542	0.037
読みにくい	読みやすい	-0.168	0.233	0.732
めちゃくちゃな	物語性のある	0.163	-0.238	0.591
回転後の負荷量平方和		2.722	2.322	1.098
寄与率		31.036	15.409	10.435
累積寄与率		31.036	46.445	56.880

表6 因子解釈

因子	形容詞	因子の解釈
1	単調な・静的な・つまらない・飽きやすい	非没入感
2	飽きやすい・受動的な・ありふれた・自然な	非斬新性
3	読みやすい・物語性のある	物語性

4. 考察

システムに関するアンケート結果から，本システムは比較的簡単に物語の生成ができることが分かった．これに関しては，複雑な選択を行うということが少なかったことも要因であると考えられる．また，「もう一度システムを使って物語を作成したいのか」という項目で有意であったので楽しみながら物語の作成が行えたということが分かった．楽しみながら生成を行えるということで同じプレイヤが何度もプレイを行い，さまざまなパターンの物語を生成してどの物語が面白いのか吟味ができるようになると考えられる．加えて他の仮想空間でもこのシステムを体験したいという結果が得られた．得られた意見の中では，「身近な大学生活などでも生成された物語を見てみたい」といった現実に近い仮想空間でも試したいという意見があった．また対立意見として，「現実には存在しないところでやるとどうなるのか気になる」といった仮想空間でしか体験できない環境で本システムを用いて物語を作成したいという意見が得られた．このような意見から，今回の環境に限らずさまざまな環境でも感情や，行動を用いて物語を体験しながら物語が生成されていくシステムは有用なのではないかと考える．

生成された物語に関するアンケートでは，生成された物語は面白いという意見が多かった．自由記述の部分から，「自分の行動が文章となって再度客観的に読めること自体が面白かった」といった自分の行動からできている箇所が評価されている事がわかった．これより，仮想空間上でテキストベースではなく，行動ベースで物語を生成することは有用であると考える．また，感情情報の付与の有無を比較したアンケートでも感情情報が付与された物語の方が場面を想像しやすいという結果が得られた．この部分に関しては，「何をしていたのか想起されやすいから．感情情報がないと他人の行動を見ているみたいだから」「虫が嫌いだから投げたなどがあとからわかるから」といったあとから見直した場合でも状況がわかる文章の作成ができることが分かった．また，このように流れがわかることでこの生成された物語を元に加筆してより情報を付加して面白い物語ができるのではないかと考える．

SD 法から非没入感，非斬新性，物語性という 3 つの因子が抽出された．非没入感という因子では，生成された物語がほとんど行動履歴のようになっており単調な物語が生成されていたことが原因の一つとして考えられる．この部分の改善に関しては，自然言語処理などを挟むなどをしてより実際の物語の様な文章を生成するといったことをして生成される各文に関して違和感のないように工夫する必要があると考えられる．もしくは，今回はどのような物に対してインタラクションをしたのかどうかのみで文章が生成されていたが，よりいろいろな行動や感情の変動に関して文章を生成できるようにすることで改善ができると考えられる．非斬新性という因子では，場面や行動に対する変化が少なかったのが原因なのではないかと考える．今回の仮想空間の場面はオフィス内ということで仮想空間に大きな斬新性がなかったのが原因の一つではないかと考えられる．また，物体に対するインタラクションや道具を用いたインタラクションに関してもできる行動がそこまで多くなかったのがこの因子が抽出されたのだと考える．アンケートの自由記述でもあったが，「手をいれるだけでなく，自分が黒い丸に入ったりするシチュエーションとか面白そうなのでいろいろ作ってみたい」という事があったので今回の道具の機能の拡張や新しい道具を追加することで改善できるのではないかと考えられる．加えて，別のシチュエーションでも試したいというアンケートの結果が有意であったため別のシチュエーション等選択や分岐を行うことでこの部分の改善に繋がると考えられる．物語性という因子では，今回生成された物語がある一つの流れを保って物語の結末まで展開することができたことが要因であると考える．この部分に関しては，今回のシステムではどのような動作を行ったらその結末に分岐するという形での分岐を行っていた．そのことにより不自然な流れで物語が終了するのではなく，自然な流れで物語が終了していたことが要因でと考える．

5. まとめ

最後に結論として，本システムである，リアルタイムのプレイヤの感情と行動をもとに物語生成をするシステムは，手軽にさまざまな物語が生成できるということが考えられる．ただし，課題点として生成できた物語に没入感や，斬新性がないことがあげられる．これらを踏まえて，今後はさまざまなインタラクションを行うことができる道具を追加したり他の仮想空間を用意するということが展望となった．

謝辞

実験にご協力いただきました函館市立赤川小学校の皆様，公立はこだて未来大学の皆様に感謝を申し上げます．

参考文献

[1] Melanie Anne Phillips, Chris Huntley, Dramatica : A New Theory of Story, http://storymind.com/free-downloads/sa_article.pdf, 2018/11/28

[2] Michael Mateas, Andrew Sterm, Façade: An Experiment in Building a Fully-Realized Interactive Drama, Game developers conference, 2003

[3] Gordon Calleja, Laura Herrewijn, Karolien Poels, Affective Involvement in Digital Games, Emotion in Games pp 39-56, 2013

[4] Hsueh-Min Chang, Von-Wun Soo: Planning-Based Narrative Generation in Simulated Game Universes, IEEE Transactions on Computational Intelligence and AI in Games (Volume: 1, Issue: 3, Sept. 2009)

[5] Marc Cavazza, Marc Cavazza, Fred Charles, Thurid Vogt, Thurid Vogt: Emotional input for character-based interactive storytelling, AAMAS '09 Proceedings of The 8th International Conference on Autonomous Agents and Multiagent Systems - Volume 1, Pages 313-320

[6] Michael Booth, "The AI Systems of Left 4 Dead," Artificial Intelligence and Interactive Digital Entertainment Conference at Stanford.

[7] J Togelius, GN Yannakakis, Emotion-Driven Level Generation, Emotion in Games, 2016

[8] B O'Neill, M Riedl, Emotion-Driven Narrative Generation, Emotion in Games, 2016

[9] Paul Ekman, Facial Action Coding System, A human face, 2002

[10] Nadia Bianchi-Berthouze, Katherine Isbister, Emotion and Body-Based Games: Overview and Opportunities, Emotion in Games, pp 235-255, 2013

[11] Irene Kotsia, Stefanos Zafeiriou, George Goudelis, Ioannis Patras, Kostas Karpouzis, Multimodal Sensing in Affective Gaming, Emotion in Games, pp 59-84, 2013

Decision Making for Model Based Design by Reinforcement Learning

Tatsuhide Sakai[*1] Takahiro Inabe [*2]

[*1] Great Wall Motor [*2] Sakiyomi AI labo

The Model Based Design is identified that hierarchy is structured on functions of each part to achieve a competitiveness in a product design. As the hierarchy becomes complicated, design variables have a huge data space, so it is difficult to properly make decisions in a short time even if a designer has extensive experience. It is verified whether Reinforcement Learning is effective for the design of electric vehicles. When applied to the vehicle performance of the top of hierarchy, the design limit of energy consumption was derived from the variables space of 128 to the 17th power and the optimal solution for Package was learned from the variables space of 10 to the 77th power.

1. Introduction

In the product design of automobiles etc., a method based on model base design (hereinafter described as MBD) is often used. The product performance is made hierarchically related to the part function, this method is effective for securing competitiveness. Since it is structured on logical expressions such as design calculations, quantitative consideration is possible, but it is difficult to decide an appropriate design specification because choices are enormous. It is verified whether Reinforcement Learning is effective for decision making of design variables in MBD by using vehicle performance design.

2. Model Base Design

2.1 Electric Vehicle Concept Design

The design objects of vehicle performance are environment, power, dynamic quality, package, strength endurance, and correlation of related functions is complicated and intertwined.

- Level 0: Phenomenon of customer experience
- Level 1: Combination of multiple components which has difficulty with each individual change
- Level 2: Single component which can be changed

It is tried applying Reinforcement Learning to EV design calculation of environmental performance and Package, to realize a long mileage with less battery & a large cabin. (Fig.1)

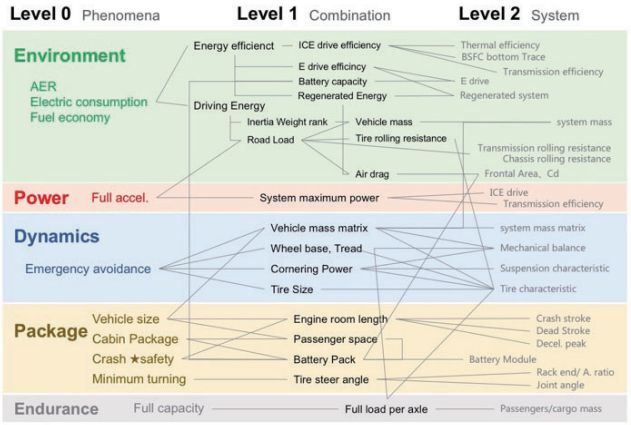


Fig.1 Model Base Design for Vehicle performance

Contact: Tatsuhide Sakai, Great Wall Motor, 2076Chaoyang Nan Da Jie Baoding Hebei China, jiujinglongying@gwm.cn

2.2 Vehicle Energy Design

The evaluation values are energy efficiency, electricity consumption and mileage. It is the design goal to reduce the vehicle driving energy and improve the electric drive efficiency and increase the regenerative energy to increase the mileage by suppressing the battery capacity.

$$E_{Effi} = W/(W_c + W_{re}) \quad (1)$$

$$E_{Cons} = (W_c + W_{re})/L_{all} \quad (2)$$

$$AER = Batt_{capa}/E_{Cons} \quad (3)$$

E_{Effi}: *energy efficiency*

E_{Cons}: *electric consumption*

AER: *electric driven mileage*

W: *vehicle driven Energy*

W_c: *battery consumption energy*

W_{re}: *regenerated energy*

$Batt_{capa}$: *battery electric capacity*

Evaluation values are set the three performances on left side of Equation (1), (2) and (3). Design variables are set 17 functions which is related to rolling resistance, aerodynamic resistance, accelerating resistance, electric drive efficiency and regeneration efficiency which are components of evaluation values.

2.3 2.3 Vehicle Package Design

37 design variables are set from the C.G., mass, and geometries of each component and so on. (Fig.2) 12 evaluation values are set as their performances of environment, dynamics, package.

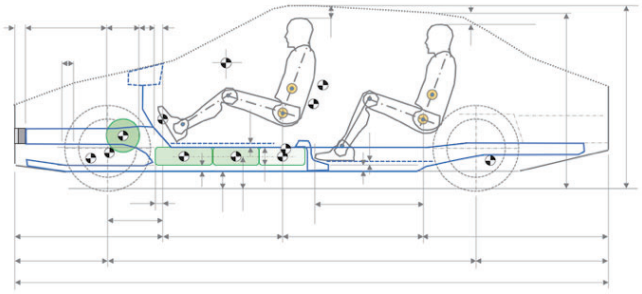


Fig.2 Design variables for vehicle package

3. Reinforcement Learning

3.1 Modeling

Neural Network is individually set for each of Energy Design and Package Design, design variables of Model Based Design are set as input, and performance evaluated values are set as output. (Fig.3)

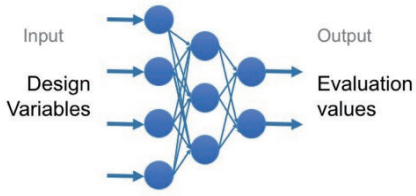


Fig.3 Neural Network for Design Calculations

In order to learn the Neural Network weighting parameters, a value-based function and a policy-based function in the Markov decision process are used.

$$(S_t, a_t) = r_t + \gamma \max_{a_t} Q(S_{t+1}, a_{t+1}) \quad (4)$$

$$V(S_t) = \max_{a_t} r_t^a + \gamma V(S_{t+1}) \quad (5)$$

$Q: Value\ based\ function, V: policy\ based\ function$

$S: situation, a: action, r: reward, \gamma: learning\ rate, t: time$

3.2 Variable and Evaluation

The range of the design variable is set from the minimum value and the maximum value. The variable selection can be made between the minimum value and the maximum value.

$$x_{i,n} = x_{i,min} + n \cdot \frac{x_{i,max} - x_{i,min}}{n_{max}} \quad (6)$$

$i = 1, \dots, i_{max}, n = 1, \dots, n_{max}$

$x: design\ variable, i: number\ of\ variables, n: division$

A reward is made determined depends on an evaluation which is calculated from the priority of performance evaluated values and sensitivity of design variable ranges to them.

$$Eva_t = function_1(w_j, y_j, b_j, c_i) \quad (7)$$

$$r_t = function_2(Eva_t) \quad (8)$$

$Eva: evaluation, r: reward,$

$w: priority, y: performance\ evaluated\ value, b: constant,$

$c: sensitivity, j: number\ of\ performance\ evaluated\ value,$

$i: number\ of\ design\ variable\ ranges$

4. Verification Result

The experimental programs are coded with DQN, MCT, A3C.

4.1 Theoretical Limit of the Design Calculation

Design limits of vehicle energy performance can be calculated. It is already known that the performance limit can be calculated in case of the loss related variables are minimized and the electric efficiency related variables are maximized, when the Battery capacity become maximum in its design variable range. The results of Reinforcement Learning are shown in Figure 4. The range of design variable is normalized to be 0.7 to 1.0 It was verified that the design limit was perfectly found by DQN in 128^{17} data space (17variables, 128choices). For MCT, only one variable result differently. This variable is a source of another variable, but it turns out not such a difference as to change another. There is almost no influence on performance evaluated value due to so small contribution.

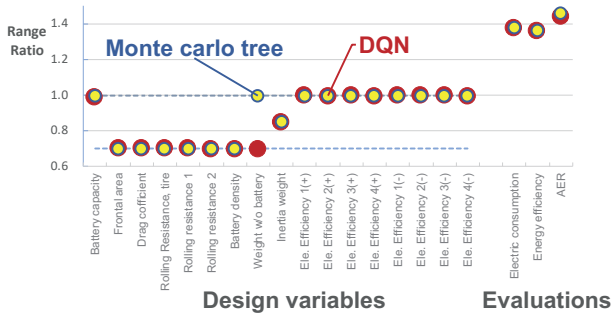


Fig.4 Learning Results for Vehicle Energy Design

4.2 Solutions in the threshold

In the case of Vehicle Package, since each of the 37 variables is set to 128 choices, the data space of the design variable is 128^{37} (10^{77} more). From the huge Data space, a solution will be searched for that matches competitiveness (a data set combination of 37 variables). A threshold value worthy of design consideration was set to the performance evaluated value and learned by A3C to achieve it.

Solutions reaching the threshold can be learned to 61, 101 set. In this report, the optimum solution is selected for the design concept (the long mileage, the large cabin, the small battery, more than current competitors on the market). The standard deviation and the optimal solution are shown in Fig.5. The optimal solution exists within the deviation, and it can be understood that competitiveness cannot be secured unless it is designed within this range.

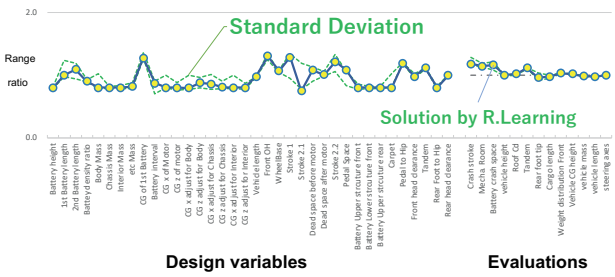


Fig.5 Learning Results of Vehicle Package Design

4.3 The optimal solution versus an expert design

Figure 6 shows a comparison of the optimal solutions by Reinforcement Learning and the result by authors. It can be known that vehicle package by Reinforcement Learning has better frontal collision performance than the design by author. On the design by Reinforcement Learning, the rear passenger space and cargo capacity which have trade off relationship to frontal collision are

worse but kept on the threshold. It can be said that the design by Reinforcement Learning is better.

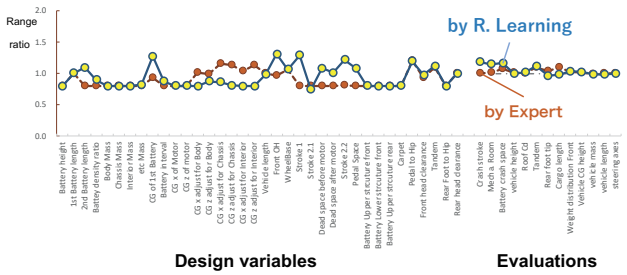


Fig.6 Comparison of Learning result with an expert's

It can be considered that the design to make use of the space efficiency of the rear part of the vehicle to the front part of the vehicle was obtained because the setting of the priority of performance and sensitivity of design range in Reinforcement Learning was appropriate. The performance evaluated values of the vehicle package are the following items.

- Vehicle height, Roof geometry (Air drag)
- Frontal collision stroke
- Driving position, driver space
- Rear passenger space
- Cargo capacity
- C.G., Vehicle mass

It turns out that each of them forms a continuous space. (Fig.7) It is a multi-disciplinary relationship, and even if a designer has lots of experience, it will not be a reason to get the optimal solution. In the case that the design variables have a complex trade off to the evaluation values, the Reinforcement Learning can search the design variables widely and deeply according to the priority of the performance evaluated value and the sensitivity of the design variable ranges. The depth & width of the search range is an advantage superior which the designer cannot have.

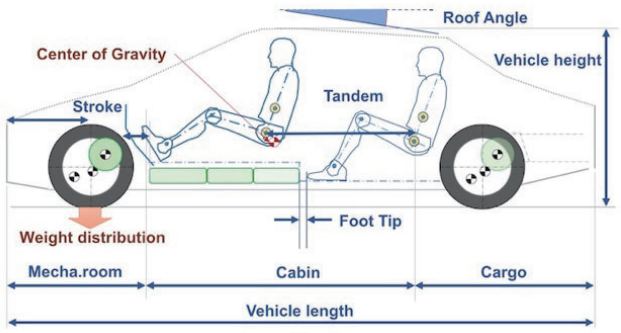


Fig.7 Evaluation values for vehicle package

5. Conclusion

When Model Based Design has a hierarchical structure that is multilayered and the design variable has a huge data space, Reinforcement Learning has superiority in determining optimal design specifications.

- The greatest advantage of Reinforcement Learning is the breadth and depth of search for design variables, even skilled mature people can never catch up.
- In order to make full use of advantage, it is necessary to enrich the logical formulas to build MBD, such as design calculations, Database and so-on.
- The role of the designer changes to making the priority of the evaluation value and the sensitivity of the variable faithfully conform to the design purpose.
- It will not be the role of the designer to search for variables that reach the performance threshold.
- The learning performance of A3C is very high, various choices of reaching the threshold are obtained and it is possible to design with deviation taken into account.

In this report, the priority of the performance evaluated values and sensitivity of the variable range for the value-based function and the policy-based function are set by trial and error. Their grounds are considered by an author through the way to overtake the competitor and the balance of performance targets. In the next stage they will be made objects of Reinforcement Learning.

References

[Sakai 2018] Tatsuhide Sakai: An Automatic Search to EV design variables using Reinforcement Learning, EVS31 Kobe Japan, 2018.

[Mnih 2016] Volodymyr Mnih: Asynchronous Methods for Deep Reinforcement Learning, ICML arXiv:1602.01783, 2016.

[Mnih 2015] Volodymyr Mnih: Human-level control through deep reinforcement learning, nature142236, NATURE VOL518, 2015.

[Mnih 2013] Volodymyr Mnih: Playing Atari with Deep Reinforcement Learning, NIPS arXiv:1312.5602v1, 2013.

[Silver 2017] David Silver: Mastering the game of Go without human knowledge, nature24270 NATURE VOL550, 2017.

[Silver 2016] David Silver: Mastering the game of Go with deep neural networks and tree search, nature16961 NATURE VOL529, 2016.

[Szepesvari, 2017] Csaba Szepesvari: Algorithm of Reinforcement Learning, Kyoritsu Publishing, 2017.

[Gruslys 2018] Audrunas Gruslys: THE REACTOR: A FAST AND SAMPLE-EFFICIENT ACTOR-CRITIC AGENT FOR REINFORCEMENT LEARNING, International Conference on Learning Representations, 2018.

[Hasselt 2016] Hado van Hasselt: Deep Reinforcement Learning with Double Q-learning, AAAI arXiv:1509.06461, 2016.

[Brockman 2016] Greg Brockman: OpenAI Gym, arXiv:1606.01540, 2016.

[Lillicrap 2015] Timothy P. Lillicrap: Continuous control with deep reinforcement learning, arXiv:1509.0297v1, 2015.

[Bergstra 2012] James Bergstra: Random Search for Hyper-Parameter Optimization, Journal of Machine Learning Research 13, 2012.

[Diaconis 2009] Persi Diaconis: The Markov chain Monte Carlo revolution, BULLETIN of the AMERICAN MATHEMATICAL SOCIETY 46, p179-205, 2009.

[Patterson 2017] Josh Patterson: Deep Learning A Practitioner's Approach, O'Reilly Media, p.1-403, 2017.

[Sugomori 2017] Yusuke Sugomori: Deep Learning: Practical Neural Networks with Java, Packt Publishing, 2017.

[Sugomori 2017] Yusuke Sugomori: 詳解ディープラーニング, MyNavi publishing, p.023-208, 2017.

[Sugomori 2016] Yusuke Sugomori: Deep Learning Java programming, Packt publishing, 2016.

[Sugomori 2016] Yusuke Sugomori: Deep Learning Java プログラミング 深層学習の理論と実装, Impress corporation, 2016.

[Henrik 2017] Henrik B.: Machine Learning, Impress corporation, 2017.

[Bostjan 2016] Kaluza Bostjan: Machine Learning in Java, Packt Publishing, 2016.

[Fujita 2016] K. Fujita, A.Takahara: 実装ディープラーニング, Ohmsha, 2016.

[Makino 2016] T. Makino: これからの強化学習, Morikita publishing, 2016.

[Saito 2016] Y. Saito: Deep Learning–Python, O'Reilly Japan, 2016.

[Okatani 2015] Takayuki Okatani: Deep Learning Machine Learning Professional Series, Kodansha, 2015.

[Ohlsson 2011] Stellan Ohlsson: Deep Learning: How the Mind Overrides Experience, Cambridge University Press, 2011.

[Otsuki 2017] K. Otsuki: 最強囲碁 AI アルファ碁解体新書, Shoeisha, 2017.

[Sutton 2000] Richard S. Sutton: Reinforcement Learning, Morikita publishing, 2000.

[Karim2018] Md. Rezaul Karim: Scala Machine Learning Projects, Packt Publishing, 2018.

[Shimada 2017] N. Shimada: Chainer with Deep Learning, Gijyutsu Hyoron, 2017.

[Chiusano 2015] Paul Chiusano: Scala Functional type design & programming, Impress corporation, 2015.

[Gibson 2017] Adam Gibson. "Deep Learning for Java". DL4J. https://deeplearning4j.org, accessed 2017-12-10.

[Silver 2017] David Silver. "Lecture 1: Introduction to Reinforcement Learning". 2017-12-12. http://www0.cs.ucl.ac.uk/staff/d.silver/web/Teaching_files/intro_RL.pdf, accessed 2017-12-26.

[Silver 2017] David Silver. "UCL Course on RL". University College London. 2015-12-31. http://www0.cs.ucl.ac.uk/staff/D.Silver/web/Teaching.html, accessed 2017-12-11.

[Sutton 2018] Richard S. Sutton. "Policy Gradient Methods for Reinforcement Learning with Function Approximation". Neural Information Proceeding Systems Foundation Inc. https://papers.nips.cc/paper/1713-policy-gradient-methods-for-reinforcement-learning-with-function-approximation.pdf, accessed 2018-03-20.

[Bergstra 2018] James Bergstra. "Algorithms for Hyper-Parameter Optimization". Neural Information Proceeding Systems Foundation Inc.. https://papers.nips.cc/paper/4443-algorithms-for-hyper-parameter-optimization.pdf, accessed 2018-1-18.

[Kim 2018] Hyunsoo Kim. "Awesome Reinforcement Learning". Awesome-rl. 2018-1-8. https://github.com/aikorea/awesome-rl, accessed 2018–1-24.

[Szepesvari 2009] Csaba Szepesvari. "Algorithms for Reinforcement Learning". Department of Computing Science University of Alberta. 2009-6-9. https://sites.ualberta.ca/~szepesva/papers/RLAlgsInMDPs.pdf, accessed 2017-12-20.

[WU 2017] YUHUAI WU. "OpenAI Baselines: ACKTR & A2C". OpenAI. 2017-8-18. https://blog.openai.com/baselines-acktr-a2c/, accessed 2017-12-14.

[KARPATHY 2017] ANDREJ KARPATHY. "Evolution Strategies as a Scalable Alternative to Reinforcement Learning". OpenAI. 2017-3-24. https://blog.openai.com/evolution-strategies/, accessed 2017-12-22.

[Benesse 2017] "強化学習とは？ALPHAGO でも使われている強化学習を丁寧に解説". みんなの AI 講座 ゼロから Python で学ぶ人工知能と機械学習. 2017-12-11. https://udemy.benesse.co.jp/ai/reinforcement-learning.html, accessed 2017-12-23.

[DeepAge 2017] "これさえ読めばすぐに理解できる強化学習の導入と実践". DeepAge. 2017-8-10. https://deepage.net/machine_learning/2017/08/10/reinforcement-learning.html, accessed 2017-12-16.

[BrainPad 2017] BrainPad. "強化学習入門 ～これから強化学習を学びたい人のための基礎知識～". Platinum Data Blog. 2017-2-24. http://blog.brainpad.co.jp/entry/2017/02/24/121500, accessed 2017-12-15.

[Kanakubo 2018] Masaaki Kanakubo. "強化学習". laboratory of Intelligent interaction Department of computer science Shizuoka Institute of Science and Technology. http://www.sist.ac.jp/~kanakubo/research/reinforcement_learning.html, accessed 2018-1-8.

[saltcooky 2018] saltcooky. "強化学習を強化学習（1）". Qiita. 2018-02-25. https://qiita.com/saltcooky/items/312e5a4919cf197a9307, accessed 2018-3-12.

[pytry3g 2018] pytry3g. "強化学習をしてみた". Qiita. 2018-2-1. https://qiita.com/pytry3g/items/024d06c52a5dfd681d94, accessed 2018-02-18.

[sugulu 2017] sugulu. "これから強化学習を勉強する人のための「強化学習アルゴリズム・マップ」と、実装例まとめ". Qiita. 2017-10-30. https://qiita.com/sugulu/items/3c7d6cbe600d455e853b, accessed 2017-12-21.

[daisuke 2017] daisuke-team-ai. "強化学習事例集 by Team AI". Qiita. 2017-10-25. https://qiita.com/daisuke-team-ai/items/ace0e1b098ee0bced127, accessed 2017-12-11.

[icoxfog417 2017] icoxfog417. "ゼロから Deep まで学ぶ強化学習". Qiita. 2017-6-6. https://qiita.com/icoxfog417/items/242439ecd1a477ece312, accessed 2017-12-13.

[evk-yk 2017] evk-yk. "強化学習で参考になったサイトまとめ". Qiita. 2017-3-27. https://qiita.com/eve_yk/items/2ace6d4c1dad7e912df1, accessed 2017-12-10.

深層学習を利用したブレイクダンスにおける新しい価値の創出・評価システムの開発

Development of New Value Creation and Evaluation System in Breakdance Using Deep Learning

平澤 直之[*1]
Naoyuki Hirasawa

清水 大地[*2]
Daichi Shimizu

[*1] 株式会社ノーニューフォークスタジオ
no new folk studio Inc.

[*2] 東京大学大学院教育学研究科
Graduate School of Education, The University of Tokyo

Abstract: In this research, we developed a system which automatically discriminates motion and visualizes the result in breakdance which is spreading widely in recent years. At that time, we aimed to develop a system that uses shoes incorporating an acceleration sensor (Smart Footwear Orphe) to classify movements under natural environment by deep learning and feed back the results to dancers. In this presentation, as well as introducing the system, we also report on the course of the case of evaluating the degree of originality of movements by applying the above system. Also, we examine how this case affects dancers by being incorporated into dance culture.

1. はじめに

本研究では，近年広く普及しつつあるダンスジャンルの 1 つであるブレイクダンスを対象に，自然な環境下での動作を自動的に判別・可視化するシステムの開発を行った．その際，加速度センサーを組み込んだ靴（スマートフットウェア Orphe）によってデータを測定した．そして，その加速度データに対する深層学習を行い，動作の分類を行うモデルを構築してシステムに組み込んだ．本研究では，当該システムの概要に関して紹介するとともに，上記のシステムを応用し，ブレイクダンスにおいて非常に重要性を有する動作のオリジナリティーの程度を評価する事例の途中経過を報告する．また，本研究がダンスカルチャーに及ぼす影響を考察する．

2. ブレイクダンスの歴史・特徴

ブレイクダンスは 1960 年代後半に New York のブロンクス地区において誕生した踊りである[OHJI 2001; Watkins 2005]．元々地域の若者によって開催されていたブロック・パーティーの中で生まれたものであったが，次第にギャングらの抗争の代替として利用されるようになり，その中で発展を遂げていった．その後，映像や放送メディアによって取り上げられるなど徐々に一般大衆にも広く着目されるようになっていき，現在では大企業主催の国際大会も開催されるなど世界中に広く普及しているダンスジャンルの 1 つである．実際の大会の例としては，RedBull BC One （ http://bcone.redbull.com/en_INT ） や Silverback（https://www.udeftour.org/）などが挙げられる．

ブレイクダンスでは，上記した歴史的背景もあり，バトルという複数名のダンサーが交互に踊りを披露するパフォーマンス形式が定着しており，様々な大会で用いられている．特にバトルでは，各ダンサーは領域において既に確立された動作や自ら創造した独創的な動作を複数組み合わせることで，1 つのパフォーマンスを披露していく（図 1 参照）．そして，それらの構成要素やパフォーマンスの質が，その独創性や音楽性，ダイナミックさ等によってジャッジに評価される．本研究では，このパフォーマンスを構成する重要な要素である動作の種類を自動的に判別し，その応用としてオリジナリティーの程度を評価し可視化するシステムの構築を目指した．

連絡先：平澤直之，株式会社ノーニューフォークスタジオ，東京都渋谷区神南一丁目 12 番 16 号アジアビル 6 階，hirasawa@no-new-folk.com

3. 目的

上記した通り，本研究ではブレイクダンスにおけるパフォーマンスを構成する各動作を自動的に判別，そのシステムを応用して動作のオリジナリティーの程度を評価し可視化するシステムの構築を目指した．またデータについて，3 軸加速度センサーを組み込んだ靴によって測定することで，可能な限り自然な状況下（現実に営まれる練習場面や実践場面）における動作判別・可視化を行うことを目指した．これらの状況下で動作判別・可視化を行うことの出来るシステムは，例えばダンススクールにおけるレッスン等の教育場面や，ダンスバトルにおいてジャッジの評価指標として機能すると考えられる．

また，これまでに既存のダンサーから評価されてこなかったような動作についても，新しい価値基準を設けることでダンススタイルの発展を促進することが可能であると考えられる．

4. システムの概要

4.1 動作の判別手法

オリジナリティーの高い動作を評価するために，まずブレイクダンスにおける基本的な動作（オリジナリティーとしては低いもの）を区別できている必要がある．ここでの動作の判別に関する手続きは以下の通りである（図 2 参照）．なおデータ測定の手続き等に関しては，[Kwapisz 2011]や[岩澤 2015]を参考とした．まず，ブレイクダンスに 10 年以上の経験がある第一著者，第二著者と 1 名の熟達したダンサー（大会等での優勝経験有り）が上記したセンサー付属の靴を装着し，領域に存在する基本的な 17 種類の動作を反復して実施した（stop, walk, toprock, indianstep, salsarock, crossdown, sixstep, fourstep, threestep, twostep, onestep, CC, windmill, backspin, thomasflare, halo, airflare）．そして，これらの動作実施時の左右脚部の 3 軸加速度データを取得した[1]．結果として，17 種類の動作について計 3012 個のデータを測定している．

[1] なお，加速度データの測定の粒度は Bluetooth LE の通信状況にも依存するが，約 40Hz 前後であった．後述するよ

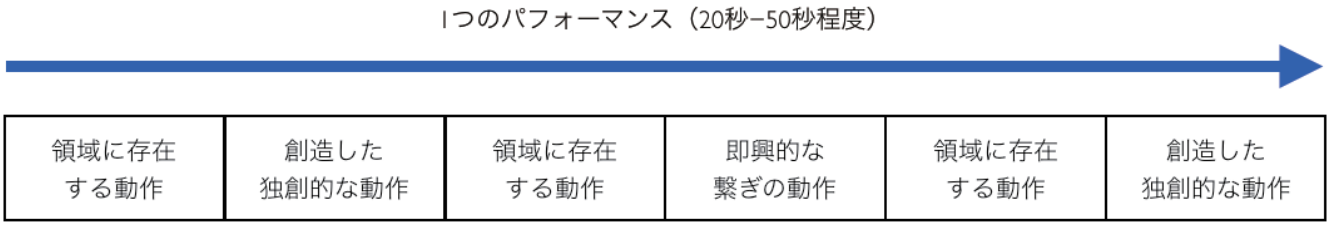


図1. ブレイクダンスにおけるパフォーマンスの1例. 煩雑になることを避けるために、動作の数や種類については大幅に省略しており、通常はより多くの数・種類の動作によってパフォーマンスが構築される場合が多い.

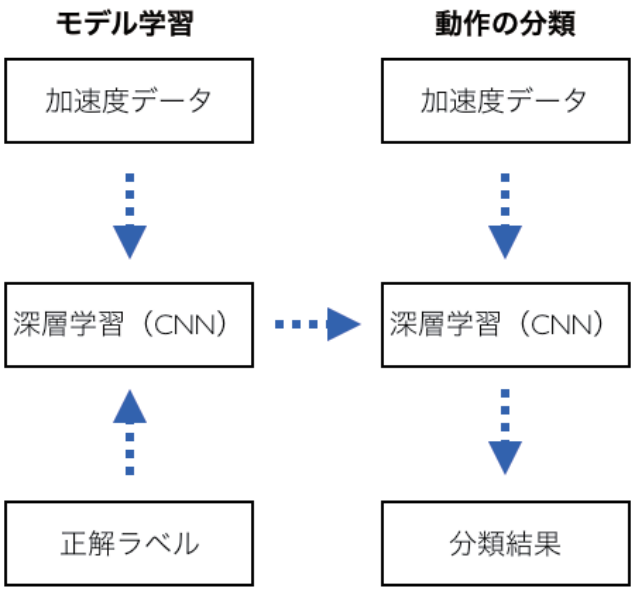


図2. システム構築の手続き

次に，上記の加速度データと正解ラベルの中の 2259 個(75%)を学習データとして利用し，モデルの構築を行った．具体的には，上記した左右脚部の 3 軸加速度センサーによって測定した 6 変数の加速度データについて，50 個の連続値を 1 単位の学習データとして入力し，その際の動作の正解ラベルを用いて教師あり学習を行った．学習においては，畳み込みニューラルネットワーク(CNN)による多クラス分類の手法を用いている．なお，測定した動作の加速度データでは，時間経過による値の著しい変化が見られており，その情報をより強く反映した分類を行う手法として，上記の学習手法を選択した．

次に，学習したモデルを利用し，測定した加速度データ値に基づいて動作を分類するシステムを構築した．ここでは 6 変数の加速度データを入力として用い，モデルによる出力値を動作の分類結果とした．なお，測定した全データ 3012 個の内，753 個(25%)をテストデータとして利用し，実際に分類精度を確認したところ，結果として約 98%という高い精度が示唆された．

4.2 動作の可視化手法

次に，分類したデータの可視化システムの概要を説明する．分類したデータは，実際にシステムを利用するダンサーやイベントでのオーディエンスにとっての理解の容易さを重視した可視化を行った．実際に動作分類の結果を可視化した例を図 3 に示す．まず動作分類の結果については，各動作に分類された

うに，この粒度で測定したデータ 50 個を 1 つの単位とし学習データ，テストデータとして利用した．



図3. 動作分類の結果を可視化した例

確率について，視覚情報として簡易に理解可能なグラフによって表現した．また，ブレイクダンスのパフォーマンスにおける動作の連なりの重要性を考慮し，1 つ前の動作から途切れることなくシームレスにグラフが変化するよう表示方式を調整した．また，ダンサーが利用する上では，パフォーマンスを実施した場で結果をすぐに確認し，フィードバック可能であることが望ましい．以上の要件を踏まえ，動作実施後，可能な限り短い遅れで分類結果を表示・記録するリアルタイム性を重視したシステム構築を行った．

5. システムの応用と課題

5.1 オリジナリティーの程度の評価

次に上記のシステムを応用して動作のオリジナリティーの測定を行い，その結果をフィードバックする新たなシステムを構築した．まず，データ収集の対象となるダンサー間で各個人が独自に創造した動作に対し，評価が偏らないように協議の上ダンサー自身がオリジナリティーの程度を決定，その程度別にデータを分類しラベル付けを行った．補足として，すでに上記してある 17 種類の基本的動作のようなデータは，オリジナリティーの程度の低いものとしてラベル付けする．この手法に基づいて学習用のデータを収集し上記した CNN 深層学習モデルに学習させた．このようにして得られた学習済みモデルに図 2 と同様に加速度データを入力すると，各クラスの予測確率が出力される(もちろん，入力したデータの特徴に近いクラスの確率が高くなる)．その際，各クラスの確率の値にオリジナリティーの程度が高いクラスの方が大きくなるような値を乗算し算出された各値の合計値をその時点での動作の評価値とする(算出例は図 4 を参照)．ダンサーは事前に設定された評価回数分(COUNT)が満たされるまで自由に踊り，その間の評価値を合計して結果が 0~100 になるように変換した値をそのダンサーの一連の動作の最終的なオリジナリティーの程度(SCORE)として可視化を行っ

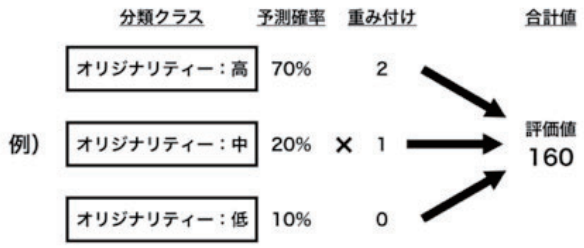


図4. オリジナリティーの評価値の算出例

た. 実際にオリジナリティーの程度を可視化した例を図 5 に示す.

本システムにおいては, オリジナリティーの程度の高いデータを学習する中でダンサーが視覚的に気付かないような特徴が抽出されることを期待して上記のラベル付け手法を用いている. このシステムを確立することで, ストリートダンスが義務教育課程に組み込まれている昨今の教育現場においてダンスに詳しくない指導者でも生徒の評価指標として活用できると考えられる. また, ダンスイベントにおいてはジャッジの人選により参加者の評価も変わってしまう場合が多かったが、このシステムを活用することで共通の評価基準を得ることができるようになるであろう.

5.2 課題

本研究の課題として挙げられるのが, モデルの構築・テストに利用するデータの多様性である. 本研究で利用したデータは 3 名のダンサーの動作を測定したものであり, 今回構築したモデルが他のダンサーを対象とした場合も十分な精度を示すか, といった点については十分に検証出来ていない. 特にオリジナリティーの測定に関しては, ダンサーの数が少ないためラベル付けの時点で偏った評価となっている可能性が高い. 今後は対象者の数を増やし, ダンサーによる個人差にも十分に対応可能なシステムを構築することが必要と考えられる.

6. ダンスカルチャーへの影響

最後に, 本研究におけるオリジナリティーの測定システムが現在のダンスカルチャーへ与える影響について, ブレイクダンスが今日まで発展してきた歴史的過程も踏まえつつ考察する. 上記したようにブレイクダンスは 1960 年代後半に誕生したものであるが, 時間の経過とともに主流とされるダンスのスタイルも変化してきた. 特に 1990 年代に登場したアメリカの Style Elements (http://www.style-elements.com)というダンスクルーはハンドホップ(倒立の状態で跳ねる動作)や独特なスレッド(身体の部位を使って作り出した輪っかに手や足を通す動作)など既存のダンススタイルとは大きく異なる踊り方を生み出し, ダンスカルチャーの発展に大きく貢献したと言われている. 本研究のオリジナリティーの評価システムにおいても, 例えば学習データをブレイクダンスの動作に限定するのではなく, 他ジャンルのダンスの動作や形態模写の動作を学習データとして取り入れることで, 既存の価値観に囚われない評価基準を生み出せる可能性がある. これまでにない新しいダンススタイルを創出する支援ができるようになると現在のダンスカルチャーの発展にも貢献できるであろう.



図5. オリジナリティーの程度を可視化した例

また, 上記したように本システムをダンスイベントのジャッジとして活用することも考えられる. ただし, 本研究は既存のダンススタイルを否定したいわけでもなく, またオリジナリティー以外にもダンサーの音楽性や動作の技術的難易度など多くの評価基準が存在する. 現状のダンスカルチャーにおける評価基準を補う形で本システムが活用されることで, 既存の価値観も尊重しつつ新たな価値観の創出に繋がるような活動を本研究でも進めていきたい.

Acknowledgment

本研究への協力をご快諾頂いたダンサーの方に厚く御礼申し上げます. なお本研究は, 科学研究費補助金若手研究 B(課題番号:16K17306、代表:清水大地)の助成を受けて行われました.

参考文献

[岩澤 2015] 岩澤有祐・矢入郁子・松尾豊. 車いす行動センシング加速度データへの表現活動の適用. 第 29 回人工知能学会全国大会発表論文集, 2C1-OS-06a-1, 2015.

[Kwapisz 2011] Kwapisz, J.R., Weiss, G.M., & Moore, S. A. Activity recognition using cell phone accelerometers. SIGKDD Explor. Newsl., Vol. 12, No. 2, pp. 74-82, 2011.

[OHJI 2001] OHJI. Roots of street dance. Bunkasha, 2001.

[Watkins 2005] Watkins, S. C. Hip hop matters: Politics, pop culture, and the struggle for the soul of a movement. Beacon Press, 2005.

General Session | General Session | [GS] J-11 Robot and real worlds

[2D1-J-11] Robot and real worlds: interaction of human, robot, and their environment

Chair:Yoshimasa Tawatsuji Reviewer:Masakazu Hirokawa
Wed. Jun 5, 2019 9:00 AM - 10:40 AM Room D (301B Medium meeting room)

[2D1-J-11-01] Evaluating the skill of robots guiding humans via a competitive task utilizing VR

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

9:00 AM - 9:20 AM

[2D1-J-11-02] Impression Effects of Collaborative Learning with Robots which Acts using Body Motion and Facial Expression

○Felix Jimenez[1], Tomohiro Yoshikawa[2], Takeshi Furuhashi[2], Masayoshi Kanoh[3] （1. School of Information Science and Technology, Aichi Prefectural University, 2. Graduate School of Engineering, Nagoya University, 3. School of Engineering, Chukyo University）

9:20 AM - 9:40 AM

[2D1-J-11-03] Influence of Eye Blink Mimicry and Interoceptive Awareness on Human-Robot Interaction

○Yuri Etani[1], Yukie Nagai[2], Konstantinos Theofilis[2], Masako Myowa[1] （1. Kyoto University, 2. National Institute of Information and Communications Technology）

9:40 AM - 10:00 AM

[2D1-J-11-04] Puppies or Flies: The Training Interaction Changes the Animacy Perception of Drones

○Watanabe Yuta[1], Onishi Yuya[1], Tanaka Kazuaki[2], Nakanisi Hideyuki[1] （1. Osaka University, 2. Kyoto Institute of Technology）

10:00 AM - 10:20 AM

[2D1-J-11-05] Emotions and Symbol Emergence in Robotics

○Takayuki Nagai[1] （1. Osaka University）

10:20 AM - 10:40 AM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

VR を活用した競技タスクによるロボットの対人誘導スキルの評価

Evaluating the skill of robots guiding humans via a competitive task utilizing VR

水地 良明 *1　稲邑 哲也 *1*2
Yoshiaki Mizuchi　Tetsunari Inamura

*1国立情報学研究所
National Institute of Informatics

*2総合研究大学院大学
SOKENDAI (The Graduate University for Advanced Studies)

We focus on evaluating an instruction ability of robots to appropriately guide human actions. We have proposed a simulation software to evaluate human-robot interaction in daily life environment based on immersive virtual reality (VR). However, difficulties still remain to evaluate the performance of human-robot communication which depends on subjective factors of humans. To develop evaluation criteria of the performance in such a human-robot communication, we designed and carried out a competitive task in which the robot has to generate comprehensible and unambiguous natural language expressions to guide test subjects to achieve several tasks in daily environments utilizing immersive VR. The evaluation results in a robot competition show the usefulness of the proposed approach. Additionally, we demonstrate that the evaluation based on human behavior itself such as changes of head directions is useful for evaluating the performance of instructions by the robot.

1. はじめに

より優れたロボットの対人コミュニケーション能力の構築に向けた手立てを効率的に探る方法の一つは，RoboCup@Home などのロボット競技会の活用である．実機ロボットの開発に起因する資金，時間，労力を削減し，効率的な評価プロセスを実現する方法として，RoboCup Soccer や RoboCup Rescue などのロボット競技会ではシミュレータが活用されている．ロボットの対人コミュニケーション能力の評価においても，多様な条件における試行や再現性の高い評価を比較的容易に実現するための方法としてシミュレータの活用が望まれる．しかしながら，ロボットと人間のやり取りに重きが置かれている RoboCup@Home では，世界大会における正式なシミュレーションリーグが存在しない．その要因の一つは，対人コミュニケーションにおける人間の行動をシミュレートすることが困難であることである．この問題については，没入型 VR の活用によって，複数のロボットの評価を同時並列で実施可能とすることで解決が図られている [Inamura 18]．一方で，人間の主観に依存する対人コミュニケーションの性能評価が困難である点が課題として残っている．

本研究では，結果が人間の主観に依存する対人コミュニケーションとして，ロボットによる対人誘導スキルに着目する．我々の日常生活では，状況に応じて場所や参照物，手順などを伝え，相手の行動を誘導する場面は多く存在する．このような対人誘導スキルは，知能ロボットが人間を相手として協働する場面や手助けを求める場面における重要な要素の一つである．対人誘導においてロボットがどれだけ効率的かつ気の利いた指示を与えられているかを被誘導者となる人間の振る舞いから評価する方法として，VR 内のアバターに没入した被験者の行動をロボットが誘導する競技タスクを設計した．本研究の目的は，競技タスクを通した実証実験により，評価方法の構築に向けた前段階として，対人コミュニケーションの評価において，従来の時間に基づく評価だけではなく，頭の向きの変化など人間の振る舞いそのものに基づく評価の必要性を明らかにすることである．また，本研究で構築した競技システムの対人コミュニケーションの性能評価における有用性を明らかにすることである．同競技システムを用いたロボット競技会において実際の人間の挙動に基づくロボットの対人コミュニケーション能力の評価を行った結果から，所要時間以外の評価基準の必要性および提案したシステムの対人コミュニケーション能力の評価における有用性について議論する．

連絡先: 水地 良明，国立情報学研究所，〒 101-8430 東京都千代田区一ツ橋 2-1-2，mizuchi@nii.ac.jp

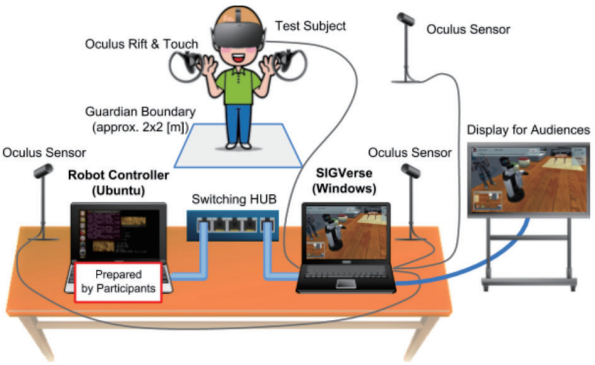


図 1: 競技システムの構成

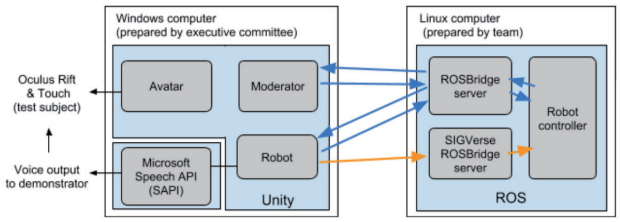


図 2: ソフトウェア構成

2. 評価方法

被誘導者となる人間 (被験者) が，VR 内のアバターにログインし，ロボットの指示に従ってタスクを遂行する競技タスクを設計した．同競技タスクにおけるロボットの役割は，人

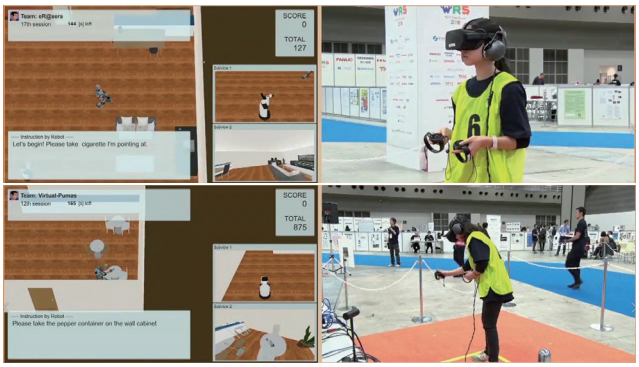


図 3: 競技の様子

間の行動を的確に誘導するために，状況に応じた自然言語表現やジェスチャを生成することである．図 1，2 に競技システムとソフトウェアの構成を示す．競技システムは，SIGVerse Ver.3[Mizuchi 17] プラットフォームの上に構成されている．SIGVerse Ver.3 は Unity と ROS を統合した設計となっているため，競技者は実機ロボットのソフトウェアを流用して仮想ロボットのソフトウェアを構築できる．

構築した競技システムを用いて，経済産業省および NEDO 主催の World Robot Summit 2018 の Service Category，Partner Robot Challenge (Virtual Space)[*1] を実施した．提案する競技タスクは，同競技会のルール [*2] における “Human Navigation” に該当する．従来のロボット競技では人間からの要求をロボットが実行することに重きが置かれていたが，Human Navigation では両者の役割が入れ替わっている．具体的には，被験者が対象物を掴んで，それを目的地に置くタスクとなっており，競技者は達成時間に基づいて計算される得点を競う競技システムは事前に GitHub[*3] で公開し，競技者には仮想ロボットの制御ソフトウェアのみを実装してもらった．被験者には，環境中にどのような物体が存在するか，どのような間取りなのか，対象物が何であるか，目的地がどこであるかといった情報は与えられない．ロボットには，各試行の開始にそれらの情報が通知される．また，アバターの視線や何を持っているかなどの振る舞いを随時取得できるようになっている．

図 3 に競技中のシステムと被験者の様子を示す．競技全体の様子についても，YouTube[*4] にて公開されている．

3. 評価結果

7 チームを対象としてそれぞれ 28 条件，計 196 回の試行を行った．16 人の被験者を対象として，7.9 時間 (196 試行*1 試行あたり最大 3 分間) の振る舞いデータを収録した．この収録データには，ロボットによる発話だけでなく，曖昧な指示が与えられた際の迷う素振りや勘違いによる無意味な行動も含め，被験者の身体的な振る舞いや物体とのインタラクションが含まれている．また，それらの挙動は VR 空間上で再現可能なレベルで記録されているため，競技の採点では対象となっていない挙動を振り返って分析することも可能となっている．

図 4–6 に点数，達成時間，対象物を把持するまでの時間を

*1 http://worldrobotsummit.org/en/wrc2018/service/
*2 http://worldrobotsummit.org/download/rulebook-en/rulebook-simulation_league_partner_robot_challnege.pdf
*3 https://github.com/PartnerRobotChallengeVirtual/
*4 https://bit.ly/2QOjJAZ

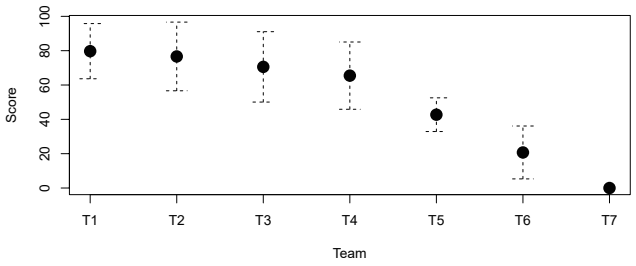


図 4: チームごとの点数

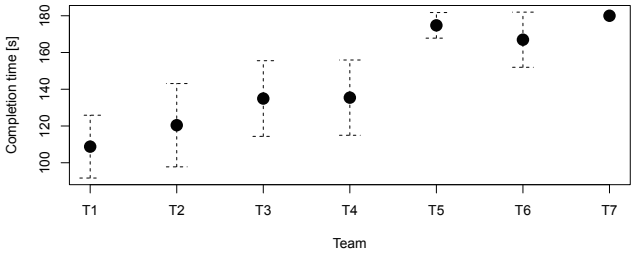


図 5: チームごとの被験者が対象物を目的地に置くまで時間

それぞれ示す．黒丸が平均，エラーバーは 95%信頼区間を表す．ここでは，タスクを達成できなかった場合の時間を 180 秒として平均時間を算出している．ロボットによる指示が分かりにくいほど，対象物の把持またはタスクの完了に時間を要する傾向が得られた．

頭の向きの変化は，対象物を見つけるためにどれだけ周囲を見渡していた度合いと相関があると考えられる．つまり，的確に対象物の場所を指示できているほど変化が少なくなることが予想される．各試行における頭の向きの変化量 v を，収録されたデータに基づいて式 (1) を用いて計算した．

$$v = \frac{1}{T_c} \sum_{t=1}^{T_c} \|\mathbf{R}_t \boldsymbol{z} - \mathbf{R}_{t-1} \boldsymbol{z}\| \tag{1}$$

ここで，t は時刻，N はデータのサンプル数，$\mathbf{R}_i$ は頭の姿勢を表す回転行列，$\boldsymbol{z} = (0, 0, 1)^{\mathrm{T}}$ は視線方向の単位ベクトル，T_c はタスクの完了までに要した時間である．図 7 に被験者の頭の向きの変化を示す．所要時間を指標とした対人コミュニケーションの評価は既存研究（例えば，[Striegnitz 11]）において利用されている．しかしながら，図 4–6 の所要時間を指標とした結果では，上位 4 チーム (T1，T2，T3，T4) に有意な差があるとは言えない (いずれの組み合わせにおいても $p > 0.42$)．一方で，頭の向きの変化では，T1 と T2 に有意な差がある ($p < 0.01$)．実際に，T1 や T5 は被験者の位置や視線方向を基準とした対象の方向を指示していたのに対し，T2 などでは相対的な方向に関する指示が含まれない傾向があった．つまり，所要時間での評価結果と頭の向きの変化での評価結果は異なることが明らかとなった．これは，時間だけではなく，様々な身体的社会的な計測に基づいて評価する必要性を示す結果である．

4. まとめ

本稿では，ロボットの対人コミュニケーションの性能を評価するためのロボット競技タスクの実施手法について述べた．同競技では，196 試行，7.9 時間のロボット・環境とのインタラ

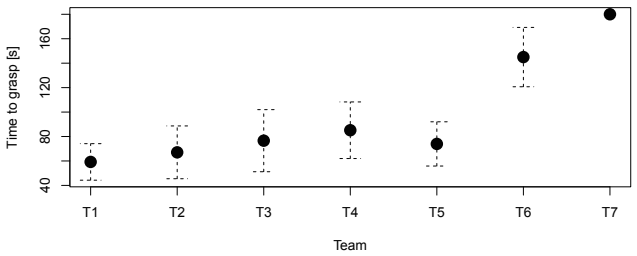


図 6: チームごとの被験者が対象物を把持するまでの時間

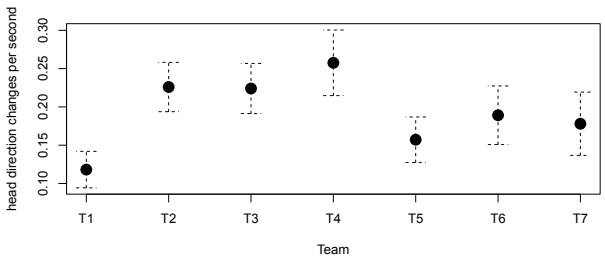


図 7: チームごとの被験者の頭の向きの変化

クションを対象とした人間の振る舞いデータを収録した．これは，提案した人間の挙動データの収集法の有用性を示している．また，頭の向きの変化など人間の振る舞いに着目することで，従来の所要時間を指標とした評価では結果に有意な差が得られない対象においても，評価結果に有意な差が得られることを明らかにした．これらの結果は，ロボットの対人コミュニケーションの性能評価において，タスクの達成に必要な所要時間だけではなく，様々な身体的社会的な計測に基づく評価の必要性を示すものである．このような結論をエビデンスに基づいて示すことができる実験システムを提供したという点も本システムの寄与の一つである．

本研究では，人間による主観的評価は行っておらず，評価基準の妥当性は明らかとなっていない．今後は，VR 上で再現した対人インタラクションにおける被験者の挙動を第三者に評価してもらい，競技会のルールにおける評価の妥当性を検証していく予定である．

謝辞

本研究の成果の一部は，国立研究開発法人新エネルギー・産業技術総合開発機構（NEDO）の委託業務，および JST CREST（グラント番号 JPMJCR15E3）の支援を受けたものです．

参考文献

[Inamura 18] Inamura, T. and Mizuchi, Y.: *Competition design to evaluate cognitive functions in human-robot interaction based on immersive VR*, RoboCup 2017: Robot World Cup XXI, Lecture Notes in Artificial Intelligence 11175, pp. 84–94 (2018).

[Mizuchi 17] Mizuchi, Y. and Inamura, T.: *Cloud-based Multimodal Human-Robot Interaction Simulator Utilizing ROS and Unity Frameworks*, in Proc. of the IEEE/SICE Int. Symp. on System Integration, pp. 948–955 (2017).

[Striegnitz 11] Striegnitz, K., Denis, A., Gargett, A., Garoufi, K., Koller, A. and Theune, M.: *Report on the First NLG Challenge on Generating Instructions in Virtual Environments (GIVE-2.5)*, in Proc. of the 13th European Workshop on Natural Language Generation, pp. 270–279 (2011).

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

表情変化と身体動作を用いて行動するロボットとの協調学習が及ぼす印象効果

Impression Effects of Collaborative Learning with Robots which Acts using Body Motion and Facial Expression

ジメネスフェリックス *1 Felix Jimenez　吉川大弘 *2 Tomohiro Yoshikawa　古橋武 *3 Takeshi Furuhashi　加納政芳 *4 Masayoshi Kanoh

*1愛知県立大学 情報科学部
School of Information Science and Technology, Aichi Prefectural University

*2*3名古屋大学大学院　工学研究科
Graduate School of Engineering, Nagoya University

*4中京大学 工学部
School of Engineering, Chukyo University

The growth of robot technology has prompted growing interest in educational-support robots. Previous studies reported that robots which alternate between the roles of the speaker and listener can prompt college students to learn by alternately solving questions with the robots. As the speaker, the robot explained a solution to its partner and solved a question. As the listener, the robot did not solve questions itself, but instead payed attention to its partner that solves the questions. However, the previous study used the robots which acts the speaker and listener by only facial expression. We did not know the effect of the robots which acts the speaker and listener by facial expression and body motion. Thus, this study investigate the effect of the robots the robots which acts the speaker and listener by facial expression and body motion.

1. はじめに

近年，学習を支援する場面で活躍する教育支援ロボットに関する研究分野が注目されている [Belpaeme 18]．本研究では，共同学習者のように振る舞い，学習者と共に学び合う教育支援ロボットに注目する．これらのロボットにおける従来研究では，学習者から教わる立場になって，教示学習を促すロボット [Tanaka 15] と，学習者と交互に問題を解き合う協調学習を促すロボット [ジメネス 16, ジメネス 17] が提唱されている．本研究では，後者のロボットに注目する．従来研究 [ジメネス 16, ジメネス 17] では，学習者に交互に問題を解き合う協調学習を促すために，ロボット自身が問題を解く動作と，学習者の問題を解く様子を観察する動作を交互に実行する行動モデル (以下，協調行動モデル) が提案された．大学生を対象とした実験を実施したところ，協調行動モデルを搭載したロボットは大学生と交互に問題を解き合う協調学習を実現できる可能性を示した．

従来研究における協調行動モデルは，表情変化によって協調行動モデルの動作を実行するロボットのみで検討されている．Human-Robot-Interaction の研究分野では，ロボットが身体動作によって動作や行動を表現することは，人の相互作用に有効であると報告されている [神田 05]．また，教育支援ロボットの従来研究では，表情変化のみで感情を表出するロボットとの共同学習に比べて，表情変化と身体動作を用いて感情を表出するロボットとの共同学習は，学習者に高い親密さを与えることができると報告されている [谷嵜 18]．協調行動モデルにおいても，表情変化だけなく，身体動作も使用して動作を実行することで，協調行動モデルを搭載したロボットは学習者により好印象を与える可能性があると考える．

そこで本稿では，表情変化と身体動作によって協調行動モデルの動作を実行するロボットとの協調学習が，学習者に与える印象効果について検証する．具体的には，表情変化のみで動作や行動を表現するロボット，身体動作のみで動作や行動を表現するロボット，表情変化と身体動作によって動作や行動を表現するロボットを比較することで検証する．実験では，前述した 3 種類のロボットに協調行動モデルを搭載し，大学生および大学院生と共に学ぶ学習実験を実施することで，それぞれのロボットが与える効果を比較する．

連絡先: ジメネスフェリックス，愛知県立大学情報科学部，jimenez@ist.aichi-pu.ac.jp



図 1: Tabot の外観

2. 協調行動モデルの概要

2.1 ロボットの外観

本稿では，頭部がタブレットで構成されているタブレット型ロボット「Tabot」(図 1) を開発し，本実験に用いた．Tabot は，頭部のタブレット上部にエージェントを表出することで，多様な表情変化を表出することができる．また，タブレット下部に学習システムを表示することで，学習者は Tabot と向き合って学習することができる．Tabot の身体部分は，首の自由度が 3，片腕の自由度が 5，脚部の自由度が 1 であり，合計で 14 の自由度を持つ．これにより，多様な身体動作が行える．

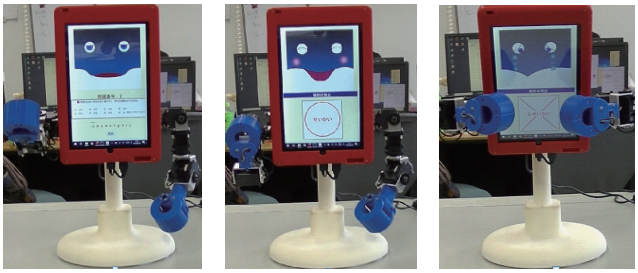


図 2: Tabot の動作

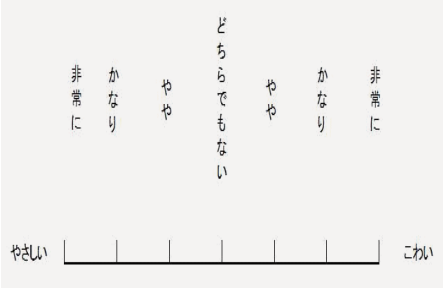


図 3: SD 法によるアンケート

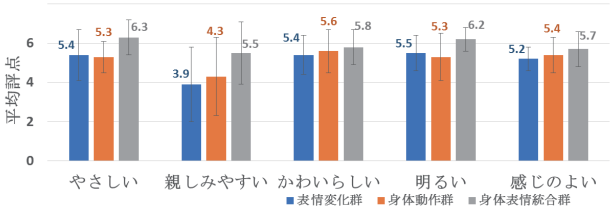


図 4: 各群における各項目の平均評点

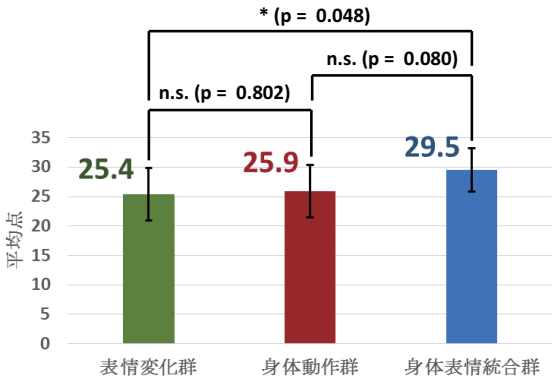


図 5: 各群における親密度の平均点

本実験では，表情変化のみを行う Tabot，身体動作をのみを行う Tabot，表情変化と身体動作の両方を行う Tabot を比較することで，ロボットの外見によって学習者に与える影響をなくす．図 2 において，表情変化と身体動作の両方を行う Tabot の動作を示す．表情変化のみを行う Tabot は図 2 における表情変化のみが実行され，身体は図 1 と同じ状態になる．身体動作をのみを行う Tabot は図 2 における身体動作のみが実行され，表情は図 1 と同じ状態になる．

2.2 協調行動モデルにおける動作

本稿では従来研究 [ジメネス 16, ジメネス 17] を基に，以下のような問題解答動作と学習者観察動作を，交互に実行する行動モデルを構築する．

(1) 問題解答動作
ロボットは図 2(a) のような動作を表出しながら「僕が解く番だね，この問題はね…」などと発話して，問題の解答と解き方を説明する．その後,「だから，答えは○○だね」などと発話する．ロボットの正答率は，学習 1 日目が 50%，2 日目が 70%，3 日目以降は 90% と設定した．

(2) 学習者観察動作
ロボットは，図 2(a) のような動作を表出しながら,「次は君が解く番だね」や「難しいね」などと発話する．また，ロボットが以前正解した問題であっても，この動作を実行するタイミングであった場合，ロボットは「難しい」などを発話する．

この二つの動作が学習時に行うロボットの基本動作であり，学習システムにおいて問題が提示されたときに実行される．具体的には，奇数番目の問題が提示された場合，ロボットは学習者観察動作を実行する．偶数番目の問題が提示された場合，ロボットは問題解答動作を実行する．また，学習システムの正誤判定が提示されたときに，解答の正否に応じてロボットは図 2(b),(c) のような喜びまたは悲しみの動作を表出する．

3. 実験

3.1 方法

本実験では，動作の表出方法が異なる 3 種類の Tabot に協調行動モデルを搭載し，Tabot と学習者が共に学ぶ学習実験を実施した．具体的には，協調行動モデルを搭載し，表情変化によって動作を実行する Tabot と共に学習する「表情変化群」，協調行動モデルを搭載し，身体動作によって動作を実行する Tabot と共に学習する「身体動作群」，協調行動モデルを搭載し，表情変化と身体動作によって動作を実行する Tabot と共に学習する「身体表情統合群」の 3 群間を比較する学習実験を実施した．

30 名の大学生および大学院生を各群に 10 名ずつ振り分けた．各群の学習者は，3 日間毎日，学習システムから提示される 30 問の問題を解いた．問題は，SPI2 の非言語分野 (中学レベルの数学問題)[品川 12] で構成される．

各群のロボットが学習者に与える心理効果を測定するために，3 日目の学習終了後に各群の学習者に対して，SD 法によるアンケート (図 3) を実施した．アンケート項目は，従来研究 [神田 01] においてロボットと人の相互作用実験で使用された，5 項目 (やさしい，親しみやすいなど) を用いた．図 3 において最左部にある「非常に」を 7 とし，最右部の「非常に」を 1 とする 1〜7 の評点で数値化した．親そして，アンケートの全項目による合計点を親密度とした．

3.2 結果

図 4 に各群における各項目の平均評点を，図 5 に各群における親密度の平均点を示す．図 4 から，各項目において身体表情統合群の平均評点は，他群に比べて高い点数であることがわかる．図 5 においても，身体表情統合群における親密度の平均点は，他群に比べて高い点数であることがわかる．また，図 5 の結果に対してテューキーの方法による検定 [金田 14] を行ったところ，身体表情統合群と表情変化群に有意差が認められた．これにより，身体動作と表情変化によって協調行動モデ

ルの動作を実行するロボットとの協調学習は，表情変化のみによって協調行動モデルの動作を実行するロボットとの協調学習に比べて，学習者に高い親密度を与えることができると示唆された．

4. おわりに

本稿では，表情変化と身体動作によって協調行動モデルの動作を実行するロボットとの協調学習が，学習者に与える印象効果について検証した．具体的には，表情変化のみで動作や行動を表現するロボット，身体動作のみで動作や行動を表現するロボット，表情変化と身体動作によって動作や行動を表現するロボットを比較することで検証した．実験では，前述した 3 種類のロボットに協調行動モデルを搭載し，大学生および大学院生と共に学ぶ学習実験を実施することで，それぞれのロボットが与える効果を比較した．

実験の結果，身体動作と表情変化によって協調行動モデルの動作を実行するロボットとの協調学習は，表情変化のみによって協調行動モデルの動作を実行するロボットとの協調学習に比べて，学習者に高い親密度を与えることができると示唆された．

今後は，身体動作と表情変化によって協調行動モデルの動作を実行するロボットが，学習者に与える学習効果に対して検証していく．

参考文献

[Belpaeme 18] Belpaeme, T., Kennedy, J., Ramachandran, A., Scassellati, B. and Fumihide Tanaka, Social Robots for Education: a Review, Science Robotics, vol.3, no.21, eaat5954, 2018.

[品川 12] 品川泰一，2014 年度版就職活動の神様の SPI2 問題集，(株) ユーキャン 学び出版，2012.

[ジメネス 16] ジメネスフェリックス, 加納政芳, 吉川大弘, 古橋武, 建設的相互作用を基に行動するロボットとの協調学習の実現可能性, 人工知能学会論文誌, vol.31, no.3, pp.A-F93_1-10, 2016.

[ジメネス 17] ジメネスフェリックス, 吉川大弘, 古橋武, 加納政芳, ロボットの正解率の変動が人との協調学習に及ぼす親密性への効果, 人工知能学会論文誌, vol.32, no.5, pp.C-H13_1-10, 2017.

[神田 01] 神田崇行，石黒浩，石田亨，人間ーロボット間相互作用にかかわる心理学的評価，日本ロボット学会誌，vol.19,no.3,pp.362-371,2001.

[神田 05] 神田崇行, 鎌島正幸, 今井倫太, 小野哲雄, 坂本大介, 石黒浩, 安西祐一郎, 人間型対話ロボットのための協調的身体動作の利用, 日本ロボット学会誌，vol.23,no.7,pp.898-909,2005.

[金田 14] 金田行雄，笠井理生，古橋武，統計・多変量解析とソフトコンピューティング　超田自由度系解析を目指して -改訂版-，共立出版，2014.

[Tanaka 15] Tanaka, F., Isshiki, K., Takahashi, F., Uekusa, M., Sei, R. and Hayashi, K., Pepper learns together with children: development of an educational application, Proceedings of the 15th IEEE-RAS International Conference on Humanoid Robots, pp.270-275, 2015.

[谷嵜 18] 谷嵜悠平, ジメネスフェリックス, 吉川大弘, 古橋武, 教育支援ロボットにおける身体動作と表情変化による共感表出法の印象, 知能と情報, vol.30, no.5, pp.700-708, 2018.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

人とロボットの対面相互作用におけるまばたき模倣と内受容感覚の影響

Influence of Eye Blink Mimicry and Interoceptive Awareness on Human-Robot Interaction

江谷 友梨[*1] 長井 志江[*2] セオフィリス コンスタンティノス[*2] 明和 政子[*1]
Yuri Etani Yukie Nagai Konstantinos Theofilis Masako Myowa

[*1] 京都大学 Kyoto University
[*2] 情報通信研究機構 National Institute of Information and Communications Technology

As robots are increasingly employed in human society, establishing affective relationship between people and robots is very important. We examined whether eye blink mimicry by a robot and individual differences in interoceptive awareness influence the affective relationship between people and the robot or not. Our results demonstrated that neither of them was statistically related to the affective relationship. However, our closer analysis revealed that people tended to imitate the robot making eye blink and that spontaneous eye blink synchrony enhanced the rapport expectation with the robot. This finding provides a great insight into future design of HRI studies.

1. 問題と目的

近年ロボット技術の発展に伴い、ロボットが様々な場面で活用されるようになり、ロボットはわたしたちにとってより身近な存在となっている。人とロボットの共生社会が目前に迫る今、両者が親和的な関係を築いていけるか否かは重要な問題である。本研究では、人とロボットが親和的な関係を築く鍵となる要因について、見た目が人に酷似していないヒューマノイドロボットを用いてロボット側の要因と人側の要因の双方から検討する。

まず、本研究ではロボット側の要因として、ロボットによる「まばたきの模倣」を扱う。人は相手の姿勢や身振りを無意識的に模倣する傾向（自動模倣）があり、模倣された人は模倣した人に対する好ましさを無意識的に高め、インタラクションが円滑に進む（カメレオン効果）[Chartrand 99]。模倣による効果は人型をしたCGのエージェントやアンドロイド（人間酷似型ロボット）に対しても確認されており、参加者の頭の動きを模倣した方が模倣しないよりも発話の内容に説得力があり、好感度が高いと評価される[Bailenson 05, Shimada 08]。しかし、[Bailenson 05][Shimada 08]では、発話の内容に対する賛成度やエージェントに対して感じた印象のみを評価しており、その後の人と人以外のエージェントの関係性については検討されていない。本研究では、ロボットと親和的な関係を築くことを期待しているかどうかを評価する尺度を用いることで、まばたきの模倣が人とロボットの親和的な関係構築に与える影響について検討する。

次に、本研究では人側の要因として「内受容感覚の個人差」を」扱う。内受容感覚とは、「身体内部の変化に関する感覚であり、心臓の鼓動の存在や、胃や内臓の圧迫感そのものに関する感覚」[寺澤 14]である。この内受容感覚に敏感な人ほど相手を自動模倣しやすい傾向にある[Ainley 14]。[Stel 10]によると、模倣には双方向の影響があり、模倣される側だけでなく模倣する側も相手に対する親密さやインタラクションの円滑さを高く評価することがわかっている。したがって、内受容感覚に敏感な人はインタラクション中に相手を模倣しやすいがために、相手と親密な関係を築きやすいと考えられる。また、内受容感覚に敏感な人がインタラクションの相手から模倣された場合は、自身の自動模倣と相手からの模倣の相乗効果によってさらに相手と親和的な関係を築きやすくなると考えられる。

本研究の目的は、①ロボットによるまばたきの模倣②内受容感覚の個人差が人とロボットの親和的な関係構築に影響するかどうかについて検討することである。ロボットとの親和的な関係の築きやすさは質問紙により評価する。①についてはロボットにまばたきを模倣される条件でインタラクションを行うまばたき模倣群と、ロボットがランダムにまばたきをする条件でインタラクションを行うまばたきランダム群の 2 群を設定し、両群の反応を比較する。②については内受容感覚の個人差を心拍カウント課題により評価し、ロボットと親和的な関係を築く期待度を評価する質問紙得点との相関関係を調べる。本研究の仮説は以下の通りである。①まばたきランダム群よりもまばたき模倣群の方が、ロボットと親和的な関係を築く期待度を高く評価する。②内受容感覚に敏感な人（心拍カウント課題の得点が高い人）ほど、インタラクションを通してロボットと親和的な関係を築く期待度が高くなる。また、その傾向はまばたきランダム群よりもまばたき模倣群で強くなる。

連絡先：江谷友梨，京都大学，etani.yuri.35x@kyoto-u.jp

2. 方法

2.1 実験参加者

実験には大学生、大学院生 35 名が参加した（うち男性 14 名、平均年齢 21.94 歳）。そのうち 18 名（うち男性 7 名）がまばたき模倣群に、17 名（うち男性 7 名）がまばたきランダム群に割り当てられた。4 名のデータに不備があり、分析から除外した。最終的には 31 名のデータを分析した（うち男性 11 名、平均年齢 21.94 歳）。そのうち 15 名（うち男性 5 名）がまばたき模倣条件で、16 名（うち男性 6 名）がまばたきランダム条件でインタラクションを行った。ただし、まばたきランダム群の全まばたきに対する iCub を逆模倣したまばたきの割合と、iCub と同期したまばたきの割合には平均値から標準偏差の 3 倍以上離れているデータがそれぞれ 1 件ずつあったため、相関分析の際はそのデータを追加で除外して分析を行った。本研究は、京都大学心の先端研究ユニット倫理審査委員会より承認を得て実施された（承認番号 30-P-13）。

2.2 実験装置

(1) 心拍計測

内受容感覚の個人差を評価するために心拍カウント課題を行った。参加者の実際の心拍数の測定にはマルチセンサー生

理計測装置 NeXus10 システム（MindMedia B.V. Netherlands, キッセイコムテック）を用いた。

(2) ロボット

参加者は、iCub と名付けられたロボットとインタラクションを行った(図 1a)。iCub は、EU プロジェクト RobotCub の一部として IIT（Italian Institute of Technology）で開発されたヒューマノイドロボットである。iCub は高さ 104cm、重さ約 22kg で、53 個のモーターを持ち、頭、腕、手、腰、脚を独立に動かすことができる[Metta 08]。本調査では、頭とまぶたのみを動かすよう設定した。iCub の真後ろにスピーカーを置き、そこから流れる音声を iCub の発話とした。音声は[Tatsukawa 16]で用いられた日本語のラジオ番組を iCub の見た目に合うようボイスチェンジしたものを用いた。ラジオは全部で 227 秒の長さに編集された。発話中 iCub は口に相当する部分に赤色の四角形と棒状の LED ライトを交互に表示することで口の開閉を表した。さらに、iCub は参加者の顔が常に眼球のカメラ画像の中心に来るよう、頭部と視線方向を制御することで参加者の顔の動きを追いかけた。まばたき模倣条件の場合、iCub は参加者のまばたきを検出し(図 1b)、参加者の約 380 ミリ秒後にまばたきをした。ただし、iCub がまばたきをするためにまぶたを閉じている間などは参加者のまばたきを検出・模倣できなかった。まばたきランダム条件の場合、iCub は約 6 秒に 1 回の頻度でまばたきをした。

2.3 実験手続き

参加者が入室して iCub と向かい合う位置に置かれた椅子に座った後、実験目的や手続きについてインフォームドコンセントを行い、実験参加および映像撮影の同意を得た。

(1) 内受容感覚の個人差の計測

手順は[Ainley 14]に従った。参加者は両鎖骨の下および左腹部の 3 箇所にポータブル電極を貼り付け、心拍カウント課題を行った。心拍カウント課題では、参加者は「はじめ」の合図から「やめ」の合図までの一定時間内に知覚された心拍数を数えて報告することが求められた。15 秒の練習試行の後、25 秒、35 秒、45 秒の 3 試行がランダムな順序で行われた。心拍カウント課題に続いて時間カウント課題[Dunn 10]を行った。これは参加者が自分の心拍に関する知識をもとに心拍数を回答していないかを確認する目的で行われた。「はじめ」の合図から「やめ」の合図までの秒数を数えて報告することが求められた。19 秒、37 秒、49 秒の 3 試行がランダムな順序で行われた。その後、参加者は「1 分間に自分の心拍は何回あると思うか」という質問に対して口頭で回答した。

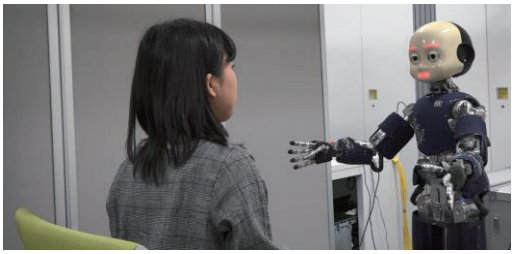
(2) RERS への回答（事前テスト）

参加者は目の前にいる iCub と親和的な関係を築く期待度について Rapport-Expectation with a Robot Scale（RERS）[Nomura 16]で評価した。質問は 18 項目あり、7 件法で評価した。最後にロボットの印象に関する自由記述欄が設けられた。

(3) iCub とのインタラクション

参加者はまばたき模倣条件もしくはまばたきランダム条件でインタラクションを行った。参加者はインタラクション中に、話しかけてくる iCub に対して自由に動いたり話したりすることが許された。ただし、顔は常に iCub の方を向いているよう求められ、iCub には接触しないよう教示した。インタラクションの様子は 2 台のビデオカメラ（HANDYCAM FDR-AX100, SONY）で撮影した。1 台は参加者の顔を、もう 1 台は iCub の顔を撮影した。

(a)



(b)

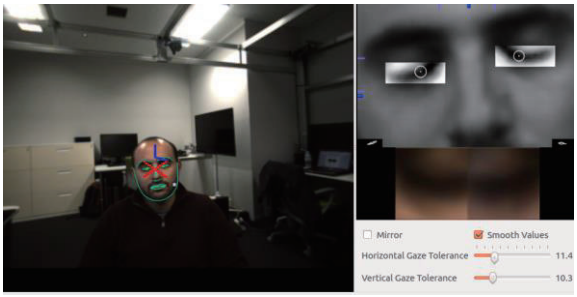


図 1. (a)インタラクションの様子, (b)iCub の眼球のカメラ画像
(左の写真の×印が参加者のまばたきの検出)

(4) RERS への回答（事後テスト）

インタラクションを通して iCub と親和的な関係を築く期待度がどのように変化したかを調べるため、参加者は再び RERS に回答した。

(5) その他の質問紙への回答

最後に参加者は基本情報および iCub に真似されていると感じることがあったか否かを尋ねる質問紙に回答した。

2.4 分析方法

本研究では統計ソフト SPSS（IBM SPSS Statistics ver.25）を用いて分析を行った。統計的検定の際の有意水準は全て有意確率 $p < .05$ に設定した（両側検定）。

(1) RERS 得点の分析

RERS の回答には順に 1～7 点を与え（一部の逆転項目には 7～1 点を与え）、合計点を算出した。Cronbach の α 係数は事前テスト、事後テストでそれぞれ $\alpha = .81$、$\alpha = .92$ であった。したがって、内的整合性は十分であると評価された。

(2) ビデオ映像の分析

まばたき模倣群については、インタラクション中に参加者がした全てのまばたきと iCub に模倣されたまばたきの回数を記録した。まばたきランダム群については、参加者がした全てのまばたき、①偶発的に iCub に模倣されたまばたき、②iCub とタイミングが一致したまばたき、③iCub を逆模倣したまばたきの回数を記録した。また、①②③を足したものを④iCub と同期したまばたきとした。

(3) 内受容感覚の個人差の分析

心拍カウント課題の得点は、1/3 Σ(1-(|実際の心拍数 - 数えた心拍数|/実際の心拍数)) [Schandry 81]によって算出した。得点は 0 から 1 の値を取り、この得点が高いほど内受容感覚に敏感であると評価した。また、時間推測課題の得点も同様に、1/3 Σ(1-(|推測した時間 - 実際に経過した時間|/実際に経過した時間))によって算出した。

3. 結果

3.1 RERS 得点

まばたき模倣群の参加者のうち 8 人が iCub にまばたきを模倣されていることに気づいた。一方まばたきランダム群では iCub は任意のタイミングでまばたきをしていたが、3 人がまばたきを真似されていると感じたと回答した。群(まばたき模倣群・まばたきランダム群)とまばたきの模倣に対する気づきの有無(気づいた・気づかなかった)を参加者間要因、回答時期(事前テスト・事後テスト)を参加者内要因とする 3 要因分散分析を行った結果、全ての主効果と交互作用に有意差はみられなかった。(群の主効果:$F(1,27) = 1.60$, $p = .22$, $\eta_p^2 = .06$;回答時期の主効果:$F(1,27) = 1.14$, $p = .30$, $\eta_p^2 = .04$;気づきの有無の主効果:$F(1,27) = 2.02$, $p = .17$, $\eta_p^2 = .07$;群と回答時期の交互作用:$F(1,27) = .01$, $p = .93$, $\eta_p^2 = .00$;群と気づきの有無の交互作用:$F(1,27) = 2.55$, $p = .12$, $\eta_p^2 = .09$;回答時期と気づきの有無の交互作用:$F(1,27) = .23$, $p = .64$, $\eta_p^2 = .01$;群と回答時期と気づきの有無の交互作用:$F(1,27) = .53$, $p = .47$, $\eta_p^2 = .02$)。図 2 に、群およびまばたきの模倣に対する気づきの有無ごとに事前テストと事後テストの RERS 得点の平均値を示した。

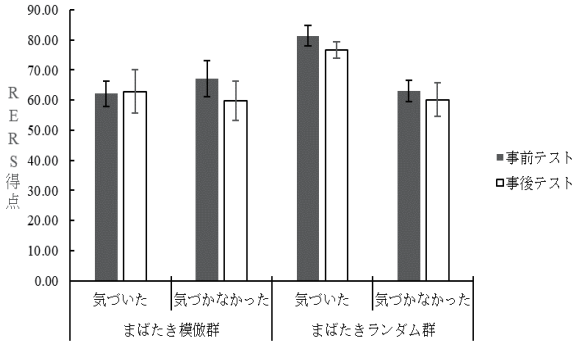


図 2. 各要因における RERS 得点の平均値(エラーバーは標準誤差)

3.2 人とロボットのまばたきのタイミング

表 1 に、まばたき模倣群の参加者の全まばたきに対する iCub に模倣されたまばたきの割合(a)、また、まばたきランダム群の参加者の全まばたきに対する①偶発的に iCub に模倣されたまばたき、②iCub とタイミングが一致したまばたき、③iCub を逆模倣したまばたき、④iCub と同期したまばたきの割合(b)の平均値と標準偏差を示した。

表 1. 参加者の全まばたきのうち(①偶発的に)iCub に模倣されたまばたき、②iCub と一致したまばたき、③iCub を逆模倣したまばたき、④iCub と同期したまばたきの割合の平均値と標準偏差(単位:%)

(a)まばたき模倣群

模倣	
平均値	標準偏差
72.67	11.94

※(b)の③と④は外れ値を除外しているため、④の平均値と標準偏差はこの表の①+②+③の値とは異なっている。

(b)まばたきランダム群

①偶発的に模倣		②一致		③逆模倣		④同期(①+②+③)	
平均値	標準偏差	平均値	標準偏差	平均値	標準偏差	平均値	標準偏差
8.37	2.60	2.09	1.08	9.46	2.98	19.48	3.65

また、独立変数を群(まばたき模倣群・まばたきランダム群)、従属変数を iCub に模倣されたまばたきの割合(まばたきランダム群の場合は①偶発的に iCub に模倣されたまばたきの割合)とする対応のない t 検定を行った結果、まばたき模倣群の方がまばたきランダム群よりも iCub に模倣されたまばたきの割合が有意に高かった($t(15.24) = -20.42$, $p = .00$, $g = -7.34$)。したがって、本研究では iCub によるまばたきの模倣を群によって操作することができていた。一方、まばたきランダム群において全まばたきに対する④iCub と同期したまばたきの割合と RERS 得点の変化量(事後テストの得点-事前テストの得点)の相関分析を行った結果、有意な関係はみられなかった($r = .35$, $p = .20$)。

3.3 内受容感覚の個人差

心拍カウント課題の得点と時間推測課題の得点の相関分析を行った結果、有意な関係はみられなかった($r = .17$, $p = .37$)。また、心拍カウント課題の得点と参加者が推測した 1 分間の自分の心拍の回数の相関分析を行った結果、有意な関係はみられなかった($r = .00$, $p = 1.00$)。つまり、参加者は時間感覚や知識に基づいて心拍を報告していたわけではなかった。

3.4 内受容感覚の個人差と RERS 得点および逆模倣の関係

まばたき模倣群において心拍カウント課題の得点と RERS 得点の変化量の相関分析を行った結果、有意な関係はみられなかった($r = -.38$, $p = .16$)。まばたきランダム群についても、相関分析の結果、心拍カウント課題と RERS 得点の変化量の間に有意な関係はみられなかった($r = .13$, $p = .63$)。また、まばたきランダム群において、心拍カウント課題の得点と③iCub を逆模倣したまばたきの割合の相関分析を行った結果、有意な関係はみられなかった($r = .25$, $p = .36$)。

4. 考察

4.1 まばたきの模倣が親和的な関係構築に与える影響

本研究では、RERS 得点についてまばたき模倣群とまばたきランダム群に統計上の差は見られなかった。よって、仮説①は支持されず、人と人に酷似していないロボットのインタラクションにおいて、まばたきの模倣が親和的な関係構築に影響を与える可能性は認められなかった。この結果については以下の 4 点の可能性が示唆される。1 点目は、人と人でないエージェントのインタラクションにおいては、模倣によって説得力や好感度などの印象が変化することはあっても、その後の関係の構築を求めるレベルまでは影響しない可能性である。進化論的な観点では、人は社会的な集団のメンバーと親和的な関係を構築することが必要不可欠だったため、自動模倣が発達したと主張している[Lakin 03]。人とロボットが親和的な関係を築くことは将来的には必要不可欠であるが、現時点ではまだその必要性を感じている人は少ないと推測できる。そうした見方にもとづけば、人とロボットのインタラクションにおいては模倣による親和的な関係を築く効果がみられなかった結果に説明をつけることができる。2 点目は、模倣による親和的な関係を築く効果は、模倣をするエージェントが人に酷似した外見や動きをしている場合に限られる可能性である。[Bailenson 05]や[Shimada 08]とは異なり、本研究の iCub はところどころ金属部分が露出していたり、口の動きを LED ライトで表現していたりと、人に酷似しているわけではなかった。このことから、模倣によって親和的な関係を構築するには、人に酷似した見た目や動きが大きく影響する可能性がある。3 点目は、模倣による親和的な関係を築く効果は、まばたきのような小さな動きではなく、ある程度大きな動きを模倣する必要がある可能性である。模倣によって相手と親和的な関係を築くには、

普段の会話の中でも相手に対して目を向けるような動きを模倣する必要があるのかもしれない。4 点目は、インタラクションの相手に模倣されることによって親和的な関係を築くことができる現象には大きな個人差がある可能性である。本研究ではまばたき模倣群内でも RERS 得点の変化量の値のばらつきが非常に大きかった。しかし、模倣によって親和的な関係を築くためには無意識的な模倣のやりとりであることが重要であるため、この個人差には模倣に対する気づきの有無が影響している可能性がある。本研究では気づきの有無の主効果は有意ではなかったが、今後気づきの有無に焦点を当てて詳しく検討する必要がある。

一方、本研究では有意な関係ではなかったが、まばたきランダム群において④iCub と同期したまばたきの割合と RERS 得点の変化量の間に正の相関関係がみられた。人とアンドロイドのインタラクションでは、人はアンドロイドの話し手のまばたきに同期してまばたきをする傾向がある[Tatsukawa 16]。この同期はアンドロイドが人から目を逸らして話した場合は消失し、人がアンドロイドの手に触れて話を聞いた場合は強化される。本研究の結果は、人とロボットのまばたきの同期が、両者が親和的な関係を築くための要因となる可能性を示す 1 つの知見となりうる。

4.2 内受容感覚の個人差が模倣による親和的な関係構築に与える影響

本研究では、内受容感覚の個人差を正しく計測できていたにもかかわらず、まばたき模倣群、まばたきランダム群共に心拍カウント課題の得点と RERS 得点の変化量の間に統計上の関係はみられなかった。したがって、仮説②は支持されなかった。また、まばたきランダム群において心拍カウント課題の得点と全まばたきに対する③iCub を逆模倣したまばたきの割合の間にも統計上の関係はみられなかった、よって、本研究では人と人に酷似していないロボットのインタラクション場面において、内受容感覚の個人差と模倣を介した親和的な関係の築きやすさの間には関連がない可能性が示された。内受容感覚の個人差と自動模倣の間に関連があることを示した[Ainley 14]で行われた課題は、自動模倣の抑制が求められた。他方、本研究では自動模倣を介した親和的な関係の築きやすさに焦点を当てた。したがって、内受容感覚の個人差は自動模倣の抑制には関連するが、自動模倣の起こりやすさやそれによる相手との親和的な関係の築きやすさには関連しないと考えられる。また、内受容感覚と社交不安の間には正の相関関係がある[Terasawa 13]。さらに、内受容感覚に敏感な人は自他の区別をしやすい[Tsakiris 11]。したがって、内受容感覚に敏感な人ほど、人ではない存在であるロボットと親和的な関係を築くことが困難である可能性が示唆される。それによって模倣による親和的な関係を築く効果が相殺されてしまった可能性も考えられる。

5. まとめ

本研究では、ロボットによるまばたきの模倣や内受容感覚の個人差が、人とロボットの親和的な関係構築に与える影響を検証したが、有意な結果を見出すことはできなかった。しかし、本結果は先行研究で報告された人とロボットの間のカメレオン効果を否定するものではなく、考察で述べた実験条件の違いが影響していると考えられる。興味深いことに、まばたきランダム群においては人がロボットのまばたきを逆模倣するような場面が観察され、まばたき同期が多いほど親和的な関係構築への期待も高まることが示された。すなわち、まばたきの模倣に限らず逆模倣や偶発的なタイミングの一致によっても親和的な関係を築きやすくなる可能性が示唆された。今後この点に着目してさらなる考察を進めていく必要がある。

参考文献

[Ainley 14] Ainley, V., Brass, M., & Tsakiris, M: Heartfelt imitation: High interoceptive awareness is linked to greater automatic imitation, *Neuropsychologia*, 60, 21-28, 2014.

[Bailenson 05] Bailenson, J. N., & Yee, N: Digital chameleons-Automatic assimilation of nonverbal gestures in immersive virtual environments, *Psychological Science*, 16(10), 814-819, 2005.

[Chartrand 99] Chartrand, T. L., & Bargh, J. A: The chameleon effect: the perception-behavior link and social interaction, *Journal of Personality and Social Psychology*, 76(6), 893-910, 1999.

[Dunn 10] Dunn, B. D., Galton, H. C., Morgan, R., Evans, D., Oliver, C., Meyer, M., Cusack, R., Lawrence, A. D., & Dalgleish, T: Listening to your heart: How interoception shapes emotion experience and intuitive decision making, *Psychological Science*, 21(12), 1835–1844, 2010.

[Lakin 03] Lakin, J. L., Jefferies, V. E., Cheng, C. M., & Chartrand T. L: The Chameleon effect as social glue: Evidence for the evolutionary significance of nonconscious mimicry, *Journal of Nonverbal Behavior*, 27(3), 145-162, 2003.

[Metta 08] Metta, G., Sandini, G., Vernon, D., Natale, L., & Nori, F: The iCub humanoid robot: an open platform for research in embodied cognition, *PerMIS '08 Proceedings of the 8th Workshop on Performance Metrics for Intelligent Systems*, 50-56, 2008.

[Nomura 16] Nomura, T., & Kanda, T: Rapport–expectation with a robot scale, *International Journal of Social Robotics*, 8(1), 21–30, 2016.

[Schandry 81] Schandry, R: Heart beat perception and emotional experience. *Psychophysiology*, 18(4), 483–488, 1981.

[Shimada 08] Shimada, M., Yamauchi, K., Minato, T., Ishiguro, H., & Itakura, S: Studying the influence of the chameleon effect on humans using an android, *IEEE/RSJ International Conference on Intelligent Robots and Systems*, 767-772, 2008.

[Stel 10] Stel, M., & Vonk, R: Mimicry in social interaction: Benefits for mimickers, mimickees, and their interaction, *British Journal of Psychology*, 101(2), 311–323, 2010.

[Tatsukawa 16] Tatsukawa, K., Nakano, T., Ishiguro, H., & Yoshikawa, Y: Eyeblink synchrony in multimodal human-android interaction, *Scientific Reports*, 6, 39718, 2016.

[Terasawa 13] Terasawa, Y., Shibata, M., Moriguchi, Y., & Umeda, S: Anterior insular cortex mediates bodily sensibility and social anxiety, *Social Cognitive and Affective Neuroscience*, 8(3), 259–266, 2013.

[寺澤 14] 寺澤悠理・梅田聡: 内受容感覚と感情をつなぐ心理・神経メカニズム, *心理学評論*, 57(1), 49-66, 2014.

[Tsakiris 11] Tsakiris, M., Tajadura-Jiménez, A., & Costantini, M: Just a heartbeat away from one's body: Interoceptive sensitivity predicts malleability of body-representations, *Proceedings of the Royal Society B: Biological Sciences*, 278(1717), 2470‑2476, 2011

子犬かハエか:
ドローンに対するアニマシー知覚を変容させる躾インタラクション

Puppies or Flies?: The Training Interaction Changes the Animacy Perception of Drones

渡邊 裕太[*1] Yuta WATANABE　大西 裕也[*1] Yuya ONISHI　田中 一晶[*2] Kazuaki TANAKA　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] 京都工芸繊維大学 情報工学・人間科学系
Information and Human Sciences, Kyoto Institute of Technology

Abstract: This study proposes a pet robot as a new utilization of drone. A general pet robot has a cute appearance. The drone used in this study improves animacy, feeling of attachment and feeling of affinity only by interaction with participants, without relying on its appearance. In the experiment, we compared these senses in case of with a training and without a training. As a result, the training condition improved the robot's animacy, feeling of attachment and feeling of intimacy. In addition, participants felt the drone as mammals and birds in the training condition, and participants felt the drone as insects in the nontraining condition. Therefore it was suggested the difference of animacy to the drone between two conditions. Furthermore, when participants damaged the drone, we found that participants felt sorry for the drone in training condition.

1. はじめに

家庭向けのドローンはそのほとんどがラジコンや撮影用として用いられており，利用方法が限られている．そこで本研究では，ドローンの新しい利用方法としてペットロボットを提案する．

ドローンをペットロボットに利用することには以下の 3 つのメリットが存在する．1 つ目は，高さ方向の動きが出来ることによって行動パターンが増加し，飽きられにくくすることができることである．2 つ目は，空を飛んでいるために，部屋や階段を超えて飼い主の後を自由に付いていくような機能を持たせることができることである．このような機能は，空を飛ばずとも従来のペットロボットにジャンプの機能をつける，段差を越える機能をつけるなどによっても実現は可能である．しかし，同じような性質の動きをする一般的なペットロボットの価格と比較してトイドローンは安価であるという 3 つ目のメリットがある．しかし，既存のドローンは撮影に使う道具といったイメージが強く，今のままでは機械らしさが強すぎて，ペットロボットとして受け入れられることは難しいと考えられる．AIBO のような既存のペットロボットはその見た目によってアニマシーや愛着，親近感を感じさせる助けを行っているが，ドローンをそのような見た目にすることは重量の制限などにより難しい．よって本研究では，ドローンのような生物らしい見た目を持たないロボットに対して，その見た目に頼らずに，参加者とのインタラクションのみでペットのような感覚，特にアニマシーと愛着，親近感を感じさせることを目的とする．

また，被験者がドローンに対して躾という行為をすることによって，ドローンのアニマシーや愛着感，親近感が向上するのかについて調査した．躾を取り上げたのは，被験者にドローンを知的な存在であると認識してもらうためである．また，被験者がアニマシーや愛着，親近感を感じているかをアンケートによる直接的な質問だけでなく，実験終了時にドローンを叩き落してもらい，その時の感想を調査した．

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

ドローンによるペットロボットを目指した先行研究[Hieida 2016]として，ドローンの動くスピードや加速度，高さなどによって感情を表現するというものがある．しかし，この実験で使用したドローンは短時間のみの行動であり，ペットの要素のうち感情表現のみに注目していた．

また，ドローンと人のインタラクションに対する研究として目をつけることによってドローンとの対話への抵抗が少なくなることがわかっている[Ruijten 2018]．しかし，この研究は見た目による影響に着目しており，動きについては調査されていない．また，オブジェクトやロボットのアニマシーは，目標指向性[Opfer 2003]やインタラクション[Bartneck 2009]の経験によって向上させることができるという研究報告がある．

また，ペットロボットに躾を行うことに関する研究として躾への適切な反応を表現する方法について調査した研究[Tanaka 2010]や，躾を行う方法について調査した研究[Kaplan 2002]が存在する．

以上の関連研究をふまえ，本研究では見た目に頼ることなく動きによってドローンにペットのような感覚，特にその中でも重要であるアニマシーと愛着，親近感を持たせるということを目的とする．

3. 実験

3.1 仮説

AIBO などのペットロボットには躾を行う機能が備わっている．躾という行為はペットに行うことであるので，躾をロボットに対して行うとそのロボットに対して生き物らしさや，愛着，親近感を感じると予想される．

そのため，本研究では以下の仮説を検証した．

仮説:ドローンのような生き物らしい見た目を持たないロボットに躾を行うことによって，そのロボットに対して感じるアニマシーや愛着，親近感が向上する．

3.2 実験環境

図 1 に実験の環境を示す．本実験では RYZE 社の Tello（図 2）を用いた．Tello は，ペットロボットとして受け入れられやすいと考えられる大きさのドローンの中で最も操作性が高かった．そのため，このドローンを採用した．

また，実験は WOZ 法で行ったため，実験室内の 2 か所にカメラを設置し，被験者から見えない位置にいる実験者がその映像を確認して遠隔地からドローンを操作していた．図 1 に示す 2 枚の写真はこのカメラから撮影したものである．

ドローンをペットとして飼うことを想定して，室内には棚や机，服掛け，カレンダーを設置し，家の一室を再現した．また，棚にはぬいぐるみと風船を設置した．また，安全性の確保と，被験者がドローンに対して恐怖感を抱きすぎないために，ドローンと床を糸で繋ぎ，被験者の足元を一段高くした．



(a) 被験者後方から見た部屋の様子　(b) 被験者前方から見た部屋の様子

図 1　実験環境



図 2 ドローンの見た目

3.3 実験内容

(1) 要因・条件

3. 1 で述べた仮説を検証するために，部屋の中でのドローンとの触れ合いの中で，ドローンに躾を行うということを要因とし，以下の 2 つの条件を設定した．

躾あり条件:この条件では被験者に対して，ドローンに，風船が割れると危険であるため風船に近づいてはいけないということを教えてあげてくださいと伝えて，ドローンに躾を行ってもらう．

躾なし条件:この条件では被験者に対して，風船に関する説明を行わなかったため被験者はドローンに躾を行わなかった．

本実験では，一方の条件を体験してしまうともう一方の条件に対する印象が変わってしまうため，躾あり／なし条件でそれぞれ異なる被験者で体験してもらう被験者間実験を行った．また，実験中のドローンの軌跡を図 3 で示す．上下は同じ条件でのドローンの軌跡であるが，条件内に大きな差は見られない．また，躾あり条件では被験者の行動に関わらず，ドローンは実験開始から 3 分の間に，4 回だけ風船に向かうというようにした．これは，予備実験にて，4 回以上ドローンが風船に向かった場合，ドローンがいうことを聞いてくれなかったと感じる被験者がいたためである．また，被験者がドローンに対して風船に近づいてはいけないということを教えることが出来たと思ってもらうために，始めの 2 回は素早く，残りの 2 回はゆっくりと向かうようにした．

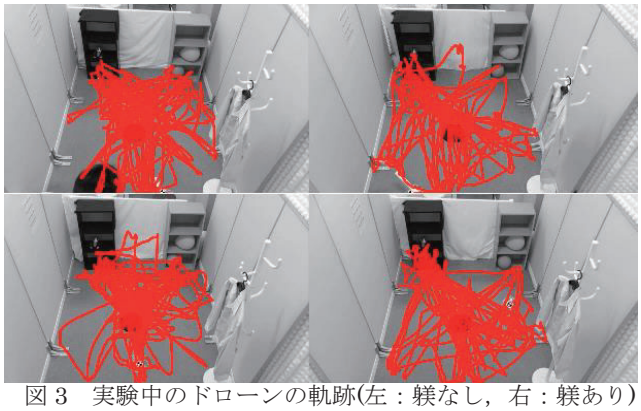


図 3　実験中のドローンの軌跡(左：躾なし，右：躾あり)

(2) 事前練習及び実験の案内

実験を行うにあたり，被験者に実験の説明を十分に理解してもらえるように事前練習と本番の 2 回に分けた．事前練習では以下の案内を行った．

- 【躾条件のみ】レーザポインタを使って，ドローンに風船が割れると危険なので風船に近づいてはいけないことを教えてあげてください．
- ドローンが自分に接近しないようにしてください．（ドローンはレーザポインタの光を当てられると，逃げて中央に戻るように動きます）
- 実験終了の時間になりましたら，呼び鈴にてお知らせしますので，棒でドローンを叩き落として停止させてください．

躾による影響のみを調べるために，例えば「ドローンを追い払ってください」のようなアニマシーを感じさせる表現を避けた．被験者に実験の説明を十分に理解してもらうために，上記の案内を書いた紙は事前練習時に被験者に配り，口頭でも確認した．また，事前練習時にはレーザポインタに対するドローンの反応を被験者に確認してもらった．事前練習は 30 秒程度行った．

(3) 実験内容

ドローンは，室内にある風船やぬいぐるみ，被験者に対して向かっていくように行動した．これは，目標指向性によってアニマシーを感じさせるためである[Opfer 2003]．ドローンは，レーザポインタの光を被験者に当てられると中央に戻るように行動した．また，どちらの条件においても被験者の行動に関わらず，実験終了までの 6 分間の間に 10 回だけ被験者に向かった．また，躾あり条件のみにおいて，実験開始から 3 分間に素早く 2 回，ゆっくりと 2 回風船に向かった．実験終了の 6 分が経った時点で呼び鈴を鳴らし，ドローンを叩き落してもらった．被験者が弱く叩いたときは自動で停止しない恐れがあるため，棒がドローンに接触した時点で着陸を行った．

3.4 被験者

本実験には我々のキャンパス周辺に住む 18 歳から 24 歳までの大学学部生 20 名(男性 10 名，女性 10 名)の被験者が参加した．各条件で 10 名ずつ(男性 5 名，女性 5 名)に体験してもらった．

3.5 アンケート

実験後にアンケートを実施し，それを実験の評価として用いた．本実験の調査対象はドローンへの躾が被験者に与える影響である．しかし，ドローンの見た目や動きそのものの印象が仮説に対応する質問に影響を及ぼす可能性が考えられる．そのため，アンケートでは，ドローンの見た目や動きそのものに対する質問，そして仮説に対応する質問を設定した．ドローンの見た目や動きそのものに関する質問は以下の 4 項目である．

- Q1 ドローンの見た目にたいして（不快に/快く）思った．
- Q2 ドローンの動きを見て（遠隔地から操作されている/自動的に動いている）と思った．
- Q3 ドローンの動きを見て，ドローンに意図があるように感じた．
- Q4 ドローンの動きを見て，ドローンに恐怖感を感じた．

Q1，Q2 の質問では，SD 法を用いた．各質問は 7 段階で設定しており，Q1 では 1:非常に不快に思った，4:どちらともいえない，7:非常に快く思ったに対応させた．また，Q2 では 1:完全に遠隔地から操作されていると感じた，4:どちらともいえない，7:完全に自動的に動いているに対応させた．それ以外の項目では 7 段階のリッカート尺度を用いた．各質問項目において 1:全くあてはまらない，4:どちらともいえない，7:非常によくあてはまるに対応させた．また，仮説に対応する質問は以下の 3 項目である．

- Q5 ドローンの動きを見て生き物らしさを感じた．
- Q6 ドローンの動きを見て，ドローンに愛着を感じた．
- Q7 ドローンの動きを見て，ドローンに親近感を感じた

また，実験を進める過程でさらに差が見られると予想される項目が見つかったため，以降の質問を追加した．そのため以降の質問項目では被験者数が少なくなっている．インタビューの結果，条件間でドローンに感じる生き物らしさの種類に違いが見られた．そこで，以下の 4 項目の質問を追加した．

- Q8 今回の実験で用いたドローンを犬や猫などの哺乳類のように感じた．
- Q9 今回の実験で用いたドローンを鳥のように感じた．
- Q10 今回の実験で用いたドローンを熱帯魚のように感じた．
- Q11 今回の実験で用いたドローンを虫のように感じた．

また，ドローンを機械として認識して壊れないかに対して抵抗を感じている被験者と，愛着や親近感から抵抗を感じている被験者がいることがインタビューによりわかったため，以下の 2 項目の質問を追加した．

- Q12 ドローンが壊れないか心配になり，ドローンを叩き落として停止させることに抵抗を感じた．
- Q13 ドローンがかわいそうだと思い，ドローンを叩き落として停止させることに抵抗を感じた．

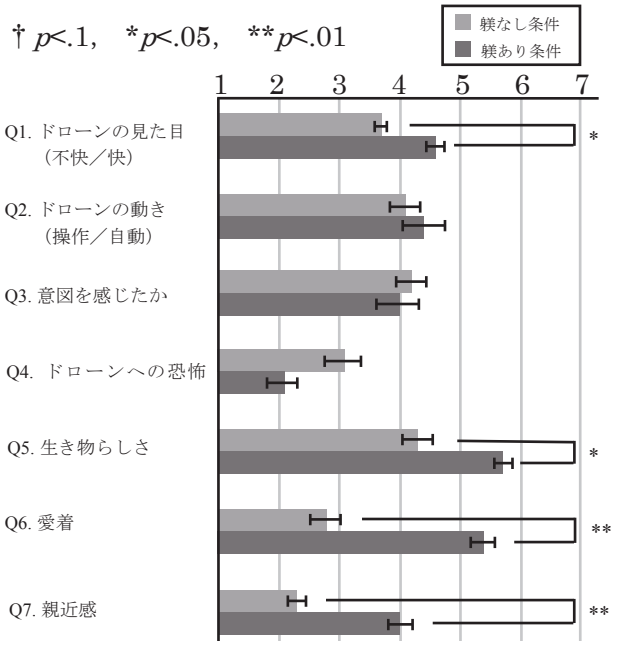
また，躾あり条件において，被験者が躾を行うことができたと感じたかを以下の質問を設定した．

- Q14 ドローンが風船に近づいてはいけないと理解したと感じた．

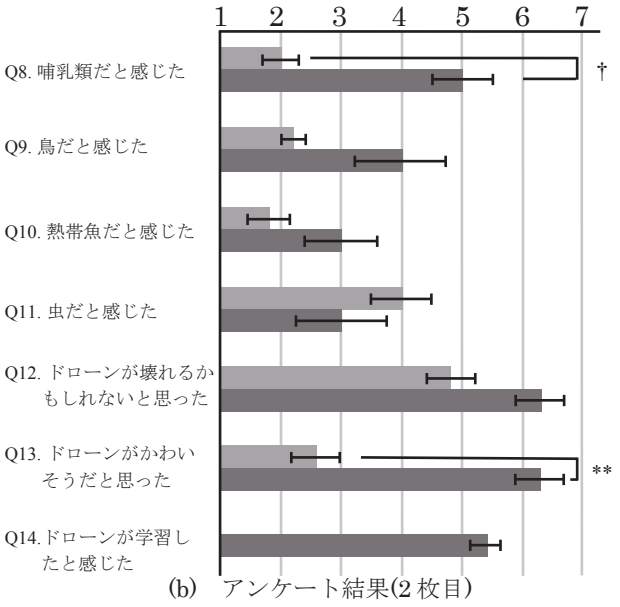
回答に影響を与えないようにするために，Q1-Q7，Q8-Q14 の 2 回に分けてアンケートを行った．すべての質問項目には自由解答欄を用意し，被験者にスコアを付けた理由を記入してもらった．また，アンケート終了後に点数を付けた理由についてインタビューで尋ねた．

4. 結果

実験結果を図 4 に示す．棒グラフは各項目のスコアの平均値を表し，エラーバーは標準誤差を表す．分析は対応のない t 検定を用いた．アンケート結果より，Q1 のドローンの見た目の項目で躾あり条件が躾なし条件よりもスコアが有意に高くなった *(t(18)=2.62, p<.05)*．Q2 ドローンの動き Q3 ドローンの意図 Q4 ドローンへの恐怖感の質問項目において有意な差が見られなかった．仮説に対応する Q5 生き物らしさ*(t(18)=2.59, p<.05)*，Q6 愛着*(t(18)=4.00, p<.01)*，Q7 親近感*(t(18)=3.60, p<.01)*の質問項目において，躾あり条件が躾なし条件よりもスコアが有意に高くなった．このことから仮説が支持されることが分かった．また，生き物らしさを詳しく調べた結果，Q8 ドローンを哺乳類だと感じた，の質問項目で躾あり条件と躾なし条件のスコア間に有意傾向が得られた*(t(7)=2.14, p<.1)*．また，ドローンを叩き落す事への抵抗を確認した質問項目では，Q13 ドローンがかわいそうだと感じた，の質問項目で躾あり条件が躾なし条件よりもスコアが有意に高くなった*(t(10)=3.26, p<.01)*．また，インタビューにてドローンがかわいそうだと感じた被験者は躾ありで 6 人，躾なしで 1 人確認された．



(a) アンケート結果(1 枚目)



(b) アンケート結果(2 枚目)

図 4 アンケート結果

5. 考察

Q4 において，条件間で統制が取れていることが確認されたが，Q1 においては躾を行った条件でよりドローンを快く思ったことが確認された．実際には条件間でドローンの見た目に差はなかったにもかかわらずアンケートの回答に差が確認されたのは，ドローンに躾を行ったことでアニマシーや愛着，親近感を感じた場合には，ドローンへの印象が好意的になっており，その影響で見た目に対しても快く思った被験者がいたと予想される．また，どちらの条件においても平均値は 4 に近い値を示しており，インタビューにおいてもドローンの見た目に対してアニマシーを感じたということは確認されず，見た目からアニマシーや愛着，親近感を感じさせることはなかった．

Q2，Q3 において，条件間で統制が取れていることが確認された．また，平均値はどちらの条件，質問においても 4 に近かったが，実際のペットロボットは自動的に意図をもって動いているという認識であると考えられるため，今後は案内の言葉などによって，ドローンが自動的に動いているという印象を持たせるように改善する必要がある．

また，Q5，Q6，Q7 の結果から，躾あり条件が躾なし条件よりもドローンに対しての生き物らしさ，愛着，親近感が高くなっていることが確認された．しかし，親近感の質問において，躾ありの条件においても平均値が 4 の近くとなっていた．このため，ドローンを家族の一員として受け入れるほどの強い愛着を持ったわけではなかったことが分かる．今後，躾以外の他の要素を付け加えることによってこの値を向上させていく必要がある．また，生き物らしさについての質問の自由解答欄において，躾あり条件を行った被験者はドローンが子犬やペットのように感じたとの回答が多く見られ，また躾なし条件を行った被験者はドローンがハエや蚊のように感じたとの回答が多く見られた． Q8~Q11 は，質問を行った被験者数が少ないため正確な議論はできないが，躾あり条件においてドローンを哺乳類だと感じる傾向があることが示唆された．

同様に，Q12，Q13 においても被験者数が少ないため，正確な議論はできないが，躾を行うことでドローンがかわいそうだと思い，叩き落すことに抵抗を感じる傾向があることが示唆された．抵抗を感じた理由をインタビューにて確認したところ，ドローンに愛着を持っていたために抵抗を感じたという回答が多く挙げられた．このことからも，被験者は躾を行うことでドローンに愛着を持っていたことが示される．

また，躾あり条件のインタビューにて，ドローンへの生き物らしさを感じた理由として，実験室内の風船やぬいぐるみ，服などに向かって動いていたからという回答が多かった．この結果は関連研究の結果[Opfer 2003]と一致しており，目標指向性がアニマシーを強化するということが確認された．しかし，ドローンはどちらの条件でも同じような行動をとっていたにもかかわらず，躾を行った被験者からこの意見が多くでた．これは，躾を行うときに，より注意深くドローンを観察するようになったためであると考えられる．また，ドローンに躾を行い，言うことを聞いてくれたと感じたために，ドローンを知的な存在であると感じたために，ドローンがただランダムに動いているのではなく，実験室内の風船やぬいぐるみ，服などに向かって動いていると感じたのだと考えられる．

また，本研究ではペットらしさの要素としてアニマシーや愛着，親近感による評価を行っていたが，インタビュー時にペットロボットとして飼う事が出来るかという質問を行ったところ，ドローンに対してその 3 つの評価が高かった被験者においても，騒音や安全性からペットロボットとして飼う事には少し抵抗を感じるといった意見が存在した．そのため，今後は質問項目にペットロボットとして飼うことができると感じたかについての質問を追加し検証する．

また，本研究では実験者がドローンを操作していたため，被験者や風船に向かう回数を決めるなどの注意を払い，実験間で動作に差が発生しないようにしていたが，意図せず差が発生している可能性がある．そのため，今後はモーションキャプチャの技術などを用いてドローンの動きを自動化させる必要がある．

6. おわりに

本研究では，ドローンのような見た目に生き物らしさを持たないロボットに対して，ペットのような感覚，その中でも特にアニマシーや愛着，親近感を持たせることを目的とした．実験では，躾の有無を要因とした 2 条件で比較した．

実験の結果，躾あり条件では，躾なし条件と比較して，ドローンへのアニマシー，愛着，親近感を強く感じるということが明らかとなった．これは，実験終了時に行ったドローンを叩き落とすという行為を行ったときの抵抗感からも確認された．また，ドローンの見た目に差はないにも拘らず，躾あり条件では，躾なし条件と比較して，見た目を快く思っていることが確認された．また，どちらの条件でも目標指向性によるアニマシーの表現を行っていたが，躾ありの条件でよりその行動が被験者に気づかれていた．また，ドローンに感じるアニマシーの種類には差があり，躾あり条件では子犬のように知性がある生き物として認識され，躾なし条件ではハエのように知性がない生き物として認識された．本研究の結果はドローンに限らず，生き物らしい見た目を持たせることが困難な全てのロボットに対して適用することが出来る．

謝辞

岡田宙士氏，金子翔氏には，被験者実験にご協力頂きました．心より感謝申し上げます．

参考文献

[Bartneck 2009] C. Bartneck, D. Kulic, E. Croft and S. Zoghbi: Measurement Instruments for the Anthropomorphism, Animacy, Likeability, Perceived Intelligence, and Perceived Safety of Robots, International Journal of Social Robotics, Vol. 1, No. 1, pp. 71‐81, 2009.

[Hieida 2016] C. Hieida, H. Matsuda, S. Kudoh and T. Suehiro: Action Elements of Emotional Body Expressions for Flying Robots, International Conference on Human Robot Interaction, pp. 439-440, 2016.

[Kaplan 2002] F. Kaplan, P. Y. Oudeyer, E. Kubinyi and A. Miklosi: Robotic Clicker Training, Robotics and Autonomous Systems, Vol. 38, No. 3-4, pp. 197‐206, 2002.

[Opfer 2003] J. E. Opfer: Identifying Living and Sentient Kinds from Dynamic Information: The Case of Goal-Directed Versus Aimless Autonomous Movement in Conceptual Change, Cognition, Vol. 86, No. 2, pp. 97-122, 2003.

[Ruijten 2018] P. A. M. Ruijten. and R. H. Cuijpers.: If Drones Could See: Investigating Evaluations of a Drone with Eyes, International Conference on Social Robotics, pp. 65-74, 2018.

[Tanaka 2010] K. Tanaka, M. Ozeki and N. Oka: The Hesitation of a Robot: A Delay in Its Motion Increases Learning Efficiency and Impresses Humans as Teachable, International Conference on Human Robot Interaction, pp. 189‐190, 2010.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

感情と記号創発ロボティクス

Emotions and Symbol Emergence in Robotics

長井 隆行 *1*2
Takayuki Nagai

*1大阪大学 Osaka University
*2電気通信大学 The University of Electro-Communications

Recent emotion studies reveal that interoception is a key concept to understand the mechanism behind human emotions. This idea can explain emergence of emotions, which can be seen as the differentiation mechanism of emotions. This paper tries to integrate the idea of emergence of emotions with the framework of symbol emergence in robotics. A preliminary study on grounding of affective words are demonstrated in this paper.

1. はじめに

感情とは何か？この問いは，古くから我々人間を悩ませ続けてきた．古くは哲学から，近年では心理学や神経科学をはじめロボティクスなど様々な領域で，この問いに対する答えの探求が続けられてきた．その探求は形を変えながら続けられているが，いまだにこの問いに対する明確な答えは存在しない．そうした中で近年の感情研究における一つの重要な示唆は，内受容感覚と情動の関係である [大平 17, 乾 18, Feldman17]．内受容感覚とは，内臓など身体内部の信号の処理の結果生じる知覚であるとされる．特に，内受容感覚の予測符号化は，予測に基づく脳の基本的な動作原理によって情動や感情を説明できる可能性を秘めている．ここで重要なのは身体であり，身体からの信号を自己組織化し自身の身体に関する予測性を高めることがポイントである．そうした情報の構造化やその構造に基づく意思決定・行動といった一連の人と環境の相互作用プロセスの中で感情が創発するものと考えられる．

本稿では，情動と感情を次のように定義する．情動とは，刺激に対する身体の反射的な反応を知覚した内受容感覚であり，体の状態を把握するための非常に基本的なものである．感情は，情動がより複雑に発展し，社会的文脈の中で発現したものであるが，内的な知覚であることに変わりはない．

ここで工学分野に目を向けてみると，人間のようなロボットやエージェントを作るという意味でも，感情は重要な要素として扱われてきた．特に感情を表出するという文脈で，多くの研究がなされている [Breazeal03]．こうした研究で問題となるのは，人がエージェントの表出をどのように捉えるかという人の心理的側面であり，このこと自体が必ずしも感情とは何かという問いに直接的に答えたり，感情を持ったエージェントを作ることを狙ったものではない．情動や感情の創発や分化という側面を捉えようとした研究は，それほど多くはない [浅田 15, 堀井 13]．

一方で知能ロボティクスでは，言語を含む知の創発的側面を扱う記号創発ロボティクスと呼ばれる領域が立ち上がっている．記号創発ロボティクスでは，ロボットやエージェントが環境や他者との相互作用を通して概念や言語をボトムアップに獲得すると考える．そうした複数の個体の知能が，ある種社会的な全体として記号システムを形成し，その記号システムがトップダウンに個体の学習を制約するという，ミクロ・マクロループとして我々の社会をとらえる．こうした社会を構成することのできるエージェントの計算モデルを構築し，物理的なロボットとして実現することが大きな目的である [Taniguchi16]．これまで記号創発ロボティクスでは，センサモータ情報の随伴性に基づいて，言語を獲得するタスクが主に検討されてきた [Nakamura11, Attamimi14]．もし情動や感情が内受容感覚を基盤とした創発現象だとすれば，これらも同じ枠組みに入れられるはずである．つまり記号創発ロボティクスで議論される計算モデルの枠組みに情動や感情を取り入れ，知能全体として議論することで，感情を持ったロボットを実現するための基礎的な検討ができる可能性がある．本稿では，こうした視点で情動/感情がどのようにモデル化され得るかについて議論することを目的とする．

連絡先: 長井隆行，大阪大学，大阪府豊中市待兼山町 1-3，06-6850-6365，nagai@sys.es.osaka-u.ac.jp

2. 感情モデル

ここではまず，感情の計算モデルを考える前段として，感情を含む知能の全体をどのように捉えるかについて考える．既に述べたように，感情を内受容感覚を基盤とした創発的な現象であるとするならば，以下の 3 点がポイントである．

- 身体の必要性
- 知能の枠組みの一つ（不可分性）
- 社会的側面の重要性

これらのことは，自動運転車が複数走っている様子に例えるとわかり易い．自動運転車には，自動車を制御するためのコンピュータが搭載されている．コンピュータには各種のセンサが接続されており，外界の情報が入力される．この情報は，自己位置の推定や障害物検知，経路の計画などに利用される．しかし，自動運転車にとって重要なセンサ情報はそれだけではない．走るための基盤として最も重要なのは，車自身の情報である．それは，現在のエンジンや燃料，タイヤの状態などである．燃料の情報は完全に正確に把握できるわけではなく，センシングに伴うノイズの影響が少なからずある．エンジンやタイヤの情報なども同様である．車は，こうした情報に基づいて走行に支障がないかどうかを瞬時に判断する必要がある．また，残りの可能な走行距離といった情報はこうしたセンシングに基づく予測であり，これから先どのような道をどれくらいのスピードで走るのかという不確定な要素を多分に含んでいる．この予測の精度を上げるためには，車がこれまでに取得した様々

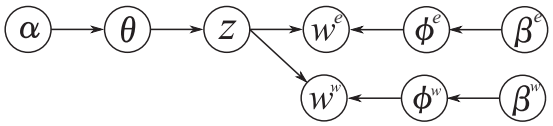


図 1: MLDA のグラフィカルモデル

なデータを構造化し，それらを総合的に参照する必要がある．このように，車においても自身の身体の情報は重要であり，それを知覚したものが情動であると捉えることで，主観的な意識の問題はあるものの，人間における情動の存在意義やメカニズムが考えやすくなる．

自動運転車の例でさらに重要なのは，他の自動運転車の存在である．外界の情報としての単なる障害物は，物理的な法則に従って存在するために，比較的その挙動は予測しやすい．しかし他の自動車は，そうした単なる物体とは異なる挙動を示す．むしろ他の個体は，自身を駆動するモデルを当てはめて予測した方が予測精度を高めることができるはずである．これは，自他分離によって，自身の予測モデルを他者の予測に利用する他者モデルの考え方であると言える．そしてこれらのことはすべて内的な知覚とも関係しているため，情動は外界に存在する物体や他者との関係として学習されることになる．こうして情動は他者との関係性や時間的な軸で複雑化することになり，これが感情であると考える．そこには，他者への羨望や将来への不安といった，比較的複雑ないわゆる高次感情が発現すると考えられる．

3. マルチモーダルカテゴリゼーションと情動

上述のような全体像を実現する前段として，情動を創り出すための非常に単純な例を示したい．以下では，内受容感覚が 2 次元のベクトルとして内部表現されていると仮定する．そしてこの 2 次元のベクトルはそれぞれ，感情価と覚醒度に対応していると仮定する．

3.1 感情的語彙の接地

筆者らのグループでは，確率的生成モデルの枠組みでマルチモーダル情報を構造化することで，ロボットが経験から概念を獲得し，さらに語彙との結びつけを相互に学習することで，語意を獲得できる可能性があることを示してきた [Nakamura11]. この仕組みをマルチモーダルカテゴリゼーションと呼ぶが，これに内受容感覚，つまりは身体の情報を入力することで，感情的語彙を獲得することを考える．マルチモーダルカテゴリゼーションは，階層ベイズや深層学習によって実装することができるが，ここでは階層ベイズに基づいたマルチモーダル LDA (MLDA: multimodal latent Dirichlet allocation) を用いた例を示す．

ここでの情動概念形成の単純化したモデルは，図 1 のグラフィカルモデルに相当する．このモデルにおいて，各観測情報 w^* は，それぞれハイパーパラメータ β^* によって決まるディリクレ事前分布に従うパラメータ ϕ^* の多項分布によって発生する．また z はカテゴリを示し，ハイパーパラメータ α によって決まるディリクレ事前分布に従うパラメータ θ の多項分布により発生する．

本稿におけるカテゴリ分類は，実際に取得した内的知覚情報と単語情報に基づき，モデルのパラメータ θ および ϕ を推定することに相当し，パラメータ推定には Gibbs Sampling を適用する．各知覚情報 m (情動の場合は感情価と覚醒度) のそれぞれの集合を $\boldsymbol{w}^m$，m 番目の情報の次元数を W^m とすると，対象における m 番目の情報の i 番目に割り当てられるカテゴリ z_{mi} は，

$$P\left(z_{mi}=k|\boldsymbol{z}^{-mi},\boldsymbol{w}^m,\alpha,\beta^m\right)\propto (N_k^{-mi}+\alpha)\cdot\frac{N_{mw^mk}^{-mi}+\beta^m}{N_{mk}^{-mi}+W^m\beta^m} \quad (1)$$

に従ってサンプリングされる．ここで N_{mw^mk} は，対象における m の情報 $\boldsymbol{w}^m$ についてカテゴリ k が割り当てられた回数を示す．式 (1) に従い，繰り返しサンプリングを行うことで結果がある値 $\hat{N}_*$ へと収束する．収束結果より，カテゴリの総数を K とする時，最終的なパラメータの推定値 $\hat{\phi}^m_{w^mk}$，$\hat{\theta}_k$ は以下のようになる．

$$\hat{\phi}^m_{w^mk}=\frac{\hat{N}_{mw^mk}+\beta^m}{\hat{N}_{mk}+W^m\beta^m},\quad \hat{\theta}_k=\frac{\hat{N}_k+\alpha}{\sum_k\hat{N}_k+K\alpha} \quad (2)$$

3.2 未知のシーンに対する語意の予測

学習したモデルを利用することで，未観測のシーンに対する情報の予測が可能である．本稿では，未知シーンを観測したことによって生成される情動信号 (感情価と覚醒度) に基づき単語を予測することを考える．観測した情動信号 $\boldsymbol{w}^e_{obs}$ から予測されるカテゴリ z，および単語 w^w は，それぞれ

$$z=\underset{z}{\mathrm{argmax}}\int P(z|\theta)P(\theta|\boldsymbol{w}^e_{obs})d\theta \quad (3)$$

$$P(\boldsymbol{w}^w|\boldsymbol{w}^e_{obs})=\int\sum_z P(w^w|z)P(z|\theta)P(\theta|\boldsymbol{w}^e_{obs})d\theta \quad (4)$$

によって求められる．これは，学習時に推定した情動信号を生成する多項分布のパラメータ ϕ^e を固定し，パラメータ θ を Gibbs Sampling により推定することで計算することが可能である．

3.3 語彙獲得の例

実際に IAPS を用いて行った実験の結果を示す．まず，IAPS[JLang05] を用いて畳み込みニューラルネットワーク (CNN) を用いて，入力画像に対して情動価と覚醒度を推定するネットワークを構築した．また，感情価と覚醒度によって簡単な表情を表出するシンプルな顔エージェントを作成した．次に，IAPS の画像と，CNN によって推定された値を用いて駆動したエージェントの顔を被験者に提示し，対応する複数の文書を自由に記述してもらった．図 2 に，データの例を示す．こうして得たデータを，前述の MLDA に入力することで，書く語彙が情動空間とどのように結びつき，モデルの内部でどのような潜在空間ができるかを調べた．

分類結果と確率的に結びついた語彙を，図 3 に示す．これより，感情価 (valence) が小さい左側のカテゴリにはネガティブな感情語が結びついており，逆に右側のカテゴリにはポジティブな語が結びついていることが分かる．学習データの文章は，感情語だけでなく，女性や子どもなどの一般名詞が含まれているため，例えば (e) のカテゴリには，女性という単語が結びついている．これは，感情価が高くかつ覚醒度の高い画像データの多くが，女性を含んでいたためである．こうしたカテゴリ分類がなされてしまうと，感情価が高くかつ覚醒度の高い状況で「女性」という単語が高い確率で予測されてしまい問題となる．画像中に何が写っているかという文脈と情動は分離してモデル化されるべきであるが，これを実現するためには，物体概念など多様な概念を別々に学習し，それらを階層的に結合する多層 MLDA[Attamimi14] を用いる必要がある．



図 2: 学習データの例

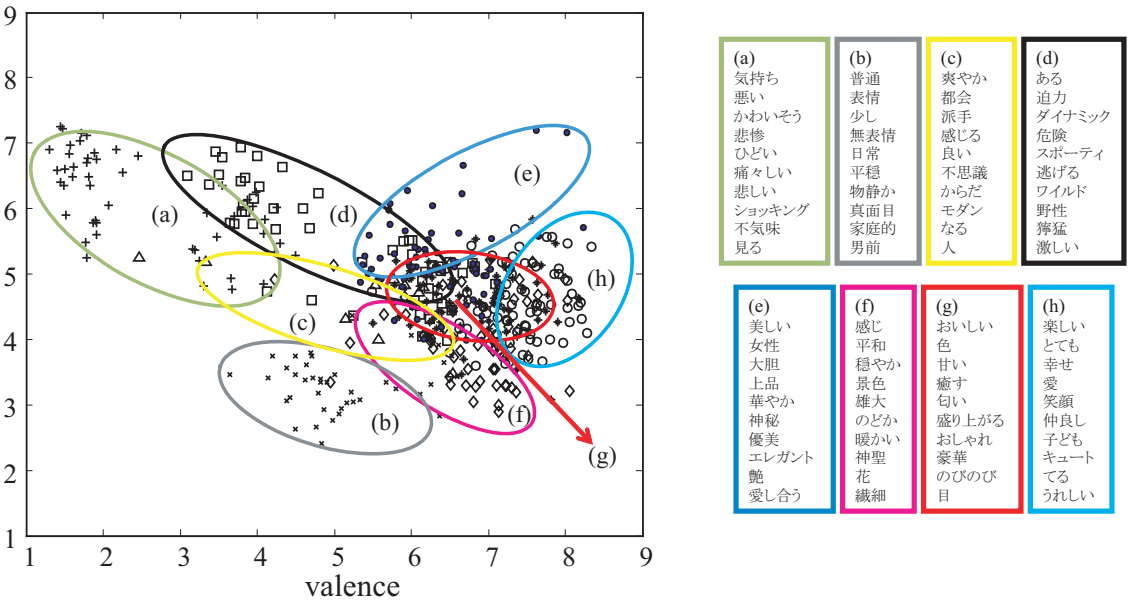


図 3: 分類 (学習) の結果

3.4 未知のシーンに対する単語予測

前述の IAPS データを用いて学習したモデルに対して，学習に用いていない画像を入力し，単語予測の実験を行った．予測結果の例を，図 4 に示す．各図は入力画像と，その際のロボットの表情，および単語予測結果を示している．単語予測のグラフは，確率の高い上位 10 位までを示しており，横軸は予測された単語の文字列を，縦軸は予測確率を示している．これらの結果より，ある程度人の感覚に即した単語が推定されていることが分かる．一方で,「女性」や「セクシー」といった単語は，上述のように学習データに多く含まれていたために推定された単語であり，必ずしも正当なプロセスで推定されているとは言えない．この問題は，シーンに含まれている物体が何であるかを考えていないことが本質的な原因であることは，前述の通りであり，これについては，物体概念を含む複数の概念を階層的に組み合わせることで解決することができると考えられる [宮澤 19].

4. 統合認知モデルと感情

上述の例は，非常に単純化したものであり情動や感情の本質を捉えているとは言い難い．しかし，例えば自然言語処理において，大量の言語資源から単語の分散表現を学習することで語彙同士の関係性から単語の意味を規定する考え方とは異なり，視覚情報が身体に及ぼした影響の知覚と語彙の結びつきに単語の意味を見出している．

この考えをさらに推し進め，情動や感情をモデル化するためにはどうすれば良いであろうか．我々は，宮澤らが提案している統合認知モデル [宮澤 19] に内受容感覚を取り入れるのが，現在実現可能な一つの方向性であると考えている．このモデルは，ロボットのマルチモーダルなセンサ情報や体勢感覚などをモダリティ毎に構造化し，さらにそれらの構造化によって得られる概念（潜在情報）同士の関係を生成モデルとして見出すものである．モデル全体は，強化学習の枠組みや時系列学習の枠組みと統合され，ボトムアップな自己組織的プロセスだけで

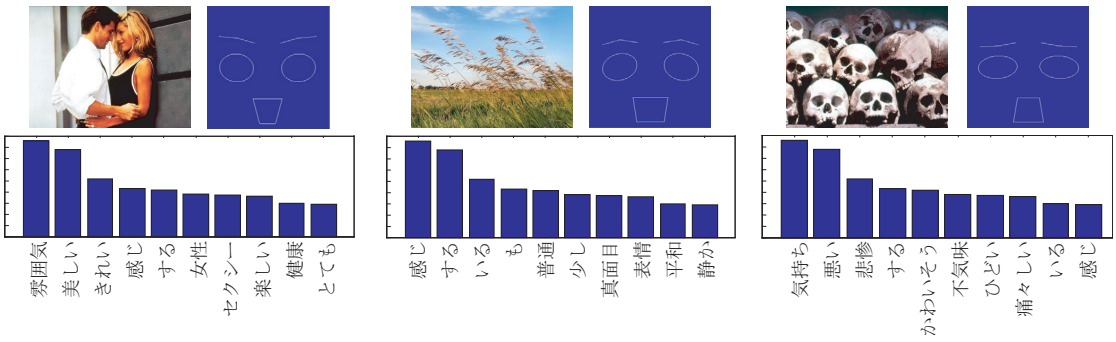


図 4: 単語予測の結果

なく，意思決定や長期の行動計画などに概念構造が影響を受ける．最も単純な考え方は，このモダリティの一つとして身体からの信号を取り入れることである．このモデルで興味深いのは，体勢感覚やモーターコマンドに基づく自他の分離（カテゴリ分類）がなされ，それが他者モデルの獲得につながる可能性があることである．そして，その他者モデルの中には，自身の内受容感覚に基づく情動状態が存在し，他者の情動状態の予測やその言語との結び付けなどが可能となる．

5. まとめ

本稿では，情動/感情を内受容感覚に基づいてモデル化することを検討した．しかしここでの議論は，内受容感覚が与えられたことを仮定してその先にどのような処理があるかを機能レベルで議論しているに過ぎない．逆に言えば，内受容感覚がある種のベクトルとして内部表現されるとすれば，その先は記号創発ロボティクスの枠組みで，知能の一部として議論できる可能性がある．したがってまず重要なことは，いかに内受容感覚を物理的なロボットで作りだすかということかもしれない．それは，バッテリー残量といったロボティクスで扱われる直感的な恒常性で成立するものなのか？尾形らの研究 [Ogata01] は，こうした点を実ロボットで検討した最初の例であり大変興味深いが，その結論はまだ十分明らかではない．また内受容感覚は，モデルからのトップダウンな信号に影響を受けるはずである．今後，内受容感覚やその予測符号化，環境や自他認知，他者モデル，本稿で述べたモデルなどを結びつけつつ，社会的な感情を含めた知能全体をモデル化することで感情のメカニズムを解明し，感情をもったロボットの実現を目指していく必要があると考えている．

謝辞

本研究の一部は，JST CREST(JPMJCR15E3) 及び科研費新学術領域「認知的インタラクションデザイン学」(26118001) の支援を受けて実施した．

参考文献

[Attamimi14] M.Attamimi, M.Fadil, K.Abe, T.Nakmura, K.Funakoshi, T.Nagai, ”Integration of Various Concepts and Grounding of Word Meanings Using Multilayerd Multimodal LDA for Sentence Generation”, IROS2014, pp.2194-2201, 2014

[Breazeal03] C.Breazeal : Emotion and sociable humanoid robots, E. Hudlika (ed), International Journal of Human Computer Interaction, 59, pp.119-155 (2003)

[Damasio03] Damasio, A.: Looking for Spinoza: Joy, Sorrow, and the Feeling Brain, Mariner Books (2003)

[Feldman17] L. Feldman-Barrett: How emotions are made: The secret life of the brain. New York, NY: Houghton Mifflin Harcourt (2017)

[JLang05] P.JLang *et al.*:International affective picture system (IAPS): Affective ratings of pictures and instruction manual, Tech. Report A-6, Univ. of Florida, Gainesville, FL (2005)

[Nakamura11] T.Nakamura, T.Araki, T.Nagai, N.Iwahashi, “Grounding of Word Meaning in Latent Dirichlet Allocation-Based Multimodal Concepts”, Adavanced Robotics 25, 2189-2206, 2011

[Ogata01] T.Ogata, S.Sugano: Emotional Communications Between Humans and the Autonomous Robot which has the Emotion Model, ICRA99, pp.462-467 (1999)

[Taniguchi16] T.Taniguchi, T.Nagai, T.Nakamura, N.Iwahashi, T.Ogata, and H.Asoh: Symbol emergence in robotics: a survey, Advanced Robotics, Vol.30, pp.706-728 (2016)

[浅田 15] 浅田: 情動発達ロボティクスによる人工共感設計に向けて, 日本ロボット学会誌, vol.32, no.89 pp.666-677 (2014)

[乾 18] 乾:感情とはそもそも何なのか:現代科学で読み解く感情のしくみと障害, ミネルヴァ書房 (2018)

[大平 17] 大平：予測的符号化・内受容感覚・感情, エモーション・スタディーズ, 第 3 巻第 1 号, pp.2 — 12 (2017)

[堀井 13] 堀井 他:乳児期の触覚優位性を利用した複数感覚情報の統合による情動文化モデル, 第 31 回ロボット学会学術講演会, RSJ2013AC1P3-04 (2013)

[宮澤 19] 宮澤, 青木, 堀井, 長井: 統合認知モデルによるロボットの概念・行動・言語の同時学習, 人工知能学会全国大会 (2019)

[2E1-J-1] Fundamental AI, theory: quantum computing and search

Chair:Takahisa Toda Reviewer:Yoichi Sasaki

Wed. Jun 5, 2019 9:00 AM - 10:20 AM Room E (301A Medium meeting room)

[2E1-J-1-01] Development of convolution filter embedded quantum autoencoder by quantum simulator

○Shiba Kodai[1], Hiroto Hakamata[2], Katsuhisa Sakamoto[1,2], Kouichi Yamaguchi[1,2], Tomah Sogabe[1,2] （1. The University of Electro-Communications , 2. i-PERC, The University of Electro-Communications ）

9:00 AM - 9:20 AM

[2E1-J-1-02] Total Quantum Search of Optimal Solution in Quantum Computing

○Tomah Sogabe[1], Koudai Shiba[1], Katsuyoshi Sakamoto[1,3], Kouichi Yamaguchi[1,3], Dinesh Malla[2] （1. The University ofElectro-Communications, 2. Grid Inc., 3. i-Powered Energy Research Center,The University ofElectro-Communications）

9:20 AM - 9:40 AM

[2E1-J-1-03] Mechanism Design for Facility Location via SAT Solving

○Nodoka Okada[1], Yuho Wada[1], Taiki Todo[1], Makoto Yokoo[1] （1. Univ. of Kyushu）

9:40 AM - 10:00 AM

[2E1-J-1-04] Reusing a Search Tree in Novelty-Based Pruning

○Ryo Ishibashi[1], Koichi Moriyama[1], Atsuko Mutoh[1], Tohgoroh Matsui[2], Nobuhiro Inuzuka[1] （1. Nagoya Institute of Technology, 2. Chubu University）

10:00 AM - 10:20 AM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

量子シミュレーターを用いた畳み込み型量子自己符号化器の開発

Development of convolution filter embedded quantum autoencoder by quantum simulator

斯波　廣大[1], 坂本 克好[1], 山口 浩一[1], Dinesh Bahadur Malla[2], 曽我部 東馬*[1,2,3]

[1]電気通信大学 先進理工学科

[2]株式会社　グリッド

[3]電気通信大学 i-パワードエネルギーシステム研究センター

The quantum gate type quantum computer has high versatility and can be expected to be put into practical use in short future. However, the quantum bits of the quantum gate type quantum computer are very weak against external interference, and it is difficult to maintain the quantum state for a long time. Therefore, in the currently developed quantum computer, the number of quantum bits is limited, so it is difficult to calculate large scale and high dimensional data. In this paper, as a solution to this problem, we proposed a computation method that applies convolution filter, which is one of the methods used in machine learning, to quantum computation. Furthermore, as a result of applying this method to the quantum auto encoder, we found the effectiveness by applying convolution filter constituted several qubits to the data made of several hundred qubits or more under the autoencoding accuracy of 98%.

1. はじめに

量子ゲート方式量子コンピュータは、解く問題に応じて量子ゲートを組み合わせて量子回路を構築できるため、汎用性が高く数十年後の実用化が期待できる。しかし、量子ゲート方式の量子コンピュータの量子ビットは、外部からの干渉に非常に弱く、量子状態を長時間維持することが難しい。そのため、量子ビット数が多くなるほどノイズが含まれやすく、誤り訂正機能も実装できない。よって、現在は誤り訂正機能がなく、量子ビット数が限られている量子ゲート方式量子コンピュータ NISQ(Noisy Intermediate-Scale Quantum computer)が開発されている[1]。

また、従来のコンピュータで量子ゲート方式量子コンピュータでの量子計算を再現できる量子シミュレータにおいても、量子ビット数を増やすごとに計算時間が指数関数的に上昇するため、数多くの量子ビットを使用する必要があるビッグデータの計算にはかなりの時間が必要となり、現実的ではない。

本稿では、この問題の解決策として、機械学習で用いられている手法の 1 つである畳み込みを量子計算に適用する計算手法を提案する。例としてこの手法を、量子アルゴリズムの 1 つである断熱量子計算を応用した量子自己符号化器に適用し、数量子ビットで構成した畳み込みフィルターを用いて数百量子ビット以上の量子計算を行う有効性について考察する。

2. 量子自己符号化器

自己符号化器とは、出力データが入力データをそのまま再現するように学習する教師あり学習アルゴリズムである[2]。入力層、隠れ層、出力層の 3 層のニューラルネットワークから構成され、隠れ層のデータは入力データの特徴を表すデータと捉えることができる。

量子自己符号化器はニューラルネットワークではなく、最適化アルゴリズムの 1 つである断熱量子計算を用いて計算している。

連絡先：曽我部 東馬,電気通信大学 i-パワードエネルギー・システム研究センター，sogabe@uec.ac.jp

2.1 断熱量子計算

断熱量子計算はイジングモデルを用いて計算されるアニーリング計算手法の 1 つである[3]。イジングモデルとは強磁性体や反強磁性体などの磁性体におけるスピンの動作をモデル化した模型であり、アップスピン($s_i = +1$)とダウンスピン($s_i = -1$)の 2 種類の状態をとる。

イジングモデルの系全体のハミルトニアンは、2 つのスピンs_i, s_j間の結合係数J_{ij}と、スピンs_iの内部にかかる局所的な縦磁場h_{z_i}を用いて次の式で表される。

$$H = \sum_{i<j} J_{ij} s_i s_j + \sum_i h_{z_i} s_i \tag{1}$$

断熱量子計算ではハミルトニアンの初期状態の設定のために、横磁場h_xを追加する。また、スピンs_iはパウリ演算子σ_i^zに相当するため、同じ行列で表される量子ゲートの位相反転演算ゲートZで表現できる。さらに、時間tをt_f規格化したパラメータ$s(= t/t_f)$を導入し、$0 \le s \le 1$とする。よって、断熱量子計算におけるハミルトニアンは次のようになる。

$$H = s\left[\sum_{i<j} J_{ij} Z_i Z_j + \sum_i h_{z_i} Z_i\right] + (1-s)\sum_i h_x X_i \tag{2}$$

量子コンピュータではユニタリ変換を順に行うことで、シュレディンガー方程式の時間発展を表すことができる。量子ビットの状態ベクトルを$|\psi\rangle$とすると、シュレディンガー方程式は次のように表せる。

$$i\hbar \frac{\partial}{\partial t}|\psi\rangle = H|\psi\rangle \tag{3}$$

状態ベクトルが時間に依存し、ハミルトニアンが時間に依存しない時のシュレディンガー方程式を解くと、次のように変形でき、ユニタリ変換$U(t)$が導出される。

$$|\psi(t)\rangle = e^{-i\frac{H}{\hbar}t}|\psi(0)\rangle \tag{4}$$

$$U(t) = e^{-i\frac{H}{\hbar}t} \tag{5}$$

よって、式(5)のHに式(2)を代入し、ユニタリ変換$U(t)$を繰り返し行うことで、ハミルトニアンの最小値が求まり、最適なスピン状態を得ることができる。

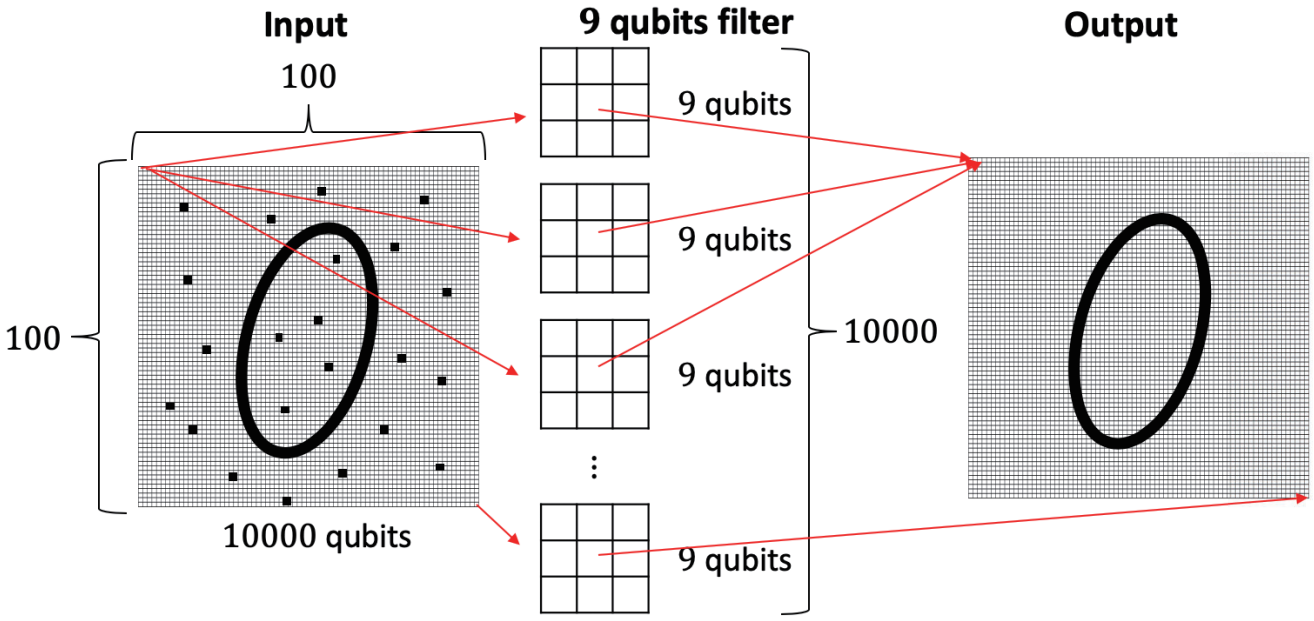


図 1 畳み込み量子自己符号化器のイメージ

2.2 通常の量子自己符号化器

まず、通常の量子自己符号化器として、3 × 3マスの 9 マス白黒画像を入力データとし、入力データの特徴データにノイズを加えた場合に入力データと同じデータを出力できるかを確認する。

各マスに量子ビットを配置し、イジングモデルのスピンとする。また、入力データの特徴データは結合係数Jとし、2 つのスピンs_i, s_jが同じ向きの場合、つまり 2 つのマスが同じ色(白と白または黒と黒)の場合、結合係数は$J_{ij} = -1$とし、2 つのスピンが違う向きの場合は$J_{ij} = 1$と設定する。なお、スピンは図 2 のように上下左右の最隣接 4 スピンとの結合のみを考慮し、周期境界条件を適用する。次に、この結合係数Jの各要素を一定の確率で符号を反転させ、ノイズとする。入力画像とノイズ混入後の画像を図 3 に示す。

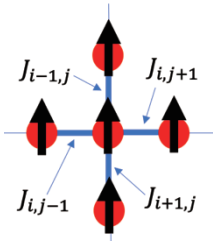
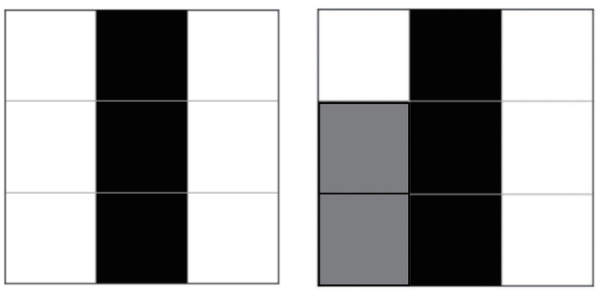


図 2 結合係数Jの設定例



(a) 入力画像　　(b) ノイズ混入画像(ノイズ率 30%)

図 3 9 マス画像(灰色はノイズ混入マス)

このノイズ画像において断熱量子計算を用いてノイズ除去を行った結果を図 4 に示す。また、このノイズ除去を 100 回試し、9 マス画像の量子自己符号化器の正確度を検証した結果を図 5 に示す。

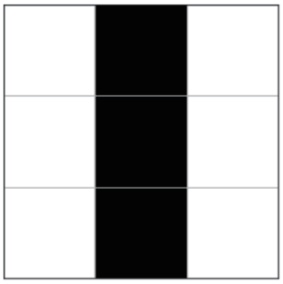


図 4 9 マス画像の量子自己符号化器の出力結果

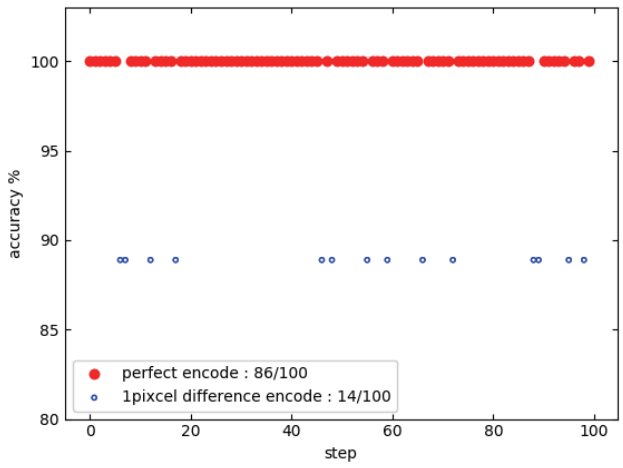


図 5 9 マス画像の量子自己符号化器の正確度

ノイズ率 30%の場合、86%の割合で入力データ画像を完全に復元できた。また、14%の割合で完全にノイズを除去できなかっ

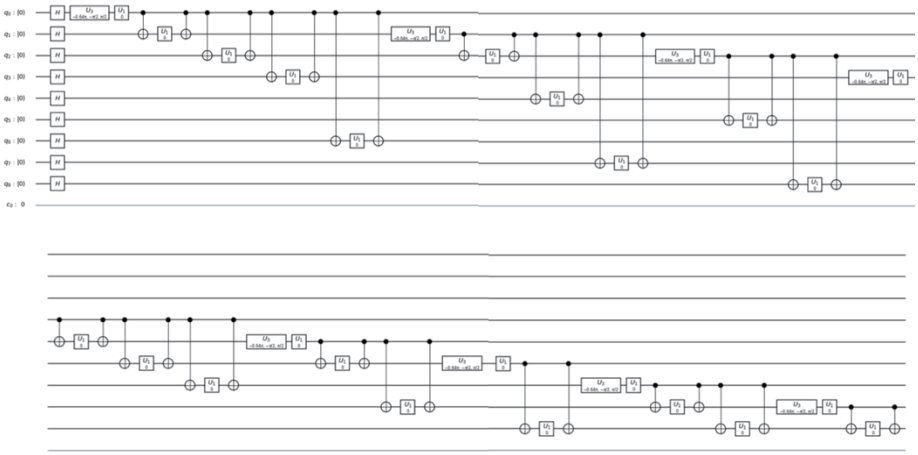


図 6 畳み込み量子自己符号化器における 9 マスの畳み込みフィルターの量子回路図の一部

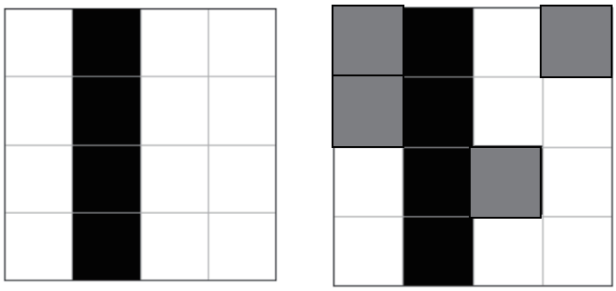
た。この結果を、畳み込みを量子計算に適用する計算手法で量子自己符号化器を行った場合と比較する。

2.3 畳み込み量子自己符号化器

前述したように、量子ビット数が限られた量子コンピュータではビッグデータの計算を行うことが困難である。この問題に対処するために、全てのマスを同時に計算するのではなく、図 1 のように3 × 3マスの 9 マスを畳み込みフィルターと考え、元の画像の 1 マスずつ計算する手法を提案する。各マスは図 2 のように上下左右の最隣接マスのみ相互作用しているが、元画像から取り出した 9 マスにおける中心のマスのみ、元画像と同じ最隣接マスからの影響を受ける。よって、元画像の 1 マスずつ 9 マスのフィルターで計算し、最後に各フィルターの中央マスを集めることで、元画像における自己符号化器として機能するのではないかと考えた。畳み込み量子自己符号化器における 9 マスの畳み込みフィルターの量子回路図の一部を図 6 に示す。

3. 実験

4 × 4マスの 16 マス白黒画像を入力データとし、量子自己符号化器に畳み込みを適用する有効性を検証する。入力画像とノイズ混入後の画像を図 7 に示す。



(a) 入力画像　(b) ノイズ混入画像(ノイズ率 30%)

図 7 16 マス画像(灰色はノイズ混入マス)

このノイズ画像において断熱量子計算を用いてノイズ除去を行った結果を図 8 に示す。また、このノイズ除去を 50 回試し、16 マス画像における畳み込み量子自己符号化器の正確度を検証した結果を図 9 に示す。

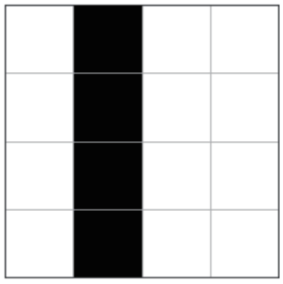


図 8 16 マス画像の量子自己符号化器の出力結果

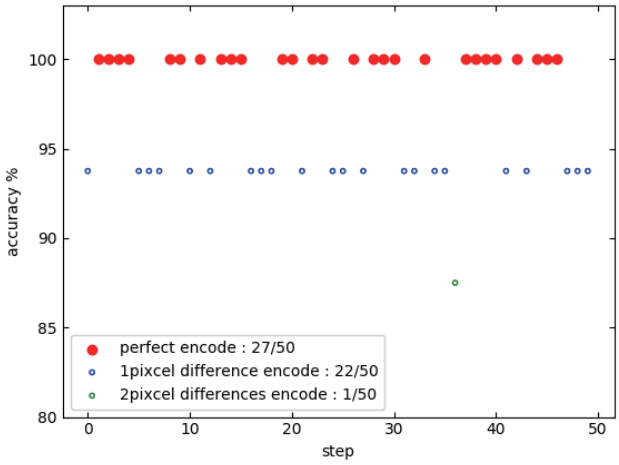
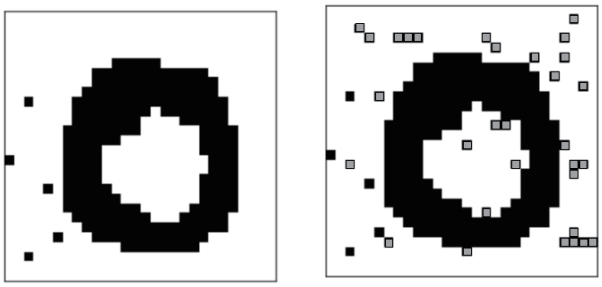


図 9 16 マス画像の量子自己符号化器の正確度

図 8 より、出力データ画像が図 7(a)の入力データ画像と同じ画像になっていることがわかる。よって、ノイズ除去ができていると考えられる。また図 9 より、ノイズ率 30%の場合、54%の割合で入力データ画像を完全に復元できることがわかった。しかし、通常の量子自己符号化器である図 5 と比較すると、正確度が低いことがわかる。これは、9 マスのフィルターでの計算の計 16 回全てにおいてノイズ除去が成功した時にのみ、元画像のノイズが完全に除去できるためであると考えられる。

続いて28 × 28マスの 1MNIST の数字 0 の画像を入力データとし、量子自己符号化器に畳み込みを適用する有効性を検証する。入力画像とノイズ混入後の画像を図 10 に示す。



(a) 入力画像　　(b) ノイズ混入画像(ノイズ率 10%)

図 10 MNIST 画像(灰色はノイズ混入マス)

このノイズ画像において断熱量子計算を用いてノイズ除去を行った結果を図 11 に示す。

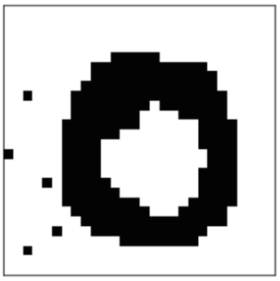


図 11 MNIST 画像の量子自己符号化器の結果

図 11 より、出力データ画像が図 10(a)の入力データ画像と全く同じ画像になっていることがわかる。よって、通常の量子自己符号化器では 784 量子ビットが必要である MNIST 画像でも、畳み込み量子自己符号化器ではノイズ除去ができていると考えられる。

4. おわりに

本稿では、量子ビット数が限られた量子コンピュータでのビッグデータの計算手法として、畳み込みの概念を量子計算に適用する手法を提案した。実験の結果、正確度は劣るものの畳み込み量子計算の有効性を見出せた。今後は正確度の低下の原因を探るとともに、複数枚の入力画像より学習したJを用いた量子自己符号化器に対して、畳み込み計算を適用する有効性の検証を行う予定である。

参考文献

[1] J. Preskill, ”Quantum computing in the NISQ era and beyond,” arXiv: 1801.00862, 2018.

[2] G. E. Hinton and R. R. Salakhutdinov, ”Reducing the Dimensionality of Data with Neural Networks,” Science 313 (5786), pp.504-507, 2006.

[3] E. Farhi, J. Goldstone, S. Gutmann, and M. Sipser, ”Quantum Computation by Adiabatic Evolution,” quant-ph/0001106, 2000.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

量子コンピューティングにおける最適解の全量子探索

曽我部 東馬*[1,2,3]　斯波　廣大[1], 坂本 克好[1], 山口 浩一[1], Dinesh Bahadur Malla[2]
[1]電気通信大学 先進理工学科
[2]株式会社　グリッド
[3]電気通信大学 i-パワードエネルギーシステム研究センター

Variational Quantum Eigensolver (VQE) has been devised which solves large-scale eigenvalue problems by calculating quantum computers and classical computers alternately. Nelder-Mead method is mainly used as a method of optimizing eigenvalues. However, there is a disadvantage that a global optimum solution cannot always be searched. In this paper, we used two kinds of optimization methods, Particle Swarm Optimization (PSO) and Quantum Behaved Particle Swarm Optimization (QPSO) as an alternative method. As a result, we found that the performance of PSO and QPSO is better than that of Nelder-Mead method for the eigenvalue optimization method in VQE algorithm. Furthermore, we found that the relative error when using QPSO is the smallest among the three optimization methods. Meanwhile, we are also incorporating quantum-bit particle swarm optimization (QBPSO) into the eigenvalue optimization method of the VQE algorithm, aiming to realize an eigenvalue search algorithm solely using quantum circuits.

1. はじめに

大規模な固有値問題を解く方法として、量子コンピュータと古典コンピュータを交互に使用して計算する、量子変分アルゴリズム(Variational Quantum Eigensolver : VQE)が考案されている[1]。量子ビットの量子状態を固有ベクトルとして固有値を計算する部分と、固有値を最適化して量子状態を更新する部分に分かれ、前者を量子コンピュータが、後者を古典コンピュータが担うことで、量子超越性が実証できる。

VQE アルゴリズムにおける固有値の最適化方法として、主に Nelder-Mead 法が用いられている。Nelder-Mead 法は目的関数の制約がなく、導関数を必要としないため、滑らかでない関数においても大域的最適解を探索することができる。

しかし、より高次元の固有値探索になると、局所的最適解にとらわれやすく、常に大域的最適解を探索することはできないという欠点がある。

本稿では、Nelder-Mead 法の代替法として、群知能の一種である粒子最適化(Particle Swarm Optimization : PSO)[2]と、PSO の粒子に量子的な振る舞いを持たせた Quantum Behaved Particle Swarm Optimization (QPSO)[3]の 2 種類の最適化法を用いる。さらに、Nelder-Mead 法を用いた場合の結果と比較し、VQE アルゴリズムの効率の向上を検証する。

また、ブロッホ球で表現される量子ビットを用いた探索手法である、quantum bit particle swarm optimization(QBPSO)[4]を VQE アルゴリズムの固有値最適化手法に組み込み、量子回路のみでの固有値探索アルゴリズムの実現を目指す。

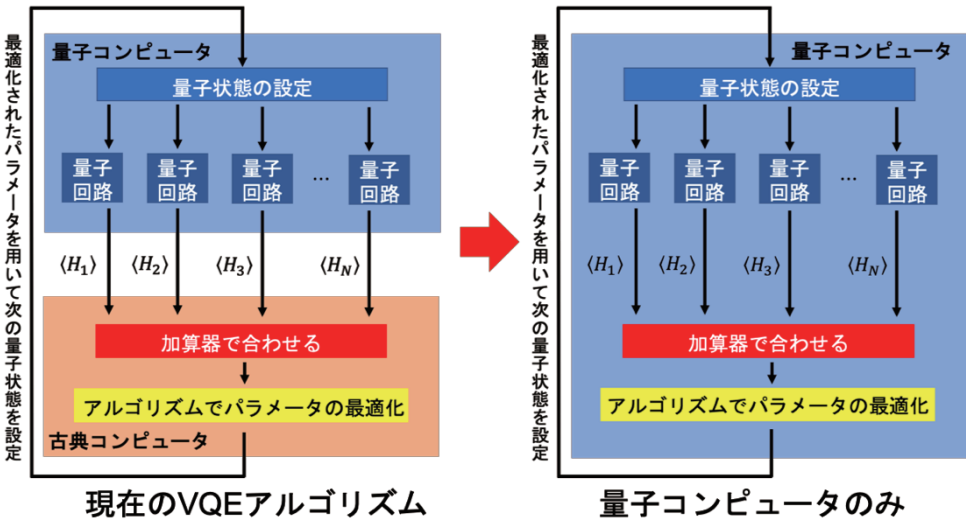


図 1 固有値探索量子アルゴリズムのイメージ

連絡先：曽我部 東馬,電気通信大学 i-パワードエネルギー・システム研究センター，sogabe@uec.ac.jp

2. 最適化アルゴリズム

2.1 PSO

PSO は複数の粒子で探索空間内に群を形成して探索する手法である。各粒子は位置の情報だけでなく、速度の情報をもち、群の中で情報を共有しながら探索する。$t+1$ステップ目におけるi番目の粒子の位置x_i^{t+1}と速度v_i^{t+1}をそれぞれ式(1)、(2)に示す。

$$x_i^{t+1} = x_i^t + v_i^{t+1} \tag{1}$$

$$v_i^{t+1} = wv_i^t + c_1r_1(p_i - x_i^t) + c_2r_2(p_G - x_i^t) \tag{2}$$

x_i^tとv_i^tはtステップ目におけるi番目の粒子の位置と速度であり、p_iはi番目の粒子がtステップ目までに探索した最良解(Personal best)、p_Gはtステップ目までに探索した群全体における最良解(Global best)である。w, c_1, c_2は重みのパラメータであり、r_1, r_2は[0, 1]を範囲とする一様乱数である。式(1)、(2)を用いて各粒子の位置と速度を更新しながら、群全体で最適解を探索する。

粒子が群全体における最良解p_Gに収束する収束モデルを式(3)に示す。

$$P = (\varphi_1 p_i + \varphi_2 p_G)/(\varphi_1 + \varphi_2) \tag{3}$$

φ_1とφ_2は一様乱数であり、これらの値を適切に選択することで各粒子は点Pに収束する。そのため PSO の粒子は点Pから離れた場所では存在しにくくなり、点Pの周辺で解探索を行う。

2.2 QPSO

QPSO における粒子は PSO で用いる速度の代わりに量子的振る舞いを持たせた粒子であり、粒子の位置は量子力学に基づく確率的観測によって決定される。

式(3)により表される、PSO の収束モデルを表現するために、量子井戸のデルタ関数ポテンシャル場を考え、量子状態の粒子が、中心がPであるポテンシャルによる束縛状態を持つとする。量子井戸のデルタ関数ポテンシャルに存在する粒子の量子状態を、波動関数から導出されるシュレディンガー方程式を式(4)に示す。

$$\frac{d^2\psi}{dy^2} + \frac{2m}{\hbar^2}[E + \gamma\delta(y)]\psi = 0 \tag{4}$$

yは粒子の位置xと点Pとの差である。mは粒子群を表し、$\hbar$はプランク定数を2πで割ったディラック定数、Eはポテンシャルの持つエネルギー、γは任意の実数である。$|y| \to \infty$の時$\psi \to 0$となる条件のもとで式(4)を変形することで、量子井戸のデルタ関数ポテンシャル場における粒子の存在確率を示す確率密度関数$|\psi(y)|^2$は次のように表せる。

$$|\psi(y)|^2 = \frac{1}{L}e^{-2|y|/L} \tag{5}$$

式(5)より、粒子と点Pとの距離が近いほど粒子の存在確率が高まり、遠いほど粒子の存在確率が低くなる。

また、ポテンシャル場の中心Pからの探索幅Lは式(4)を変形することで、次のように表現できる。

$$L = (1/g)|y| = (1/g)|x - P| \tag{6}$$

gは QPSO における唯一のハイパーパラメータであり、$ln\sqrt{2}$より大きいという条件を満たす。よって、tステップ目におけるi番目の粒子の位置は式(7)によって更新される。

$$x_i^t = \begin{cases} P - L * (\ln(1/u)) & r < 0.5 \\ P + L * (\ln(1/u)) & r \geq 0.5 \end{cases} \tag{7}$$

uとrは[0, 1]を範囲とする一様乱数である。QPSO は式(7)により粒子の位置を更新して、群全体で最適解を探索する。

3. 実験

量子シミュレータを用いて、VQE アルゴリズムで4×4行列の固有値 4 個と、8×8行列の固有値 8 個を求め、Nelder-Mead 法、PSO、QPSO の 3 種類の最適化法の性能を比較する。VQE アルゴリズムでは式(8)で示すように、量子状態$|\psi\rangle$に対するハミルトニアンHの期待値Eが基底状態のエネルギーE_0よりも常に大きいか等しいという変分原理に基づき、最小固有値を探索する。

$$\langle H \rangle = \langle \psi | H | \psi \rangle \geq E_0 \tag{8}$$

また、ハミルトニアンHの行列が対称行列であり、全ての固有値の符号が等しい場合、Hの固有ベクトル$|v_0\rangle, |v_1\rangle, |v_2\rangle, \ldots$を用いて式(9)が成立する。

$$H = H|v_0\rangle\langle v_0| + H|v_1\rangle\langle v_1| + H|v_2\rangle\langle v_2| + \cdots$$

$$H - H|v_0\rangle\langle v_0| = H|v_1\rangle\langle v_1| + H|v_2\rangle\langle v_2| + \cdots \tag{9}$$

VQE アルゴリズムは式(8)より、1 つの固有値のみ探索するため、式(9)に基づき行列を変化させ、元のハミルトニアンHの全ての固有値を一つずつ求める。

3.1 4×4行列

まず、VQE アルゴリズムで4×4行列の固有値 4 個を求め、3 種類の最適化法の性能を比較する。各アルゴリズムのパラメータの値は経験的に決定する。ハミルトニアンHの行列を式(10)に示す。

$$H = \begin{bmatrix} 3 & 0 & 0 & 2 \\ 0 & 5 & 0 & 0 \\ 0 & 0 & 4 & 0 \\ 2 & 0 & 0 & 2 \end{bmatrix} \tag{10}$$

また、各固有値の理論値を式(11)に示す。

$$\lambda_0 = 5, \quad \lambda_1 = 4.562, \quad \lambda_2 = 4, \quad \lambda_3 = 0.4384 \tag{11}$$

最適化法を PSO とした場合の固有値λ_1の探索推移を図 2 に示す。

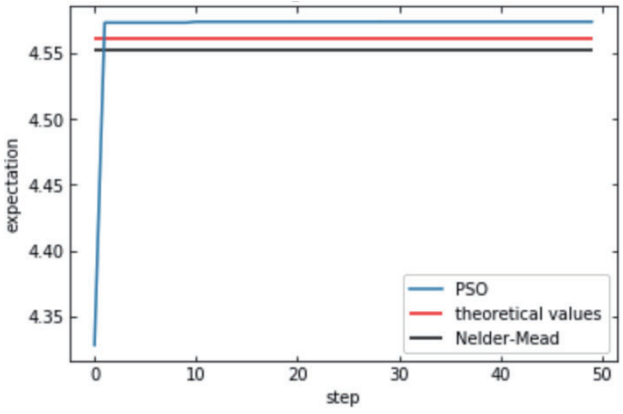


図 2 VQE における固有値探索推移 (PSO)

また各固有値において、3 種類の最適化法それぞれで求めた解と理論値との相対誤差を求めた結果を図 3 に示す。

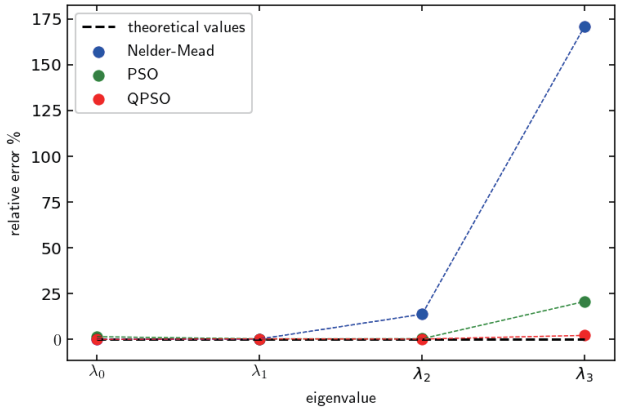


図 3 各最適化法による固有値の理論値との相対誤差比較

図 3 より、λ_0とλ_1はどの最適化法でも理論値に近い値を探索できていることがわかる。しかしλ_2とλ_3における相対誤差を比較すると、QPSO で探索した解の誤差が一番小さく、Nelder-Mead 法で探索した解の誤差が一番大きいことがわかる。

3.2 8 × 8行列

続いて、VQEアルゴリズムで8 × 8行列の固有値8個を求め、3 種類の最適化法の性能を比較する。各アルゴリズムのパラメータの値は経験的に決定する。ハミルトニアンHの行列を式(12)に示す。

$$H = \begin{bmatrix} 3 & 0 & 0 & 2 & 0 & 0 & 1 & 0 \\ 0 & 5 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 4 & 0 & 0 & 4 & 0 & 0 \\ 2 & 0 & 0 & 2 & 0 & 0 & 0 & 6 \\ 0 & 0 & 0 & 0 & 3 & 0 & 0 & 0 \\ 0 & 0 & 4 & 0 & 0 & 7 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 & 2 & 0 \\ 0 & 0 & 0 & 6 & 0 & 0 & 0 & 9 \end{bmatrix} \quad (12)$$

また、各固有値の理論値を式(13)に示す。

$$\lambda_0 = 12.55, \quad \lambda_1 = 9.772, \quad \lambda_2 = 5, \quad \lambda_3 = 3.952$$
$$\lambda_4 = 3, \quad \lambda_5 = 1.572, \quad \lambda_6 = 1.228, \quad \lambda_7 = -2.078 \quad (13)$$

λ_7のみ負の値であるが、今回も式(9)を用いて探索したため、λ_7のみ正しく探索できない。

8 × 8行列の固有値を求めるVQEアルゴリズムの量子回路図を図 4 に示す。また、最適化法を QPSO とした場合の固有値λ_2の探索推移を図 5 に示す。

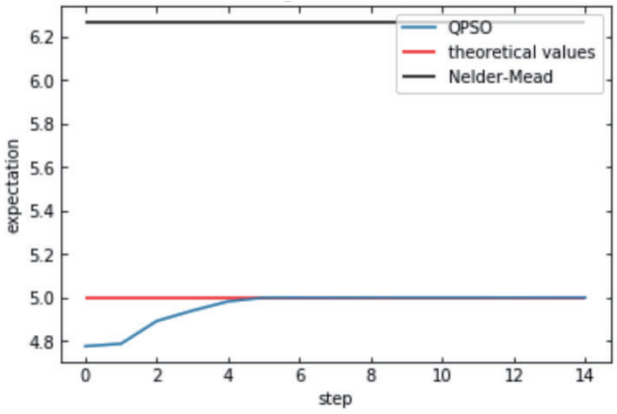


図 5 VQE における固有値探索推移 (PSO)

また各固有値において、3 種類の最適化法それぞれで求めた解と理論値との相対誤差を求めた結果を図 6 に示す。

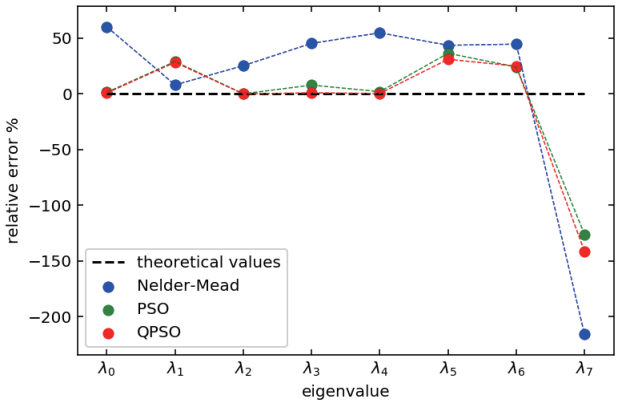


図 6 各最適化法による固有値の理論値との相対誤差比較

図 6 より、λ_7がどの最適化法でも相対誤差が大きいことがわかる。前述した通り、λ_7の理論値が負の値であるためである。また、各固有値を比較すると、λ_1のみ Nelder-Mead 法で探索した解の誤差が一番小さいが、その他の固有値を考慮すると、QPSO で探索した解の誤差が一番小さいと考えられる。

4. おわりに

本稿では、VQE アルゴリズムの最適化法に PSO と、QPSO の 2 種類の最適化法を用いて、Nelder-Mead 法を用いた場合と比較し、VQE アルゴリズムの効率の向上を検証した。実験では VQE アルゴリズムにおける固有値の最適化方法は Nelder-Mead 法よりも PSO や QPSO を用いたほうが性能が良く、中でも QPSO を用いた場合の誤差が一番小さいことがわかった。

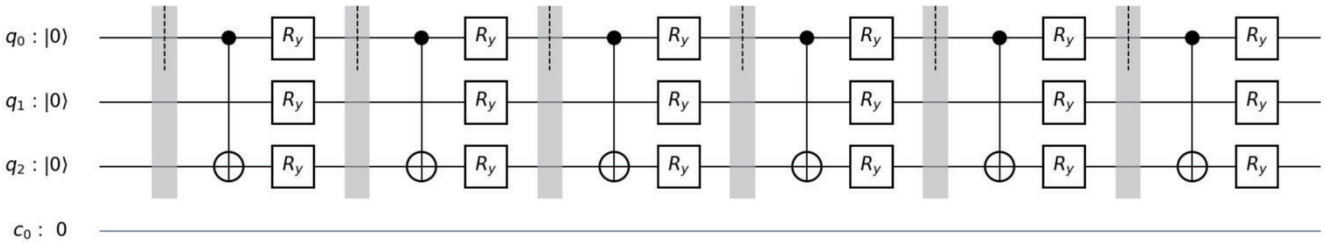


図 4 VQE アルゴリズムの量子回路図

今後は、粒子群最適化の効率を改善するために、ブロッホ球で表現される量子ビットを用いた探索方法である Bloch quantum-inspired particle swarm optimization(BQPSO)[4] を VQE アルゴリズムの固有値最適化手法に組み込み、量子回路のみでの固有値探索アルゴリズムの実現や、VQE アルゴリズムのさらなる効率の向上を図る予定である。

参考文献

[1] A. Peruzzo, J. McClean, P. Shadbolt, M.-H. Yung, X.-Q. Zhou, P. J. Love, A. Aspuru-Guzik, J. L. O'Brienh, "A variational eigenvalue solver on a photonic quantum processor," Nature Communications, Vol.5, id.4213, 2014.

[2] J. Kennedy and R. C. Everhart, "Particle Swarm Optimization" Proc. Int'l Conf. Neural Networks, Vol.4, pp.1942-1948 1995.

[3] J. Sun, B. Feng and W. Xu, "Particle Swarm Optimization with Particles Having Quantum Behavior," Proc. Congress on Evolutionary Computation, 2004.

[4] Xiande Liu and Xiaoming Liu, "Quantum Particle Swarm Optimization Based on Bloch Coordinates of Qubits," 2013 Ninth International Conference on Natural Computation (ICNC), 2014.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

SAT ソルバーを利用した施設配置のメカニズムデザイン

Mechanism Design for Facility Location via SAT Solving

岡田 和夏 Nodoka Okada　和田 勇歩 Yuho Wada　東藤 大樹 Taiki Todo　横尾 真 Makoto Yokoo

九州大学 大学院システム情報科学府
Graduate School of Information Science and Electrical Engineering, Kyushu University

We consider the problem of locating one facility on discrete grids with variable populations. An agent's preference is single-peaked or single-dipped, depending on whether she wants to access the facility (a public good), or be far from it (a public bad). In this paper, we clarify whether or not there exists a mechanism which satisfies both false-name-proofness and Pareto efficiency on a discrete grid by using SAT solver. Concretely, we reveal the existense about the appropreate mechanism on a grid which size is less than 3×3, further the impossibility besides those grids. Moreover, we also clarify the impossibility about ontoness on grids which size is over 2×3.

1. 序論

施設配置問題は，集団における意思決定を考察する伝統的な研究課題であり，メカニズムデザインの 1 分野として，現在においても活発な研究がなされている [Anastasiadis 18, Keijzer 18]．この問題では，参加者 (エージェント) の選好とエージェントが申告する所在地に基づき，施設の配置位置を適切に決定する．この際，エージェントの選好として，**単峰的選好**と**単溝的選好**の 2 種類が考えらえる．単峰的選好とは，自身の所在地から施設の配置位置までの距離が小さい程，効用が高いとする考えであり，例として，図書館やバス停などの近くにあると利便性が高い公共財 (公益財) に対して我々が持ち得る．一方，単溝的選好とは，自身の所在地から施設の配置位置までの距離が大きい程，効用が高いとする考えであり，例として，原子力発電所や産業廃棄物処理場などの近くにあると疎ましい公共財 (公害財) に対して我々が持ち得る．

本論文では，効率性を表す指標として**パレート効率性**を導入する．メカニズムデザインの分野においても，「いずれのエージェントの効用も犠牲にせず，他のエージェントの効用を改善することができる」非効率的な状況を回避するために，パレート効率性を満たすメカニズムの設計は重要視されている．また，各エージェントが利己的に振る舞う環境では，エージェントが自身の所在地を偽ることで，より高い効用を得ようとする不正行為 (**戦略的操作**) に頑健なメカニズムの設計が重要である．更に，電子投票システムを用いた選挙のように，インターネット上で運用するメカニズムを設計する場合は，1 人のエージェントが複数のアカウントを用いて，複数人のエージェントであるかのように振る舞う不正行為 (**架空名義操作**) に頑健なメカニズムの設計も重要となる．架空名義操作は戦略的操作を一般化したものとして知られているため，本論文では，架空名義操作に頑健なメカニズムについて考える．

公益財を配置する施設配置問題の研究として，連続一次元空間におけるパレート効率性，戦略的操作不可能性，匿名性の 3 つの性質を満たす施設配置メカニズムの特徴付けがなされている [Moulin 80]．また，多次元空間における戦略的操作不可能性を満たす施設配置メカニズムも考察されている [Sui 13]．更に，戦略的操作不可能性を一般化した架空名義操作不可能性を満たす施設配置メカニズムの研究もなされており [Todo 11, Sonoda 16]，離散空間の場合 [Ono 17, Nehama 19]，多次元離散空間や公害財の場合 [Wada 18] においても考察がなされている．

施設配置問題では，空間のサイズや満たすべき性質の数が増加すると条件分岐が指数関数的に増加するため，人間がメカニズムの設計や不可能性の証明を行うことは極めて困難となる．そこで，我々は，充足可能性問題 (satisfiability problem, SAT) を解くソフトウェアである **SAT ソルバー**を用いた計算機科学的アプローチで，施設配置問題の解析を試みる．SAT とは，命題論理式が真になる割り当てが存在する (充足可能) か否 (充足不能) かを判定する NP 完全な問題である．しかしながら，限定的なサイズであれば NP 完全な問題を解くことができる．SAT ソルバーは，問題を入力として与えると，充足可能 (SAT) の場合は真偽値の割当を，充足不能 (UNSAT) の場合は“UNSAT”を出力する．また，ソルバーによっては，最小の充足不能な節集合 (Minimum Unsatisfiable Subset, MUS) や UNSAT の導出過程を出力させるなどのオプションも存在する．SAT ソルバーは，定理証明や制約充足問題など様々な分野で活用されており，文献 [Brandt 18] では，メカニズムデザイン研究の 1 分野である社会的選択・投票への活用が紹介されている．

本論文では，まず，施設配置問題を連言標準形 (CNF) の SAT インスタンスに変換する SAT 符号化を紹介する．次に，SAT 符号化した施設配置問題を PicoSAT [Biere 08] に入力して多次元離散空間上の施設配置問題を解き，パレート効率性および架空名義操作不可能性を同時に満たすメカニズムの存在性が理論的結果と一致することを確認する．最後に，SAT ソルバーによって，サイズ 2×3 の格子空間において単溝的選好の場合，パレート効率性，架空名義操作不可能性，および全射性を同時に満たすメカニズムが存在しないことを示す．

2. モデル

本論文では，格子状のグラフ $G = (V, E)$ 上のノードに，1 つの施設を配置する問題を扱う．なお，V はノードの集合，E はエッジの集合を表す．また，潜在的なエージェントの集合を $\mathcal{N} = \{1, 2, \ldots\}$ とする．潜在的なエージェント全員が参加するのではなく，施設を利用しようと考えているエージェントのみが所在地を申告し，意思決定に参加する．メカニズムに参

連絡先: 岡田和夏，九州大学大学院システム情報科学府，819-0395 福岡県福岡市西区元岡 744 番地，(092)802-3576，n-okada@agent.inf.kyushu-u.ac.jp

加するエージェントの集合を $N \subseteq \mathcal{N}(|N| = n \geq 2)$ とする．エージェント $i \in N$ の所在地を $z_i \in V$ とし，エージェントの所在地の組を $Z = (z_i)_{i \in N}$ とする．また，特定のエージェント i の申告を除いた所在地の組を Z_{-i} とする $(Z = (z_i, Z_{-i}))$．各エージェントは自身の所在地と施設の配置位置に関して，コスト関数 $c : V \times V \to \mathbb{Z}$ を持つ．具体的には，任意のノード $a \in V$ に対して，エージェント i が持つコストを $c(z_i, a) \in \mathbb{N}$ と表記する．選好 $p \in \mathbb{B}$ には，エージェントの選好が単峰的である場合は $p = 0$ を割り当て，単溝的である場合は $p = 1$ を割り当てる．なお，各選好の定義は以下の通りである．

定義 1 (単峰的選好) $z_i = (x_i, y_i) \in V$ を所在地とするエージェント i の選好が格子空間 G 上で単峰的選好であるとは，施設の配置位置 $a = (a_x, a_y) \in V$ に対して，コスト c が以下の式に従うことをいう．

$$c(z_i, a) = |x_i - a_x| + |y_i - a_y|.$$

定義 2 (単溝的選好) $z_i = (x_i, y_i) \in V$ を所在地とするエージェント i の選好が格子空間 G 上で単溝的選好であるとは，施設の配置位置 $a = (a_x, a_y) \in V$ に対して，コスト c が以下の式に従うことをいう．

$$c(z_i, a) = -|x_i - a_x| - |y_i - a_y|.$$

例えば，図書館やバス停などの近くにあると利便性が高い公共財 (公益財) に対して持ち得る選好が単峰的選好であり，原子力発電所や産業廃棄物処理場などの近くにあると疎ましい公共財 (公害財) に対して持ち得る選好が単溝的選好である．

本論文では，エージェントの所在地の組 Z とそのエージェントの選好 p を入力し，施設の配置位置 $a \in V$ を出力する配置メカニズムを考える．メカニズム f は，各エージェントの集合 N に対する関数 f_N の組によって $f = (f_N)_{N \subseteq \mathcal{N}}$ と表現され，各 f_N は以下で定義される．

$$f_N : V^n \times \mathbb{B} \to V.$$

配置メカニズム f における施設の配置位置は常に効率的であることが望まれる．本論文では，効率性を表す指標としてパレート効率性を導入する．パレート効率性を満たす配置メカニズムでは,「いずれのエージェントのコストも増加させずに，他のエージェントのコストを減少させることができる」非効率的な状況を回避できる．パレート効率性の定義は以下の通りである．

定義 3 (パレート効率性) 配置メカニズム f がパレート効率性を満たすとは，$\forall N, \forall Z, \forall p$ において，以下の 2 つの条件を同時に満たす $a \in V$ が存在しないことをいう．

- $\forall i \in N$ に対して，$c(z_i, f(Z, p)) \leq c(z_i, a)$ を満たす
- $\exists j \in N$ に対して，$c(z_j, f(Z, p)) < c(z_j, a)$ を満たす

また，上記 2 つの条件を同時に満たさない $f(Z, p)$ をパレート効率的な位置と呼び，パレート効率的な位置の集合を $PE(Z, p) \subseteq V$ と記述する．

また，エージェントは複数の名義を用いて申告を行うことも可能である．エージェント $i \in N$ が使用する名義の集合を ϕ_i とする．このエージェントが名義の集合 ϕ_i を用いて虚偽申告する所在地の組を $Z'_{\phi_i} \in V^{|\phi_i|}$ とする．インターネット上で投票を行う場合，合理的なエージェントは，自身のコストを小さくするために複数のアカウントを用いて，複数人のエージェンであるかのように振る舞う可能性がある．このような不正行為 (架空名義操作) に頑健なメカニズムを設計するためには，1 人のエージェントが複数の名義を用いて所在地を申告しても，自身のコストを小さくできない性質を満たす必要がある．これを架空名義操作不可能性といい，以下のように定義する．

定義 4 (架空名義操作不可能性) 配置メカニズム f が架空名義操作不可能性を満たすとは，以下の条件を満たすことをいう．$\forall N, \forall Z, \forall p, \forall i \in N, \forall z_i, \forall z'_i \in V, \forall \phi_i \subseteq \mathcal{N} \backslash N, \forall Z_{\phi_i} \in V^{|\phi_i|}$ に対して，

$$c(z_i, f(Z, p)) \leq c(z_i, f((z'_i, Z_{\phi_i}, Z_{-i}), p)).$$

施設配置問題において，一名義のみの架空名義操作に対して頑健なメカニズムは，名義の数を制限しない一般の架空名義操作に対しても同様に頑健となることが知られている．したがって，本論文では，一名義のみの架空名義操作について考える．

また，市民主権や公平性の観点から，施設配置問題においては，すべてのノードが配置位置になり得る必要がある．任意のノードについて，少なくとも 1 つの入力プロファイルのもとで，そのノードが出力として選ばれることを全射的であるといい，以下のように定義する．

定義 5 (全射的) 配置メカニズム f が全射的であるとは，$\forall v \in V, \forall p$ に対して，$f(Z, p) = v$ を満たす，ある Z が存在することをいう．

3. SAT 符号化

施設配置問題では，空間のサイズや満たすべき性質の数が増加すると条件分岐が指数関数的に増加するため，人間がメカニズムの設計や不可能性の証明を行うことは極めて困難となる．そこで，我々は，充足可能性問題 (satisfiability problem, SAT) を解くソフトウェアである SAT ソルバーを用いた計算機科学的アプローチで，施設配置問題の解析を試みる．SAT とは，命題論理式が真になる割り当てが存在する (充足可能) か否 (充足不能) かを判定する NP 完全な問題である．しかしながら，限定的なサイズであれば NP 完全な問題を解くことができる．

このアプローチの核心は，施設配置問題を CNF 形式の SAT インスタンスとして符号化することである．符号化のためには，問題に関するすべての公理を命題論理で記述する必要がある．本節では，グラフ G と選好 p から，自動で CNF 形式の SAT インスタンスを生成するアルゴリズムの提案を行う．

まず，$\forall v \in V$ に対して，厳密な選好を表す二項関係を求め，選好の集合 $P_{p,v}$ に格納する．

次に，$\forall S \subseteq V$ に対して，パレート効率的なノードの集合 $PE(S, p)$ を求め，パレート効率的なノード $v \in PE(S, p)$ に対して，変数 $b_{S,v}$ の定義を行う．ここで，変数 $b_{S,v}$ は，入力プロファイルが S のときに施設が v に配置されることを意味する．その後，以下の論理式で示すように，変数 $b_{S,v}$ を変数の集合 B に追加する．

$$B \equiv \bigvee_{v \in PE(S,p)} b_{S,v}.$$

続いて，施設配置問題の下限制約を以下の論理式で定式化する．

$$C_u \equiv \bigvee_{v \in PE(S,p)} b_{S,v}.$$

ここで，下限制約とは，エージェントの所在地の組 $\forall Z$ に対して配置可能なノードの集合 $PE(S,p)$ の内，少なくとも 1 つのノードに施設が配置されることを意味する．

同様に，施設配置問題の上限制約も以下の論理式で定式化する．

$$C_u \equiv \bigvee_{(v,v')\in PE(S,p)} (\neg b_{S,v} \vee \neg b_{S,v'}).$$

ここで，上限制約とは，エージェントの所在地の組 $\forall Z$ に対して配置可能なノードの集合 $PE(S,p)$ の内，複数のノードへ同時に施設が配置されないことを意味する．

更に，架空名義操作不可能性に関する制約の定式化を行う．まず，$\forall S \subseteq V, \forall m \in S$ に対して，m に位置するエージェントによって，S から操作可能なプロファイルの集合 $M(S,m) \subseteq V$ を求める．次に，$\forall T \in M(S,m), \forall (v,v') \in P_{p,m}$ に対して，$v \in PE(T,p)$ かつ $v' \in PE(S,p)$ の場合，すなわち，m に位置するエージェントにとって，v' より v の方がコストが小さくなる場合，以下の論理式で架空名義操作不可能性に関する制約を定式化する．

$$C_r \equiv \bigvee (b_{S,v'} \rightarrow \neg b_{T,v}).$$

命題論理の性質より，上式を CNF 形式に書き換えることができる．

$$C_r \equiv \bigvee (\neg b_{S,v'} \vee \neg b_{T,v}).$$

架空名義操作不可能性に関する制約の定式化例を例 1 に示す．

例 1 サイズ 2×2 の格子空間において単峰的選好の場合 図 1 では，ノード 0 に位置するエージェントに関して，以下の選好が成り立つ．

$$0 > 1,\ 0 > 2,\ 0 > 3,\ 1 > 3,\ 2 > 3.$$

ここで，プロファイルが 03 のとき，ノード 0 に位置するエージェントは，名義を追加することで以下のプロファイルに操作可能である．

$$3,\ 13,\ 23,\ 013,\ 023,\ 123,\ 0123.$$

例として，プロファイルが 03 のとき施設はノード 1 に配置され (b_{03-1})，プロファイルが 023 のとき施設はノード 0 に配置される (b_{023-0}) 場合を考える．ノード 0 に位置するエージェントの選好では，$0 > 1$ であるため，操作によってより望ましい結果を得ることができる．したがって，架空名義操作不可能性を満たすためには，以下の論理式を満たす必要がある．

$$b_{03-1} \rightarrow \neg b_{023-0}.$$

CNF 形式にするため，命題論理の性質を用いて論理和の形に変換する．

$$\neg b_{03-1} \vee \neg b_{023-0}.$$

最後に，求めた C_u および C_r を SAT インスタンスに追加し，同様の手順を繰り返す．

以上のアルゴリズムを表現するために必要な 2 つの関数 BINARY-RELATION(p,v)，MANIPULATION(S,m) を紹介する．

BINARY-RELATION(p,v)

選好 p とノード v が与えられた場合，v の厳密な選好を表す二項関係を返す．

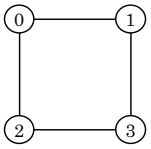


図 1: サイズ 2 × 2 の格子空間

Algorithm 1 Automated CNF SAT instance Generator

Require: a graph $G = (V, E)$, a preference domain p
Ensure: CNF SAT instance $\mathcal{F}$

let $B \leftarrow \emptyset$, $C_u \leftarrow \emptyset$ and $C_r \leftarrow \emptyset$
for $v \in V$ **do**
  $P_{p,v} \leftarrow$ BINARY-RELATION$(p, v) \subset E^2$
end for
for $S \subseteq V$ **do**
  for $v \in$ PE(S, p) **do**
    $B \leftarrow B \cup \{b_{S,v}\}$
  end for
  $C_u \leftarrow C_u \cup \bigvee_{v\in \mathrm{PE}(S,p)} b_{S,v}$
  for any pair $v, v' \in$ PE(S, p) **do**
    $C_u \leftarrow C_u \cup (\neg b_{S,v} \vee \neg b_{S,v'})$
  end for
end for
for $S \subseteq V$ **do**
  for $m \in S$ **do**
    $M(S, m) \leftarrow$ MANIPULATION$(S, m) \subseteq V$
    for $T \in M(S, m)$ **do**
      for any pair $(v, v') \in P_{p,m}$ **do**
        if $v \in$ PE(T, p) and $v' \in$ PE(S, p) **then**
          $C_r \leftarrow C_r \cup (\neg b_{S,v'} \vee \neg b_{T,v})$
        end if
      end for
    end for
  end for
end for
print C_u and C_r to $\mathcal{F}$
return $\mathcal{F}$

MANIPULATION(S,m)

プロファイル S とノード m が与えられた場合，m に位置するエージェントによって S から操作可能なプロファイルの集合を返す．

提案アルゴリズムを Algorithm 1 に示す．2-4 行目は各ノードにおける厳密な選好関係の計算，6-8 行目はパレート効率性を満たす変数の定義，9 行目は下限制約の定式化，10-12 行目は上限制約の定式化，14-25 行目は，架空名義操作不可能性に関する制約の定式化を行っている．

4. SAT ソルバーの出力結果

SAT 符号化した施設配置問題を SAT ソルバーに入力し，充足可能性の判定を行う．充足可能 (SAT) の場合は真偽値の割当が，充足不能 (UNSAT) の場合は “UNSAT” が出力される．本論文では，MUS や UNSAT の導出過程の出力などのオプションが豊富なソルバーである，PicoSAT を用いる．

実際に多次元離散空間上の施設配置問題を解き，パレート

表 1: 単峰的選好における理論的結果と SAT ソルバーの出力結果

サイズ	理論的結果	出力結果
1×3	存在する	SAT
2×2	存在する	SAT
2×3	存在する	SAT
3×3	存在しない	UNSAT
$2 \times 2 \times 2$	存在しない	UNSAT
$2 \times 2 \times 3$	存在しない	UNSAT

表 2: 単溝的選好における理論的結果と SAT ソルバーの出力結果

サイズ	理論的結果	出力結果
1×3	存在する	SAT
2×2	存在する	SAT
2×3	存在する	SAT
3×3	存在しない	UNSAT
$2 \times 2 \times 2$	存在しない	UNSAT
$2 \times 2 \times 3$	存在しない	UNSAT

効率性および架空名義操作不可能性を満たすメカニズムの存在性が，理論的結果と一致することを確認した．表 1，表 2 に単峰的選好および単溝的選好における結果をそれぞれ示す．

また，SAT ソルバーにより，サイズ 2×3 の格子空間において単溝的選好の場合，パレート効率性，架空名義操作不可能性，および全射性を同時に満たすメカニズムが存在しないことが判明した．MUS や UNSAT の導出過程を用いて，可読な不可能性の証明が作成できるのではないかと考えられる．

5. 結論

本論文では，充足可能性問題を解くソフトウェアである SAT ソルバーを用いた計算機科学的アプローチで，施設配置問題の解析を試みた．まず，グラフとエージェントの選好から，自動で SAT インスタンスを生成するアルゴリズムの提案を行い，パレート効率性および架空名義操作不可能性に関する施設配置問題の SAT 符号化を行った．次に，PicoSAT を用いて実際に多次元離散空間上の施設配置問題を解き，パレート効率性および架空名義操作不可能性を同時に満たすメカニズムの存在性が，理論的結果と一致することを確認した．最後に，SAT ソルバーによって，サイズ 2×3 の格子空間において単溝的選好の場合，パレート効率性，架空名義操作不可能性，および全射性を同時に満たすメカニズムが存在しないことが判明した．

今後の課題として以下の 2 つが挙げられる．1 つ目は，問題が充足可能の場合に，真偽値の割当からメカニズムを設計することである．2 つ目は，問題が充足不能の場合に，MUS や UNSAT の導出過程を用いて，可読な不可能性の証明を作成することである．

謝辞

本研究は JSPS 科研費 JP17H00761 および 17H04695 の助成を受けたものです．深く感謝いたします．

参考文献

[Anastasiadis 18] Eleftherios Anastasiadis, and Argyrios Deligkas. Heterogeneous Facility Location Games, The 17th International Conference on Autonomous Agents and Multiagent Systems, pp. 623-631, 2018.

[Keijzer 18] Bart Keijzer, and Dominik Wojtczak. Facility Reallocation on the Line, The 27th International Joint Conference on Artificial Intelligence, pp. 188-194, 2018.

[Moulin 80] Herve Moulin. On strategy-proofness and single peakedness, Public Choice, Vol. 35, No. 4, pp. 437-455, 1980.

[Sui 13] Xin Sui, Craig Boutilier, and Tuomas W Sandholm. Analysis and Optimization of Multi-Dimensional Percentile Mechanisms, In Proceedings of the 23rd International Joint Conference on Artificial Intelligence, pp. 367-374, 2013.

[Todo 11] Taiki Todo, Atsushi Iwasaki, and Makoto Yokoo. False-name-proof mechanism design without money, In Proceedings of the 10th International Conference on Autonomous Agents and Multiagent Systems, Vol 2, pp. 651-658, 2011.

[Sonoda 16] Akihisa Sonoda, Taiki Todo, and Makoto Yokoo. False-Name-Proof Locations of Two Facilities: Economic and Algorithmic Approaches, In Proceedings of the 30th conference on Artificial Intelligence, pp. 615-621, 2016.

[Ono 17] Tomohiro Ono, Taiki Todo, and Makoto Yokoo. Rename and False-Name Manipulations in Discrete Facility Location with Optional Preferences, The 20th International Conference on Principles and Practice of Multi-Agent Systems, pp. 163-179, 2017.

[Nehama 19] Ilan Nehama, Taiki Todo, and Makoto Yokoo. Manipulations-resistant facility location mechanisms for ZV-line graphs, To appear in Proceedings of the 18th International Conference on Autonomous Agents and Multi-Agent Systems, 2019.

[Wada 18] 和田 勇歩，東藤 大樹，横尾 真. 離散空間における施設配置問題の考察, 合同エージェントワークショップ&シンポジウム, 2018.

[Brandt 18] Felix Brandt, Christian Saile, and Christian Stricker. Voting with Ties: Strong Impossibilities via SAT Solving, The 17th International Conference on Autonomous Agents and Multiagent Systems, pp.1285–1293, 2018.

[Biere 08] Armin Biere. PicoSAT Essentials, Journal on Satisfiability, Boolean Modeling and Computation, vol. 4, pp. 75-97, Delft University, 2008.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

Novelty-Based Pruningにおける木の再利用

Reusing a Search Tree in Novelty-Based Pruning

石橋 遼 *1 Ryo Ishibashi　森山 甲一 *1 Koichi Moriyama　武藤 敦子 *1 Atsuko Mutoh　松井 藤五郎 *2 Tohgoroh Matsui　犬塚 信博 *1 Nobuhiro Inuzuka

*1名古屋工業大学 大学院工学研究科 情報工学専攻
Department of Computer Science, Graduate School of Engineering, Nagoya Institute of Technology

*2中部大学 生命健康科学部 臨床工学科
Department of Clinical Engineering, College of Life and Health Sciences, Chubu University

Novelty-Based Pruning (NBP) is a Monte-Carlo Tree Search (MCTS) method that introduced a pruning mechanism based on the novelty of nodes to search more unknown nodes in limited time. When an action is chosen, MCTS methods start a new search from a root node corresponding to the new state. However, it is not appropriate for NBP because the new search clears all information on what sub-trees should be pruned and the information is created again by redundant searches. This work proposes a novel method reusing a searched tree starting with a node corresponding to the new state, which is a child of the old root node. It is expected to increase the number of unknown nodes searched in limited time. In experiments of general video game playing, the number was slightly increased; however, it was not significantly different from the normal NBP.

1. はじめに

近年、様々な分野において木探索アルゴリズムは利用されている。木探索アルゴリズムには、幅優先探索や深さ優先探索といった様々な種類があり、その中の 1 つにモンテカルロ木探索と呼ばれる手法が存在する [1]。これは、ランダムな探索を繰り返してその結果を基に評価値を推定し、木を徐々に拡張して最良となるノードを選択するという手法であり、派生手法もいくつか開発されている。その中の 1 つである Novelty-Based Pruning は探索の際に無駄を省くことで、短時間で多くのノードが探索できるアルゴリズムである [2]。

このようなアルゴリズムが利用される分野として、様々な種類があるビデオゲームを汎用的にプレイするゲームプレイング AI の研究をする General Video Game PlayingAI (GVGAI) [3] という分野が存在する。その分野においてモンテカルロ木探索は、問題特有の知識を必要とせず汎用的に利用できることから、様々なゲームプレイング AI に利用されており [4]、特に Novelty-Based Pruning は 1 人用のゲームをプレイさせる部門において優れた成績を残している [5]。

しかし、このアルゴリズムは行動を選択した後に遷移先のノードをルートノードとして再び探索する際に、以前の探索でそのルートノードの子ノードだった部分を再び探索してしまうことや、以前の探索で不要と判断した部分を探索してしまうことで無駄が生じているという問題がある。そこで本研究では、その無駄な探索を削減しより多くのノードが探索できるようにすることを目的とする。

連絡先: 連絡先: 石橋 遼, 名古屋工業大学工学研究科情報工学専攻, 愛知県名古屋市昭和区御器所町, r.ishibashi.663@nitech.jp

2. モンテカルロ木探索と Novelty-Based Pruning

2.1 モンテカルロ木探索

モンテカルロ木探索 (Monte-Calro Tree Search: MCTS) [1][6] とは最良優先探索の 1 つであり、ランダムに行動を選択してそれを基に評価値を推定し木を拡張しながら探索していく木探索アルゴリズムである。MCTS は、まず現在の状態をルートノードとして設定し、ルートノードのみで構成された木を構築する。そして、「選択」、「シミュレーション」、「拡張」、「伝搬」の 4 つの過程を繰り返し行い、評価値を推定し徐々に木を拡張しながら探索を進めていく。そして、一定時間経つか最後のノード (葉ノード) を探索したら評価値の最も高いノードに遷移するように行動を決定する。以下に 4 つの過程それぞれについて詳しく説明する。

「選択」は、子ノードを追加して木を拡張するノードを選択する過程である。先ずルートノードから開始し、拡張の余地があるノード (そのノードにおいてとり得る行動の数より探索した子ノードの数が少ないノード) に到達するまでノードを選んでいく。ノードを選ぶ上では、推定評価値が高いノードを優先する一方で、探索の上で訪れた回数が少ないノードも選ばれなければならず、これら 2 つの要素のバランスが重要になる。これらのバランスが取れた選び方はいくつか提案されているが、その中で最もよく使用されているのが UCB1 アルゴリズム [1] である。これは、現在のノードを p、p の子ノードの集合を S として、以下の式の値が最大となるような子ノード $s \in S$ を選ぶという方法である。

$$v_s + C \times \sqrt{\frac{\ln n_p}{n_s}} \tag{1}$$

上記の式では、v_sは正規化した s の推定評価値 ($v_s \in [0, 1]$) 、n_p, n_sはそれぞれ p と s を訪れた回数、C は 推定評価値と訪れた回数のバランスを調整するための定数を表している。

「シミュレーション」では追加する予定のノードから仮想のノードを遷移していき、そのノードの推定評価値を計算する。

「選択」の過程で選択されたノードの子ノードの中で、未探索のものを 1 つ選んでそのノードから仮想葉ノード (これ以上拡張できないノード) か、指定した深さの仮想ノードに到達するまでランダムに行動を選択することで遷移していく。評価値の推定には s を追加する予定のノード、t を遷移を繰り返した際の末端の仮想ノード とし、以下の式を適応させる [6]。

$$v_s = \begin{cases} I + v_t & \text{if T is a winning node.} \\ -I + v_t & \text{if T is a losing node.} \\ v_t & \text{if T is a non-terminal node.} \end{cases}$$

上記の式に於いて v_sは s の推定評価値、v_tは t における価値、I は極端に大きい値 (v_tの最大値を v_{tmax}とすると $I \gg v_{tmax}$) を表し、t が望ましい仮想葉ノード (*winning node*) だった場合は v_tに I を加えた値、望ましくない仮想葉ノード (*losing node*) だった場合は v_tから I を引いた値、t が 仮想葉ノードでなかった (*non-terminal node*) 場合は v_tの値が s の推定評価値となる。

「拡張」ではノードを追加して木を拡張する。「シミュレーション」で推定評価値を求めたノードの情報を親ノードに追加し、その追加するノードに親ノードの情報を追加する。これによりノードの追加が行われ、木が拡張される。

「伝搬」では追加したノードの推定評価値をルートノードへ伝搬させる。「シミュレーション」で求めた追加したノードから推定評価値の和を取りながら逆方向に伝搬させる。そして、ルートノードの子ノードにその値を反映させる。このときの 子ノード c の新しい推定評価値 v_c^*は c の古い評価値を v_c、c から追加したノードまでの経路上のノードの集合を N、$n \in N$ の推定評価値を v_n とすると以下の式で表される。

$$v_c^* = v_c + \sum_{n \in N} v_n \tag{2}$$

以上の 4 つの過程を一定の時間内で繰り返し (図 1 参照) 、最終的なルートノードの子ノードの評価値を元に行動を選択する。そして、選択した行動によって遷移した先のノードを新たにルートノードに設定して再び探索する。

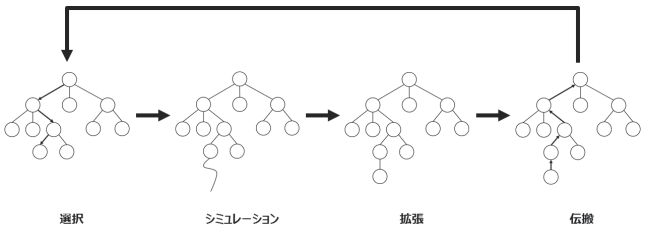


図 1: モンテカルロ木探索

2.2 Novelty-Based Pruning

Novelty-Based Pruning (NBP) [2][6] は MCTS から派生した探索アルゴリズムの 1 つで、先に探索した状態と似た状態が出た場合、それ以降は探索せずに新しい状態を優先して探索するというものである。このアルゴリズムは、使用する上で近傍ノードと新規度 (とそれに伴って新規性) を定義して、ノードの情報として蓄えさせる必要がある。

近傍ノードとは対象となるノードの新規度を計る為の比較対象となるノードの事であり、以下の 4 つのノードを指す。

1. 探索済みの兄弟ノード
2. 親ノード
3. 親ノードの兄弟ノード
4. 親ノードの近傍ノード

例として、図 2 ではノード S_iの近傍ノードを灰色のノードで表す。そしてその後にノード S_{i+1}を対象とする場合は、灰色のノードにノード S_iを加えたものが 近傍ノードとなる。

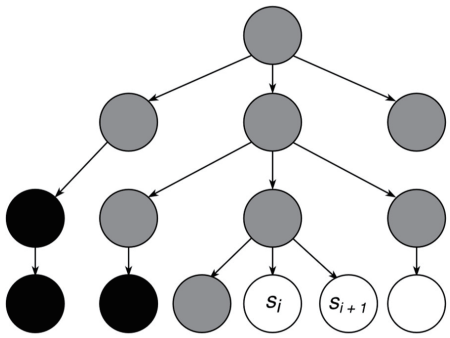


図 2: 近傍ノード

新規度とは、そのノードがどの程度新しいかを数値化したもので値が小さいほど新しい (新規性がある) ものであると判断される。新規度を計る方法は、先ず新規度を計るノードとそのノードの近傍ノードを 1 つずつ比較していく。それらのノードの状態を表す値を比較して、その値が一致するノードの数をカウントしていく。新規度は、近傍ノード中に存在する同じ値を持つノードの数+1 で計られる。例えば、図 2 の ノード S_i の状態を表現する値と同じノードが近傍ノード中に無かった場合、ノード S_i の新規度は 0+1 で 1 となる。この新規度が定めた閾値以下かそれより大きいかでノードの新規性を判断する。新規性はブール代数で表現され、新規性があると判断された場合は true, ないと判断された場合は false となる。

以上を踏まえて NBP の説明をする。新規度の計算及びノードの新規性の判断は MCTS の「選択」の過程にて実行される。「選択」の過程で拡張の余地があるノードが選択されたとき、「シミュレーション」に移行する前に、そのノードの全ての子ノードについて新規度を計る。それらの子ノードの中で、新規度が定めた閾値より大きいノードは新規性がないと判断 (値を false にする) し、「拡張」の過程で木に追加せず、「選択」の過程でも未探索のノードとして扱わない。そして新規度が定めた閾値以下の子ノードは新規性があると判断 (値を true にする) し、MCTS におけるその後の過程で探索の対象となる。後は基の MCTS と同様に新規性のある子ノードに対してシミュレートを行い、そのノードを追加して木を拡張させて、評価値をルートノードまで伝搬させる。そして一定時間繰り返した後に、求めた評価値を元に行動を選択する。そして、選択した行動によって遷移した先のノードを新たにルートノードに設定して再び探索する。なお、全ての子ノードで新規性がないと判

断された場合は、それらのノードの親ノード (「選択」の過程で選択されたノード) も新規性がないと判断し、新規性の値を false に変更する。

3. 提案手法

本研究では行動を決定して遷移する際に、遷移した先の状態をルートノードとして新しく設定する (図 3 左側) のではなく、その行動によって遷移する先のノードをそのままルートノードとして設定する (図 3 右側) 。

従来手法では、探索を開始する際に今の状態をノードで表現し、そのノードをルートノードに設定してルートノードのみから構成される木を構築する。そして、木を拡張しながら探索を進める。

今回提案する手法は、以下のとおりにルートノードを設定する際にその前の探索で決定した行動によってルートノードから遷移する先の子ノードを取り出し、そのノードが持っている情報を維持したままルートノードに設定する。

1. 再利用するための子ノードを見つける
2. 見つかった場合はその子ノードをルートノードに設定する
   (見つからなかった場合は新しくルートノードを設定する)
3. NBP を実行する

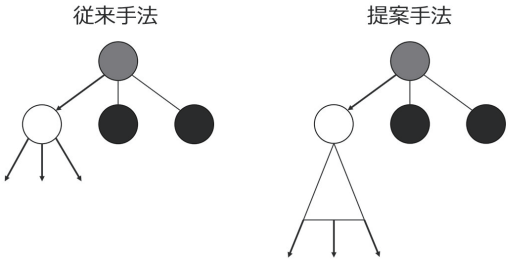


図 3: 従来手法と提案手法の比較
従来手法では遷移先のノードから探索を開始しているが提案手法では子木を再利用し子木の葉ノードから探索を開始している。

この手法では、状態の変化が前の状態に依って変化する (マルコフ性がある) 場合は遷移先のノードの子ノードが成す木 (子木) の持つ情報を失うことなく引き継ぐことができるため、子木を再利用することができるという利点がある。これにより、子木の葉から探索することができ、探索できなかった部分をより多く探索することが可能になる。

4. 実験

4.1 実験方法

本研究では、実際に NBP が使用されているゲームプレイング AI “MaastCTS2”[5] と、それに提案手法の処理を加えて改良したゲームプレイング AI “MaastCTS2_R” で、実際に 10 個の 1-Player ゲーム (1 人用のゲーム) をそれぞれ 10 回ずつプレイし、探索したノード数とゲームのスコアを比較する。

4.2 プレイするゲーム

プレイするゲームは GVGAI の競技会のページで配布されているフレームワークを利用する [3]。これは様々な種類の 2D ゲームをプログラムで扱えるように言語に変換したもので、AI の性能を評価するためのベンチマークとなる。各ゲームには自キャラクター (自分が操作するキャラクター) が存在し、エージェントはこのキャラクターを操作してゲームごとに異なる勝利条件を目指す。本研究では公開されている以下の 10 種のゲームを使用した： aliens, digdug, jaws, labyrinth, missilecommand, pacman, racebet, sheriff, survivezombies, waitforbreakfast。

ゲームを起動すると、エージェントは探索を開始するために 1 秒間の処理時間が与えられ、以降は 40 ミリ秒間隔 (この間隔を tick と呼ぶ) の探索する時間が与えられる。エージェントは各 tick の間に探索をしてどのように操作するかを決定し、その後実行してキャラクターを操作する。これをゲームが終了するまで繰り返しながらゲームを進めていく [4]。

このフレームワークが内包しているゲームは、そのゲーム自体の状況 (経過時間、現在のスコアなど) 、ゲーム内における各要素の状態 (自キャラクターの位置、体力、所持アイテムなど) 、現在の状態からとり得る操作などの情報が全て観測可能なものになっており、エージェントはこれらの情報を値のとして木探索におけるノードに蓄えることで、ゲームの各状態をノードとして扱うことが可能になっている [7]。例えば現在自キャラクターがいる座標を x, y の 2 次元の値で表現し、あるアイテムを所持しているということを 1 で表現すると、ノードには ((x, y) , 1) という情報が蓄えられる。

4.3 MaastCTS2

今回の実験で用いるゲームプレイング AI は 2016 年に Denis Soemers 氏が開発した “MaastCTS2” と呼ばれるものである。これはゲームにおける行動決定を NBP で行っている AI であり、2016 年度の GVGAI の競技会に参加しており、1-Player ゲームの部門において優秀な成績を残している [5]。

この AI では NBP で新規度を計る際に、ノードが持つ状態を表現する値 (現在いる座標、所持アイテムの有無など) の情報をまとめて 1 つの要素と見なし、それら全てが一致する場合のみ同一の状態を表現しているノードと見なす。そして新規性の判断基準は、新規度が 1 である、すなわち近傍ノード中に同一の状態を表しているノードがなかった場合のみ新規性があると判断する。

4.4 MaastCTS2_R

上述した MaastCTS2 に提案手法の処理を加えた AI が “MaastCTS2_R” である。この AI は MaastCTS2 においてルートノードを設定する処理の部分を、ノードが情報を維持したままルートノードに設定されるように改良した AI である。それ以外の部分に関しては変更はしておらず、基の MaastCTS2 と同じように処理をする。

4.5 実験結果と考察

表 1 にそれぞれの手法で実験した結果を示す。スコアと探索ノード数はそれぞれのゲームで 10 回プレイさせた際の平均値で、どちらも大きい方がより良い結果であることを示している。実験の結果から、全てのゲームにおいて提案手法の処理を加えた MaastCTS2_R の方が基となった MaastCTS と比較してより多くのノードを探索した。また、それと同時にゲームそのもののスコアも labyrinth を除いて MaastCTS2_R がよりよい結果を出している。

表 1: 実験結果

	MaastCTS2		MaastCTS2_R	
	スコア	探索ノード数	スコア	探索ノード数
aliens	28.8	302.2	36.4	336.3
digdug	2.9	71.7	5.9	75.4
jaws	1.4	77.2	2.9	78.2
labyrinth	0	331.2	0	382.5
missilecommand	-1.5	82.7	0.8	86.3
pacman	9.6	40.7	12.5	43.3
racebet	0.1	35.5	0.4	36.3
sheriff	-0.1	107.1	1.4	111.2
survivezombies	2044.2	187.5	2694.6	201.1
waitforbreakfast	0.2	27.1	0.4	35.0

しかし、表 2 が示すように探索ノード数については有意差がほとんど見られなかった。一方でスコアについては多少の有意差が見られたが、探索ノード数の差が有意でないことから、提案手法がスコアの上昇に寄与しているとは言い切れない。これは、tick という微小時間単位の中では再利用するノードの数が少なくなってしまうために、結果として両者の間に大きな差が出なかったと考えられる。

表 2: 各ゲームにおけるスコアと探索ノード数について、従来手法と提案手法による t 検定の結果（p 値）

	スコア	探索ノード数
aliens	0.2547	0.3194
digdug	0.0038	0.4736
jaws	0.0429	0.8269
labyrinth	-*	0.2811
missilecommand	0.0009	0.5173
pacman	0.1965	0.3031
racebet	0.1934	0.0457
sheriff	0.0811	0.6815
survivezombies	0.3595	0.4346
waitforbreakfast	0.4433	0.4263

(* : labyrinth のスコアは両手法で同じ結果だったため、p 値の算出はできなかった)

5. おわりに

本研究では、NBP における木探索部分で生じる無駄な探索を削減し、より多くのノードを探索できるようにすることを目的として、それを実現するために木を再利用するという手法を提案した。そして、その手法によって探索ノード数にどれほどの差が出るのかを観察するために、実際のゲームプレイング AI と比較を行った。また、フレームワークを利用することで実際にゲームをプレイさせ、ゲームの結果にどれほど影響するのかの確認も行った。

結果として探索ノード数はわずかに上昇したが、差は有意ではなかった。微小な時間単位の中では再利用するノードの数はそれほど多くはなく、再利用しても探索するノード数に大きな差は生じなかったと考えられる。また、スコアについても提案手法がスコアの上昇に寄与しているとは言い切れない。

今後の課題として、微小な探索時間の中でも有意差が生じるような手法を開発することが課題となる。また、探索時間を延長した場合に有意差は生じるのかを観察することも課題の 1 つである。

参考文献

[1] M. H. M. Winands, “Monte-Carlo Tree Search”, In *Encyclopedia of Compute Graphics and Games,* Springer, 2015.

[2] T. Geffner and H. Geffner, “Width-based Planning for General Video-Game Playing”, *Workshop of General Intelligence in Game-Playing Agents (GIGA),* 2015.

[3] The General Video Game AI Competition
`http://www.gvgai.net/`
(2019 年 1 月 23 日参照).

[4] D. Perez et al., “Open Loop Search for General Video Game Playing”, *Proc. 2015 Annual Conference on Genetic and Evolutionary Computation (GECCO),* pp. 337-344.

[5] D. Soemers, “The General Video Game Agent MaastCTS2”,
`https://dennissoemers.github.io/jekyll/update/2016/09/29/the-general-video-game-agent-maastcts2.html`
(2019 年 1 月 23 日参照).

[6] D. J. N. J. Soemers et al., “Enhancements for Real-Time Monte-Carlo Tree Search in General Video Game Playing”, *Proc. 2016 IEEE Conference on Computational Intelligence and Games (CIG),* 2016.

[7] D. Ashlock et al., “General Video Game Playing Escapes the No Free Lunch Theorem” *Proc. 2017 IEEE Conference on Computational Intelligence and Games (CIG),* 2017

General Session | General Session | [GS] J-6 Web mining

[2E5-J-6] Web mining 2

Chair:Kotaro Nakayama Reviewer:Masahiro Ito

Wed. Jun 5, 2019 5:20 PM - 6:20 PM Room E (301A Medium meeting room)

[2E5-J-6-01] Common Characteristics Found in Twitter Data and Human Behavior on Retweet

○Shigeo Shioda Shioda[1], Keisuke Nakajima[1] （1. Chiba University）

5:20 PM - 5:40 PM

[2E5-J-6-02] Resonance Structure of Online Flaming: The Epicenter of Information Sharing on Online Flaming

○Kohei Koyama[1], Kimitaka Asatani[1], Takeshi Sakaki[1], Ichiro Sakata[1] （1. The University of Tokyo）

5:40 PM - 6:00 PM

[2E5-J-6-03] Identifying Know-How Sites by Classifier Learning with Features of Topic Distribution within a Site

○Yohei Ohkawa[1,2], Tatsuya Maeda[1], Tengyang Chen[1], Takehito Utsuro[1], Yasuhide Kawada[3] （1. University of Tsukuba, 2. AVILEN Inc., 3. Logworks Co., Ltd.）

6:00 PM - 6:20 PM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

Twitterデータに見られる特徴と人間のリツイート行動

Common Characteristics Found in Twitter Data and Human Behavior on Retweet

塩田 茂雄　　中島 圭佑
Shigeo Shioda　　Keisuke Nakajima

千葉大学 大学院融合理工学府 都市環境システムコース
Urban Environment & Systems, Guraduate School of Science and Engineering, Chiba University

In order to see the human behavior on Twitter, we analyzed a large amount of Twitter data collected by the keyword search function of Twitter API. We found some common features in Twitter data; e.g., for any search keywords, the number of retweets follows a power-law distribution. We describe some of these characteristics based on the assumption that Twitter users tend to retweet tweets that have been retweeted many times before.

1. まえがき

実社会で重大な出来事が発生すると，Twitterに様々な書き込みやそのコピー（リツイート）が大量に投稿され，やがて沈静化する様子が見られるが，これは実社会における人々の情報活動がTwitter上に表出した現象であり，それら現象のから人々がどのような行動特性を有するかを分析することができる．

現実のソーシャルメディア上の現象は様々であるが，我々はTwitter APIのキーワード検索機能により収集した大量のツイートを分析した結果，以下の共通の特徴を見出した．

1. 日常的なキーワードで検索するとオリジナルツイートが半数以上を占めるが，重大な出来事に関する非日常的なキーワードで検索するとリツイートが大半を占める．
2. （1つのツイートに着目したときの）単位時間あたりのリツイート数の変化は，急峻なピークを迎えたのち昼夜変動を繰り返しながら減衰するという定型パタンに従う．
3. 検索を行うキーワードに関わらずリツイート数は（べき分布のような）裾の長い分布に従い，最大リツイート数と平均リツイート数の差が非常に大きい．
4. リツイート数と（ツイートを行ったユーザの）フォロワー数との相関は小さい．

リツイートは情報のコピーの拡散であるから，1番目は通常時にはつぶやく（日常の感想を記す）ための道具として使われているTwitterが，ひとたび重大な出来事が発生すると情報拡散用ツールとして機能することを意味する．2番目は，Twitter上の情報拡散の仕方に一定の法則が存在することを示唆している．3番目はごく一部のツイートにリツイートが集中すること，さらには（キーワードに関わらず分布形状が共通であることから）その集中の仕方にやはり一定の法則があることを意味するものと考えられる．4番目はいわゆるインフルエンサーがリツイート数の多寡に影響しないことを示唆している．

本稿では，上述の特徴について実データを用いて詳細に説明を行うとともに，特に3番目の特徴に焦点を当て，3番目の特徴がどのような人間の行動特性（リツイート行動）から生じているかについて考察する．

以下，2章ではキーワード検索で収集したTwitterデータの特徴を詳細に説明する．次いで，3章では，人間のリツイート行動に単純なルールを仮定した確率モデルにより3番目の特徴が再現できること，その結果，人々はツイート内容よりもそれまでにリツイートされている回数を基準としてリツイートするか否かを判断している可能性が高いことを示す．最後に，4章において結論を述べる．

表 1: キーワード毎の総ツイート数，リツイート（RT）数

キーワード	総ツイート数	リツイート数	RT 割合
ハロウィン	6,592,492	4,362,237	66.2%
ゴーン	838,076	616,565	73.6%
miss universe	451,784	388,709	86.0%
紅白	3,526,719	2,351,358	66.7%
嵐	3,971,476	2,338417	58.9%
NGT	329,598	223,896	67.9%
なう	772,841	144,957	18.8%
拡散希望	538,722	395,688	73.4%
インフル	374,564	74,064	19.8%
美しい	573,436	278,379	48.5%

2. キーワード検索で収集されるTwitterデータの特徴

2.1 収集方法

Twitter APIのキーワード検索機能により，指定したキーワードを含む収集日からさかのぼって10日間分のツイート（リツイートを含む）を収集する [*1] とともに，収集した各ツイートの投稿日，投稿ユーザのフォロワー数，リツイート数，お気に入り数などのメタデータをあわせて取得した．表1に，本稿で分析するデータを収集する際に使用したキーワードを示す．

2.2 リツイートの占める割合

リツイートはオリジナルツイートのコピーをフォロワーに流す行為であり，典型的な情報拡散である．従って，全体のツイートの中にリツイートが占める割合で，Twitterが情報拡散ツールとして機能する程度を測ることができる．

連絡先: 塩田茂雄，千葉大学，〒263-8522 千葉市稲毛区弥生町1-33，Tel/Fax: 043-290-3237，shioda@faculty.chiba-u.jp

*1 Twitter APIでは，(検索時点を起点とする）過去10日間のデータを収集することができる．

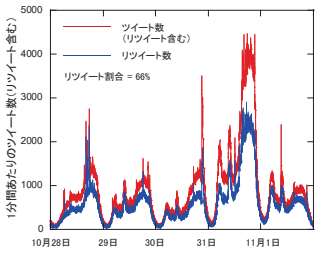


図 1: 1 分当たりのツイート数の時間変化（ハロウィン）

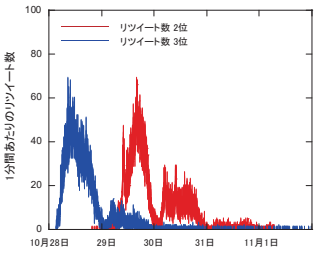


図 2: リツイート数上位のリツイート数変化（ハロウィン）

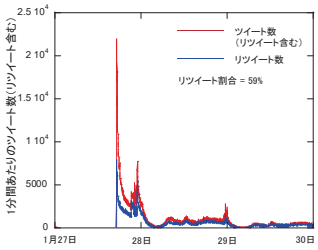


図 3: 1 分当たりのツイート数の時間変化（嵐）

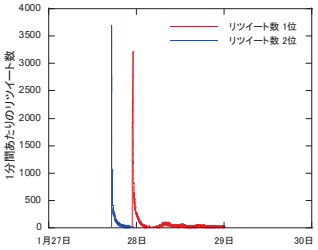


図 4: リツイート数上位のリツイート数変化（嵐）

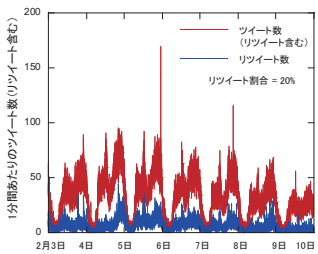


図 5: 1 分当たりのツイート数の時間変化（インフル）

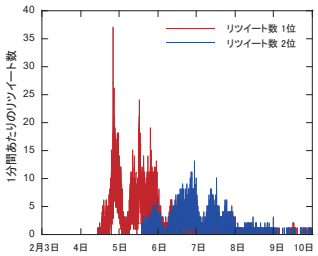


図 6: リツイート数上位のリツイート数変化（インフル）

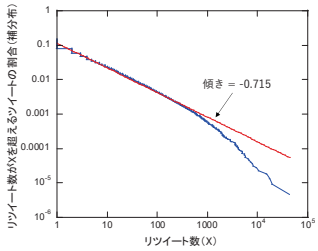


図 7: リツイート数の補分布（ゴーン）

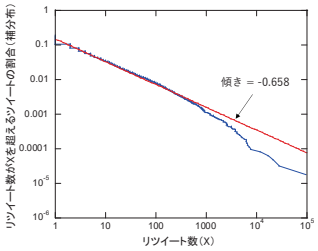


図 8: リツイート数の補分布（miss universe）

表 1 に，キーワード毎に収集した総ツイート数（リツイートを含む），リツイート数，およびリツイートが全体に占める割合を記した．表 1 において,「ハロウィン」から「NGT」までは非日常的な出来事にかかわるキーワードであり，リツイートが半分以上を占める．一方,（日常的なキーワードに相当すると考えられる）「なう」,「インフル」,「美しい」で検索を行うと，リツイートは半分以下となる．

以上のように，普段は日常の感想等を書き込む（つぶやく）ためのツールとして機能している Twitter は，ひとたび非日常的な出来事が発生すると情報拡散ツールとして使われる実態が確認された．

なお,「拡散希望」は日常的なキーワードの 1 つと考えられるが,（拡散を希望するという内容のツイートであるためか）リツイート率は例外的に高かった．

2.3 1 分間あたりツイート数の時間変化

図 1 は「ハロウィン」というキーワードで収集したツイートの 1 分間あたりのツイート数の時間変化を示したものである．図で赤線はツイートとリツイートを合わせた数，青線はリツイートのみの数を表す．図から，ハロウィン（10 月 31 日）より前の 10 月 28 頃から多数のツイートが投稿されており，昼夜変動を繰り返しながら，ハロウィン当日にツイート数のピークが生じている様子が明瞭に見える．10 月 28 日は日曜日であり，渋谷で暴徒と化した集団が軽トラックを横転させるという事件が起きた日である．ハロウィン終了後も多数のツイートの投稿が確認される．図 2 はリツイート数が第 2 位と第 3 位（6 万 6 千件，5 万 8 千件）のツイートのリツイート数の変化である．リツイート数最上位（10 万 7 千件）のリツイートの時間変化データは，途中までしか取れていなかったため，図には掲載しなかった．なお，リツイート数が最大のツイートは交番で警察官がお菓子をあげている所に遭遇した，という内容のツイートであった．

「嵐」というキーワードで取得した Twitter データに関する結果を図 3 と図 4 に示す．データはアイドルグループ「嵐」が 2020 年での活動休止を発表した時期に取得したものである．「嵐」の活動休止は「嵐」の公式サイトで流れ，その直後に 1 分間に 20,000 件を超える大量のツイートが書き込まれている．その少し直後に別のピークが見られるが，これは「嵐」の会見が TV で流れているときのものと思われる．しかし，Twitter への書き込みは 27 日の二つのピーク以降，急速に減少している．なおリツイート数最上位（16 万 4 千件）は「嵐」の会見に関連して青木源太アナウンサーが書き込んだツイート，第 2 位（10 万件）はテレ朝 news の「嵐」の活動休止を報告するツイートであった．

図 5 と図 6 は「インフル」というキーワードで 2019 年 2 月 3 日から取得した結果である．主として，インフルエンザに関するツイートが収集されている．インフルエンザは必ずしも日常的なキーワードではないが，今冬は全国的にインフルエンザが広く流行し，インフルエンザにかかることが珍しくない（日常的な）出来事になっているためか，1 分間あたりのツイート数には日変動はあまり観察されず，昼夜変動を繰り返すだけの定常的な時間変化を示している．実際，リツイートの占める割合も少なく，インフルエンザに関するごく日常的な書き込みが多数を占めている．リツイート数 1 位のツイートもごく日常的な出来事に関するものであった．

2.4 リツイート数の補分布

次に，キーワード毎に，オリジナルツイートがそれぞれ何回リツイートされているかを確認し，その分布の特徴を分析した．一部のキーワードについての結果を図 7 から図 10 に示す．図の横軸はリツイート数（X），縦軸はリツイート数が X を超えるツイートの割合（リツイート数の補分布）を示す．いずれも両対数グラフである．どのキーワードについても，リツイート数の補分布は両対数グラフで直線状にプロットされ，べき分布を連想させる，典型的な裾の長い分布に従う．

表 2 には，それぞれのキーワードに対する補分布の傾きとべき分布で近似したときのべき指数を示した．なお，べき指数は補分布の傾きの符号を反転し（正の値とし），1 を加えたものに等しい．非日常的なキーワードに対するべき指数と日常的なキーワードに対するべき指数は若干異なり，前者の方がやや

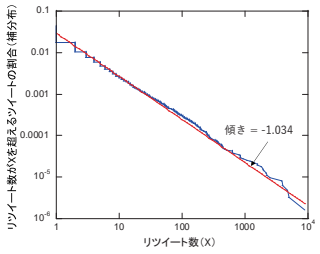


図 9: リツイート数の補分布（なう）

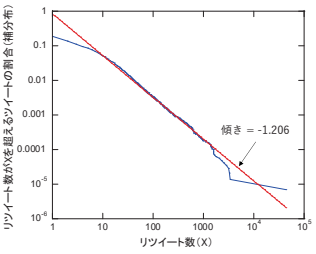


図 10: リツイート数の補分布（拡散希望）

表 2: キーワード毎の補分布の傾きとべき指数

キーワード	補分布の傾き	べき指数
ハロウィン	-0.765	1.765
ゴーン	-0.715	1.715
miss universe	-0.658	1.658
紅白	-0.680	1.680
嵐	-0.715	1.715
NGT	-0.698	1.698
なう	-1.034	2.034
拡散希望	-1.206	2.206
インフル	-0.931	1.931
美しい	-0.817	1.817

小さい値を取る．

2.5 リツイート数と発信者のフォロワー数との相関

最後に各ツイートのリツイート数と発信者のフォロワー数との相関係数を確認した結果を表 3 に示す．やや意外なことに，どのキーワードについても，リツイート数と発信者のフォロワー数との相関係数は小さく，(フォロワー数という尺度での) インフルエンサーが Twitter 上の情報拡散に必ずしも大きな影響力を持つものではないという結果となった．参考までに，各ツイートのリツイート数とお気に入り数の相関係数も示した．リツイート数とお気に入り数の間には明らかな相関がある．

3. リツイート数分布のべき則性の出現モデル

3.1 優先的選択ルールに基づくリツイートモデル

リツイート数がべき分布に従う傾向は，Barabási-Albert モデル [Barábasi 99] で用いられた優先的選択ルールによって説明できると考えられる．以下，優先的選択ルールの要素を取り入れた単純なリツイートモデルを説明する．時刻 t までに書き込まれたツイートの総数を $N_0(t)$，時刻 t までの総リツイート回数を $N_1(t)$，n 番目に書き込まれたツイートの時刻 t でのリツイート数を $r_n(t)$，n 番目に書き込まれたツイートの内容を点数化したものを a_n とする．

1. 時刻 0 以降，頻度 λ_0 でツイートが書き込まれる．
2. 時刻 0 以降，頻度 λ_1 で，その時刻までに書き込まれた全ツイートの中から 1 つツイートが選ばれて，リツイートされる．
3. 2 において，n 番目に書き込まれたツイートは確率 $(a_n + r_n(t))/\sum_{i=1}^{N_0(t)}(a_i + r_i(t))$ で選択される．a_n は n 番目のツイートの価値（魅力）を数値化したものに相当する．

簡単のために，$a_1 = a_2 = \cdots = a$ とする．リツイートされる機会は単位時間あたり λ_1 回存在し，1 回の機会あたり，n 番目に書き込まれたツイートがリツイートされる確率は $(a + r_n(t))/\sum_{i=1}^{N_0(t)}(a + r_i(t))$ であることから，次が成り立つ．

$$\frac{dr_n(t)}{dt} = \lambda_1 \frac{a + r_n(t)}{\sum_{i=1}^{N_0(t)}(a + r_i(t))}$$

ここで，時刻 t までに書き込まれたツイートの総数はおよそ $\lambda_0 t$ に等しいこと，また時刻 t までのリツイート総数はおよそ $\lambda_1 t$ に等しいことより

$$\sum_{i=1}^{N_0(t)}(a + r_i(t)) = aN_0(t) + N_1(t) \approx (a\lambda_0 + \lambda_1)t.$$

したがって

$$\frac{dr_n(t)}{dt} \approx \lambda_1 \frac{a + r_n(t)}{(a\lambda_0 + \lambda_1)t}. \quad (1)$$

n 番目に書き込まれたツイートの書き込み時刻を t_n とする．$r_n(t_n) = 0$ の初期条件のもとで (1) を解くと，次が得られる．

$$r_n(t) = a\left(\left(\frac{t}{t_n}\right)^{1/\gamma} - 1\right), \quad \gamma \stackrel{\text{def}}{=} \frac{a\lambda_0 + \lambda_1}{\lambda_1}.$$

上式より，n 番目に書き込まれたオリジナルツイートのリツイート数が x を超える，つまり $a\left(\left(\frac{t}{t_n}\right)^{1/\alpha} - 1\right) > x$ であることは，

$$t_n < t\left(\frac{a}{a + x}\right)^{\gamma}$$

であること，つまりそのツイートが時刻 $t\left(\frac{a}{a+x}\right)^{\gamma}$ 以前に書き込まれたことを意味する．オリジナルツイートは一定の頻度で書き込まれているので，時刻 t までに書き込まれたツイートのうち，時刻 $t\left(\frac{a}{a+x}\right)^{\gamma}$ 以前に書き込まれたツイートの割合は $\left(\frac{a}{a+x}\right)^{\gamma}$ に等しい．したがって，リツイート数が x を超えるオリジナルツイートの割合 $P(r > x)$ は

$$P(r > x) = \left(\frac{a}{a + x}\right)^{\gamma} \approx \left(\frac{x}{a}\right)^{-\gamma}$$

つまり，リツイート数の分布はべき則に従い，そのべき指数は $\gamma + 1$ に等しい．このモデルでは $\gamma \geq 1$ であり，従ってべき指数の値は 2 以上である．

表 2 で示したように，日常的なキーワードの場合，リツイート数の分布のべき指数は 2 付近もしくはそれ以上の値を取るため，このモデルで説明できる．また，平均リツイート数は λ_1/λ_0 で与えられる点に注意すると

$$a = (\gamma - 1)\frac{\lambda_1}{\lambda_0} = (\gamma - 1) \times \text{平均リツイート数}$$

表 3: リツイート数と（発信者の）フォロワー数，お気に入り数との相関係数

キーワード	対フォロワー数	対お気に入り数
ハロウィン	0.05	0.86
ゴーン	0.05	0.82
miss universe	0.03	0.95
紅白	0.19	0.94
嵐	0.12	0.91
NGT	0.01	0.96
なう	0.23	0.88
拡散希望	0.05	0.98
インフル	0.03	0.95
美しい	0.17	0.83

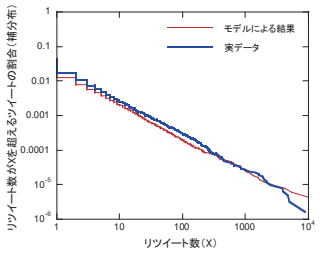


図 11: 提案モデルによるリツイート数の補分布と実データとの比較（なう）

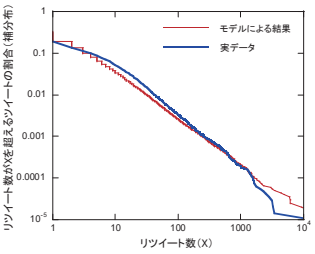


図 12: 提案モデルによるリツイート数の補分布と実データとの比較（拡散希望）

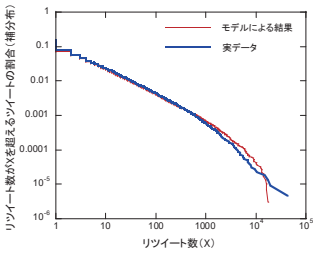


図 13: 提案モデルによるリツイート数の補分布と実データとの比較（ゴーン）

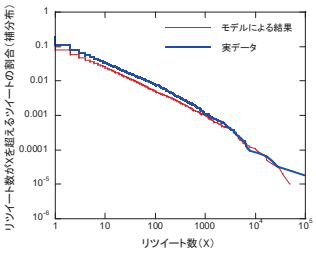


図 14: 提案モデルによるリツイート数の補分布と実データとの比較（miss universe）

が成り立つので，べき指数の値と平均リツイート数から a の値も定まる．キーワードが「拡散希望」のときの平均リツイート数は 2.99，γ の値は 1.206 であるので，$a = 0.616$ である．また，キーワードが「なう」のときの平均リツイート数は 0.27，γ の値は 1.034 であるので，$a = 0.009$ となる．いずれも a の値は非常に小さい．

図 11 は $\lambda_1/\lambda_0 = 0.27$，$a = 0.03$ の設定で，同様に提案モデルを用いてシミュレーションを行い，リツイート数の補分布を図示し，「なう」というキーワードで取得した Twitter データのリツイート数の補分布と比較したものである．補分布はおよそ一致しており，再現性が得られていることが確認できる．一方，図 12 は $\lambda_1/\lambda_0 = 2.99$，$a = 0.616$ の設定で，提案モデルを用いてシミュレーションにより各ツイートのリツイート数を生成し，「拡散希望」というキーワードで取得した Twitter データのリツイート数の補分布と比較したものである．やはり，補分布はおよそ一致する．両ケースとも，1 以上の値を取るリツイート数に比べて a の値は非常に小さく，ほぼリツイート数がリツイートされるか否かを決める要因となっている．すなわち，このモデルは，人々がツイートの内容ではなく，主としてリツイート回数に基づいてリツイートするか否かを決めていることを意味している．

3.2 リツイートモデルの改良

3.1 節のモデルではべき指数は 2 以上の値しか取らないが，表 2 で示したように，非日常的なキーワードの場合，リツイート数の分布のべき指数は 2 未満の値になるため，このモデルでは説明ができない．

べき指数を 2 未満にする一つの方法は，ツイート頻度，リツイート頻度に時間依存性を持たせることである．例えば，

$$N_0(t) = \lambda_0 t^{\eta-1}, \quad N_1(t) = \lambda_1 t^{\eta}, \quad (\eta > 1)$$

とする．このとき 3.1 節のモデルの 1 番目及び 2 番目の項目は以下に変わる．

1*. 時刻 t において，頻度 $(\eta-1)\lambda_0 t^{\eta-2}$ でツイートが書き込まれる．

2*. 時刻 t において，頻度 $\eta\lambda_1 t^{\eta-1}$ で，その時刻までに書き込まれた全ツイートの中から 1 つツイートが選ばれて，リツイートされる．

簡単のために，$a_1 = a_2 = \cdots = a$ とする．このとき，同様の考察から以下が得られる．

$$P(r_n > x) = \frac{\left(\left(\frac{a}{a+x}\right)^{1/\eta}\left(t + \frac{a\lambda_0}{\lambda_1}\right) - \frac{a\lambda_0}{\lambda_1}\right)^{\eta-1}}{t^{\eta-1}}$$

$$\approx \left(\frac{x}{a}\right)^{-\frac{\eta-1}{\eta}}. \quad (x \to \infty)$$

従って η の値を選ぶことによって，べき指数を 1 から 2 の間の自由な値に設定できる．

図 13 は $\eta = 3.3$，$\lambda_1/\lambda_0 = 4$，$a = 0.1$ の設定で，改良リツイートモデルに基づくシミュレーションを行って得られたリツイート数の補分布を図示し，「ゴーン」というキーワードで取得した Twitter データのリツイート数の補分布と比較したものである．補分布はおよそ一致しており，再現性が得られていることが確認できる．一方，図 14 は $\eta = 3$，$\lambda_1/\lambda_0 = 6.6$，$a = 0.1$ の設定で，同様のシミュレーションを行って得られたリツイート数の補分布を図示し，「miss universe」というキーワードで取得した Twitter データのリツイート数の補分布と比較したものである．やはり，補分布はおよそ一致する．

4. むすび

本稿では，Twitter API により収集したツイートデータを分析し，幾つかの共通の特徴が見いだされることを示すとともに， 特にリツイート数分布に関する特徴を，人々のリツイート行動に関するシンプルな確率モデルにより再現できることを示した．なお，1 章で述べた特徴のうち，リツイート数の時間変化に関する（2 番目の）特徴ついては，比較的単純な情報拡散モデル [塩田 18b] により再現できることを確認している [塩田 18a]．本稿で用いた確率モデルはまだ単純であり，今後は Twitter データのより詳細な分析を行ってモデルの精緻化を進めるとともに， Twitter 上の現象の予測法への活用についても検討を進めたい．

参考文献

[Barábasi 99] Barábasi, A.-L. and Albert, R.: Emergence of Scaling in Random Networks, *Science*, Vol. 286, pp. 509–512 (1999)

[塩田 18a] 塩田茂雄, 南川雅人, 中島圭佑：キーワード検索で収集される Twitter データの特徴と Twitter 上の情報拡散過程, 電子情報通信学会情報ネットワーク研究会, IN2018-64, pp. 31–36 (2018)

[塩田 18b] 塩田茂雄，南川雅人，中島圭佑：SNS 投稿件数推移分析のための情報拡散モデルと強相関近似解析, 第二回計算社会科学ワークショップ, pp. 1–10 (2018)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

ネット炎上におけるユーザーの共振構造

Resonance Structure of Online Flaming: The Epicenter of Information Sharing on Online Flaming

小山 耕平[*1] 浅谷 公威[*1] 榊 剛史[*1] 坂田 一郎[*1]
Kohei Koyama Kimitaka Asatani Takeshi Sakaki Ichiro Sakata

[*1] 東京大学大学院工学系研究科
Graduate School of Engineering, the University of Tokyo

As the world becomes more sensitive towards scandals and political correctness, free information sharing is at risk from the fear of online flaming, as such unreasonable online flaming is expected to be eliminated. In this paper, we performed detailed analysis of specific Twitter user groups who get involved with online flaming on Twitter with high frequency. Our aim is to unveil what structure escalates online flaming on Twitter. The result indicates that users who are frequently involved with online flaming are connected through a (followers) network and demonstrates a resonance structure.

1. 概要(Abstract)

ソーシャルメディアは従来のメディアにより報道されなかった情報が拡散する性質を持つ．特定の情報が瞬間的に大きな勢いでソーシャルメディア上にて拡散する現象はネット炎上とよばれ，世論や企業の株価などに大きな影響を与えている．さらに，従来のメディアがネット炎上を後追いで報道することも増えているため，ネット炎上の社会的影響力は強くなりつつある．

ネット炎上において多くの場合，個人や法人に対し誹謗中傷が殺到する．例えば，人種・性差別や企業の不祥事などに関わる問題行為が炎上している．企業の不祥事などに関しては，炎上が問題行為の改善を促す効果を持つ場合がある一方で，議論や対話ではない誹謗中傷が集中する場合もあるという指摘もある[田中 16]．さらに，炎上を恐れて活動自体や情報発信が過度に自粛されてしまうこともあり[Moor 10]．ネット炎上の意見形成への影響は大きいと考えられる．このように社会において重要になりつつなるネット炎上のメカニズムを理解することは重要である．

多くの従来の研究において炎上の時系列推移の理解や予測に焦点が当てられてきた．炎上の推移はSIモデルやHawks Processなどを応用したモデルは炎上のメカニズムのモデル化に適しており，炎上の性質を分類や背後にある心理を推定が行われている[Lehmann 2012, Matsubara 2012]．また，炎上の時系列を予測についても研究が進んでいる[Wang 2015]．このように炎上におけるツイート数の推移の概形から多くのことが推定できる．

近年では，ネット上の議論への参加者個人の性質についての分析も進んでいる．Kumarらは，オンラインコミュニティサイトであるReddit上におけるコミュニティ間の誹謗中傷の発生過程を分析し，1%以下の”攻撃的”なユーザー群が全誹謗中傷の74%を開始させていたことが明らかにした[Kumar 18]．また，オンラインネットワークにおける情報拡散において，一部のフォロワー数が多いユーザーが情報の伝播に大きな役割を担っていることは様々な場面で明らかになっている．これらの議論がそのままTwitter上に当てはまるかは議論の余地が大きいが，複数のTwitterの炎上に高頻度で関わっている人たちがいるとすれば，その性質やその影響力を分析することは炎上のメカニズムの解明の上で重要である．これまでの調査や研究により，ネット関連団体によるアンケート調査[情報処理推進機構 18]やユーザー属性の調査[山口15]により炎上参加者の素性が明らかになりつつあるが，高頻度にネット炎上に参加するユーザ群を想定して分析を行っている研究は存在しない．

本研究では，「ネット炎上」発生メカニズムの一端を解明することを目的に，有力ソーシャルメディアの一つであるTwitter上で「ネット炎上」の分析を行った．特に「ネット炎上に高頻度で関与するユーザー群」の存在を仮定した上で，「そのようなユーザがネット炎上を引き起こす大きな要因の一つになっているのではないか」という仮説をたて，実際に「ネット炎上に高頻度で関与するユーザ」が存在するのか，また存在する場合にそれらのユーザがどのようなユーザー特性を有するのか，および，どのような構造的特徴を有するのかについて分析した．

2018年12月から2019年1月の間に発生した6件の炎上に対して分析を行った結果，計約13万人がいずれかの炎上に参加していた．ユーザーごとの炎上関与回数の分析により，炎上参加者は他の炎上にも参加しやすいことが明らかになった．特に5件以上の炎上に関わるユーザー77名にたいして詳細な分析を行ったところ，それらのユーザー間ではフォロー/フォロワー関係が密に存在していた．また，高頻度炎上関与ユーザーは多くのフォロワー数を持つことが分かった．

以上の分析より，炎上においてネットワークで密に繋がった高頻度関与ユーザー群が同じ炎上トピックに対してツイートを行う情報の共振構造が観察された．この共振構造の中にいる各ユーザーはフォロワー数が多く，炎上の拡散に影響を及ぼしていると推測される．このように高頻度炎上関与ユーザー群における情報の共振構造が推測されるが，これらの特徴がネット炎上発生にどのように影響を与えているかについては，今後さらに詳細に研究を進めていく必要がある．

2. データセット

2018 年 12 月 19 日から 2019 年 1 月 22 日にかけて Twitter 社が提供する公式 API を用いて収集した，6 件の炎上データの内容，合計ツイート数，ツイートしたユーザー数を表1にまとめた．

収集データの内容とは，炎上の対象の属性と，炎上トピックの種類を指す．本研究で用いる収集データの内訳は，著名人，お

連絡先：小山耕平，東京大学，東京都文京区本郷 7-3-1，kkoyama@g.ecc.u-tokyo.ac.jp

*1 アカウント削除や鍵付きアカウントへの変更が行われると，Twitter API を用いた分析が不可になる．

よび, 法人の二対象, そして, 政治関連, 倫理観, ジェンダー関連の三トピックである.

合計ツイート数は, 炎上発生から1週間以内にツイートされた炎上関連キーワード含むツイート数の合計である. ツイートしたユーザー数は, 各炎上において炎上関連キーワードを含むツイートをしたユニークユーザー数の合計である.

表1:データセット

	内容 (対象/トピック)	合計 ツイート数	ツイートした ユーザー数
1	著名人 / 政治関連	391, 457	89, 414
2	著名人 / 倫理観	34, 797	19, 766
3	著名人 / 倫理観	33, 745	18, 142
4	著名人 / ジェンダー関連	6, 865	6, 426
5	法人 / ジェンダー関連	9, 546	6, 928
6	法人 / ジェンダー関連	18, 119	12, 567

3. 分析

3.1 炎上出現頻度の分析

各炎上それぞれに参加したユーザーが収集データセットの 6 件の炎上に何回出現したかの頻度を分析した結果を表2に示す.

なお, アカウント削除などの理由*1 で分析が不可となったユーザーおよびツイートデータは, 収集データセットから除外して分析を行った.

表2:炎上出現頻度の分布

炎上参加頻度	ユーザー数
6 回	6
5 回	73
4 回	451
3 回	2, 007
2 回	11, 760
1 回	121,283
合計	135,580

Twitter の月間アクティブユーザー数が約 4, 500 万, および, 6つの炎上に関与した総ユーザー数が 135, 580 であることから, 全月間アクティブユーザーの約 0. 3%が, 少なくとも 1 回以上これらの炎上に関連するツイートを行ったことになる. 一方で, 少なくとも 1 回以上これらの炎上に関するツイートを行ったユーザーのうち, 約 10%が 2 つ以上の炎上に出現している. また, 6 つの炎上のうち, 5 回以上参加した高頻度参加ユーザーは 79 ユーザーであり, 少なくとも 1 回以上炎上にしたユーザーに占める割合は, 約 0. 06%である.

これらの結果から, 炎上に関与するユーザーは全ユーザーのごく一部であるが, 一度でも炎上に参加するユーザーは, 全く炎上に参加しないユーザーに比べて, 複数の炎上に参加する傾向が強いことが判明した. また, その割合はごく僅かであるが, 高頻度炎上参加ユーザー群が存在することが判明した.

3.2 炎上関与ユーザー群フォロワー分析

収集データのユーザーを, 炎上関与回数ごとにグルーピングし, グループごとのフォロワー数の分布を図1に示す. 横軸は 0~999, 1000~1999, 2000~2999, 3000~3999, 4000~4999, 5000 以上の 5 つの域に分けたフォロワー数であり, 縦軸は各グループに含まれるユーザーの数に対する, 該当フォロワー数を持つユーザーの割合である. なお, 各グループのユーザー数は, 前述の表2にあるように, 5 回以上関与が 79 ユーザー, 4 回関与が 451 ユーザー, 3 回関与が 2007 ユーザー, 2 回関与が 11760 ユーザー, 1 回関与が 121,283 ユーザーである.

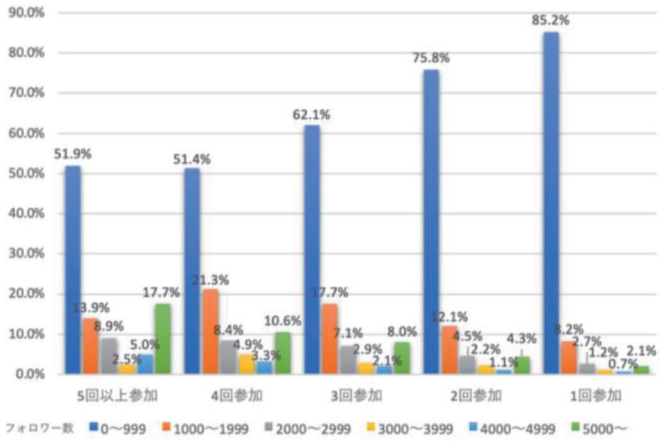


図1: 炎上関与回数グループごとのフォロワー数分布

フォロワー数が 5000 以上のユーザー割合が最も高いのは, 5 回以上関与する高頻度炎上関与ユーザー群であった. 全体の傾向として, 炎上関与回数が多いほど, 多くのフォロワー数を持つユーザー割合が高くなり, フォロワー数が 0~999 のユーザー数が占める割合は, 1 回のみ炎上に関与するユーザー群では 85. 2%である一方, 5 回以上関与する高頻度炎上関与ユーザー群では 51. 9%であった.

これらの結果から, 高頻度炎上関与ユーザー群は, 他のユーザー群に比べて多くのフォロワー数を保持している傾向があり, 高頻度炎上関与ユーザー群は Twitter 上での情報拡散において, 強い影響力を持っていることが判明した.

3.3 高頻度炎上関与ユーザー群ネットワーク分析

収集データの 6 つの炎上のうち, 5 つ以上の炎上に出現する 79 の高頻度炎上関与ユーザーに関して, フォローネットワークを構築したものが図 2 である.

高頻度で炎上に出現する79 ユーザーのうち, 51ユーザーが 1つのネットワークを構築していることが判明した. 平均ノード次数は 4. 67 であり, 最高次数ノードの次数は 15 であった. また平均パス長は 2. 85 であった.

図 2 におけるノードの大きさは次数の大きさを表し, 特に高次数であった 6 つのノードには, それぞれの Twitter プロフィール

から読み取れる特徴をラベル付けした. また, 有効エッジの矢印の向きはフォローの向きを表す.

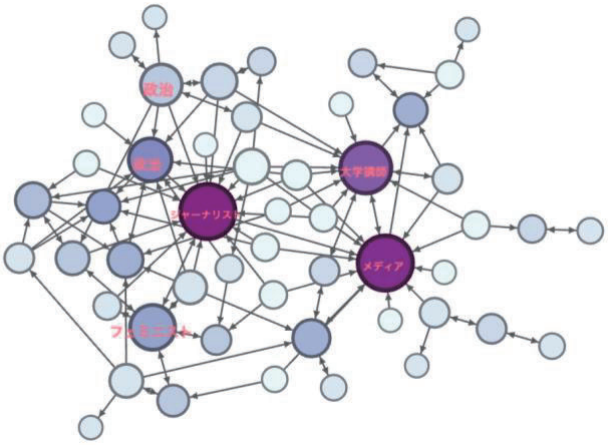


図 2:高頻度炎上関与ユーザー群ネットワーク

高頻度炎上関与ユーザー群の全 79 ユーザーのうち, 約 65%の 51 ユーザーが 1 つのネットワークを構築していることから, 高頻度炎上関与ユーザー群は1つのクラスターを形成していると考えることが出来, このネットワーク内で炎上に関するツイート情報が伝播しあっていると考えられる. また, ネットワークの平均ノード次数 4. 67 に対し, ノード次数 10 以上を超える 6 つのノードが存在することから, 高頻度炎上関与クラスターの中心的役割を果たしているユーザーが存在することが分かった. なお, 3. 2 で判明したように, 高頻度炎上関与ユーザー群は, 多くのフォロワー数を持つユーザーで構成されており, 高頻度炎上関与クラスター内の一部で取り上げられた炎上案件は, 速やかに同クラスター内で共有された後, クラスタ内各ユーザーのフォロワーを通じて, 広く Twitter 全般に拡散されていくという炎上発生メカニズムの存在が推測される.

4. 結論

本研究ではネット炎上に高頻度でかかわるユーザーの性質を分析するため, 6件の炎上データより高頻度炎上関与ユーザーを抽出した. 炎上においてフォロー/フォロワーネットワークで密に繋がった高頻度参加ユーザー群が, 同じトピックに対してツイートを行う共振構造が観察された. また, この共振構造の中にいる各ユーザーはフォロワー数が多い特徴があり, Twitter上における炎上の拡散に影響を及ぼしていると考えられる. このように高頻度炎上関与ユーザー群における情報の共振構造が推測されるが, これらの特徴がネット炎上発生にどのように影響を与えているのか, ネット炎上の分類やツイート情報の内容が共振構造にどのような影響を与えているのか, 共振構造がネット炎上拡散のどの段階で影響を及ぼしているのか等に関して, 今後さらに詳細に研究を進めていく必要がある.

参考文献

[情報処理推進機構 18] 情報処理推進機構: 2018年度情報セキュリティの倫理に対する意識調査報告書, (2018)

[総務 18] 総務省:平成29年度版情報通信白書, (2018)

[田中 16] 田中辰雄, 山口真一: ネット炎上の研究, 誰があおり, どう対処するのか, 勁草書房, (2016)

[山口 15] 山口真一: 実証分析による炎上の実態と炎上加担者属性の検証, 情報通信学会誌33巻2号, pp53-65, (2015)

[Allcott 17] Hunt Allcott and Matthew Gentzkow: Social Media and Fake News in the 2016 Election, Journal of Economic Perspectives Vol. 31, pp. 211-236, (2017)

[Andrews 03] Dorine Andrews, Blair Nonnecke, and Jennifer Preece: Electronic Survey Methodology: A Case Study in Reaching Hard-to-Involve Internet Users, International Journal of Human-Computer Interaction, Vol. 16, pp. 185-210, (2003)

[Kumar 18] Srijan Kumar, William L. Hamilton, Jure Leskovec, and Dan Jurafsky: Community Interaction and Conflict on the Web, WWW'18 Proceeding of the 2018 World Wide Web Conference, pp. 933-943, (2018)

[Lehmann 2012] Lehmann Janette, Bruno Gonçalves, José J. Ramasco, and Ciro Cattuto. "Dynamical classes of collective attention in twitter.", In *Proceedings of the 21st international conference on World Wide Web*, pp. 251-260. ACM, (2012)

[Wang 2015] Wang, Senzhang, Zhao Yan, Xia Hu, S. Yu Philip, and Zhoujun Li. "Burst Time Prediction in Cascades." In *AAAI*, pp. 325-331. (2015)

[Matsubara 2012] Matsubara, Yasuko, Yasushi Sakurai, B. Aditya Prakash, Lei Li, and Christos Faloutsos. " In *Proceedings of the 18th ACM SIGKDD international conference on Knowledge discovery and data mining*, pp. 6-14. ACM, (2012)

[Moor 2010] Peter J. Moor, Ard Heuvelman, and Ria Verleur: "Flaming on Youtube", Computers in Human Behavior, Vol. 26, pp. 1536-1546, (2010)

[Resnick 13] Paul Resnick, Sean A. Munson, R. Kelly Garrett. Natalie Jomini Stroud, Travls Kriplean: Bursting Your (Filter) Bubble: Strategies for Promoting Diverse Exposure, CSCW'13 Proceedings of the 2013 Confeence on Computer supported cooperative work companion, pp. 95-100, (2013)

[Pew 18] Elisa Sharer: Social media outpaces print newspapers in the U. S. as a news source, Pew Research Institute, (2018) http://www.pewresearch.org/fact-tank/2018/12/10/social-media-outpaces-print-newspapers-in-the-u-s-as-a-news-source/ (アクセス日: 2019年1月30日)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

サイト内の話題分布素性を用いた分類器学習による ノウハウサイト同定

Identifying Know-How Sites
by Classifier Learning with Features of Topic Distribution within a Site

大川 遥平 *1*2 Yohei Ohkawa　前田 竜治 *1 Tatsuya Maeda　陳 騰揚 *1 Tengyang Chen　宇津呂 武仁 *3 Takehito Utsuro　河田 容英 *4 Yasuhide Kawada

*1筑波大学大学院システム情報工学研究科 Grad. Sch. Sys. & Inf. Eng, Univ. of Tsukuba
*2(株)AVILEN AVILEN Inc.
*3筑波大学システム情報系 Fclty. Eng, Inf. & Sys, Univ. of Tsukuba
*4(株) ログワークス Logworks Co., Ltd.

This paper proposes techniques of automatically discovering tips Web sites from a large collection of Web pages using a topic model and support vector machine (SVM). Tips refer to practical knowledge or expertise that is used to help accomplish certain tasks in a particular field. We designed several approaches of extracting features with respect to domain names based on their distribution among Web pages and candidate tips Web sites. In addition, search engine suggests, the query keywords used to fetch Web pages from the search engine are also considered to present patterns that can be potential features.It was discovered from our dataset that domain names of tips Web sites (Web sites containing tips on a certain specific theme) are more likely dispersed among topics and Web pages. These domain names also tend to correspond to a larger number of search engine suggests. This paper verifies such observed patterns by training an SVM using those extracted features. Evaluation is performed in precision and recall to measure correctness of classifying whether or not a domain name belongs to a tips Web site.

1. はじめに

インターネットの発展により，日々，膨大な量のデータがウェブ上に増え続けている．自身の行動の助けとなるようなノウハウ・知識などの有用な情報がどこに掲載されているかを特定することが難しくなってきている．その背景には，近年，自社サイトのページ閲覧を目的としたウェブサイト，SEO (Search Engine Optimization) 対策を施し，ウェブ検索結果で注目されることを目的としたウェブサイトが増加傾向にあることが挙げられる．そのため，検索エンジンが果たすべき重要な責務として，有益な情報を掲載するページと，有益な情報は掲載しないが，SEO 対策の結果ウェブ検索上位に順位付けされるページをいかにして識別するか，という課題が挙げられる．例えば，(a) 花粉症，(b) 結婚，(c) 就活，(d) マンション，(e) 虫歯，(f) 食虫毒，の各クエリを Google 検索エンジンで検索した際の上位 50 件のウェブページのうち，ノウハウ知識を掲載するページの割合を図 1 に示す．どの検索クエリの検索結果においても，検索上位 50 件においては，ノウハウ知識掲載ページの割合は 50%かそれ以下となっている．これより，検索エンジンのユーザーは有益な情報が掲載されているウェブページを判別するのが困難なことが予想される．

この結果をふまえて，本論文では，ノウハウ知識を含むウェブサイトをドメイン単位で自動的に判定することを目的とし，その分類方法を提案する．提案する分類方法は，ウェブページの収集，トピックモデルを用いたウェブページのクラスタリング，各ドメインの特徴抽出，SVM のトレーニングからなり，それらの手法について記述する．また，評価実験の結果において，一定以上の再現率・適合率が達成できたことを示す．

連絡先: 大川 遥平，筑波大学大学院システム情報工学研究科，〒 305-8573 茨城県つくば市天王台 1-1-1，029-853-5427

2. 検索エンジン・サジェストを用いたウェブページの収集

本論文では，分析の対象であるクエリ・フォーカス「就活」,「花粉症」,「結婚」,「マンション」,「虫歯」，および,「食中毒」について，検索エンジン・サジェストを利用してウェブページを収集する．そのためにまず，Google 検索エンジンを用いて，一つのクエリ・フォーカスにおいて，約 100 通りの文字列を指定し，最大約 1,000 語の検索エンジン・サジェストを収集する．クエリ・フォーカス「花粉症」,「結婚」,「就活」,「マンション」,「虫歯」,「食中毒」において，収集されたサジェストの数を表 1 に示す．ここで，クエリ・フォーカスに対して収集されたサジェストの集合を $\mathbb{S}$ として，あるサジェスト $s \in \mathbb{S}$ に対して，クエリ・フォーカスとの AND 検索の検索結果上位 N 件以内に検索されるウェブページの集合を $S(q)$ とする．本論文では，$N = 20$ とした．このとき，各クエリ・フォーカスに対して収集されるウェブページの集合 $S(q)$ を次式で定義する．

$$S(q) \quad = \quad \left\{ s \in S \middle| q \in Q(s, N) \right\}$$

また，収集可能なサジェストとクエリフォーカスとの AND 検索により収集可能なウェブページを Q とする．

$$Q \quad = \quad \bigcup_{s \in S} Q(s, N)$$

3. ノウハウサイトの候補集合

3.1 トピックモデル

本論文では LDA(Latent Dirichlet Allocation) [Blei03] を用いる．LDA はトピックモデルのもっともメジャーなモデルのひとつである．トピック数 K を与えると，各トピック z_n における語の生成確率 $P(w \mid z_n)$ $(w \in V)$，および各トピック P_z

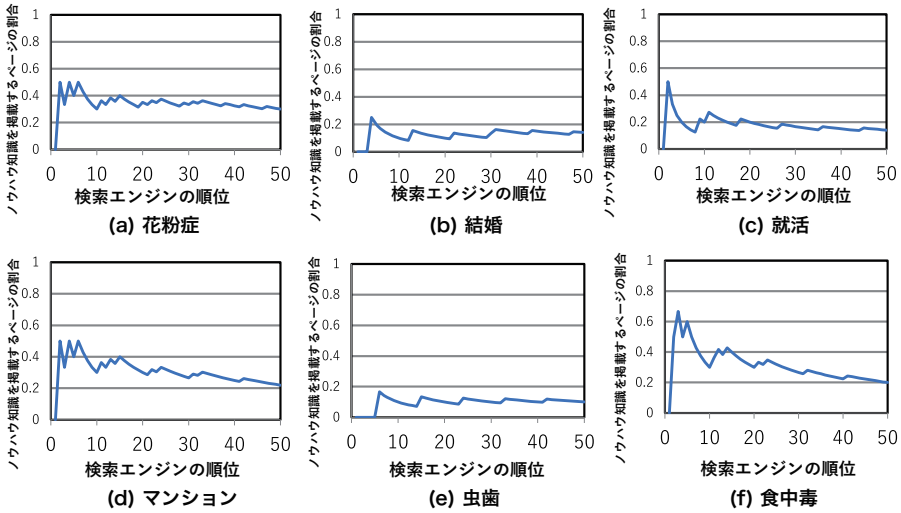


図 1: (a) 花粉症，(b) 結婚，(c) 就活，(d) マンション，(e) 虫歯，(f) 食中毒，の各クエリを Google 検索エンジンで検索した際の上位 50 件のウェブページのうち，ノウハウ知識を掲載するページの割合．

表 1: 各クエリのデータ概要

クエリ フォーカス	サジェスト 数	ウェブ ページ数	ノウハウサイト 候補の数 (正例/負例)
花粉症	849	9,738	101 (45/56)
結婚	959	13,256	85 (40/45)
就活	926	12,073	82 (51/31)
マンション	958	13,734	89 (57/32)
虫歯	835	9,554	92 (45/47)
食中毒	806	7,668	93 (28/65)
合計	5,333	66,023	542 (266/276)

表 2: ノウハウサイト候補のドメインに対する評価基準

<table>
<tr><td colspan="3">ドメインそのものがノウハウ知識を提示する個別ページへのリンクを一覧するページである</td><td>A 群</td></tr>
<tr><td rowspan="4">ドメインそのものがノウハウ知識を提示する個別ページへのリンクを一覧するページではない</td><td rowspan="2">ノウハウ知識を提示する個別ページへのリンクを一覧するページが存在する</td><td>ドメインのトップからノウハウ知識を提示する個別ページへのリンクを一覧するページに容易に辿り着ける</td><td>B 群</td></tr>
<tr><td>ドメインのトップからノウハウ知識を提示する個別ページへのリンクを一覧するページに容易には辿り着けない</td><td>C 群</td></tr>
<tr><td rowspan="2">ノウハウ知識を提示する個別ページへのリンクを一覧するページが存在しない</td><td>ノウハウ知識を提示する個別ページが存在する</td><td>D 群</td></tr>
<tr><td>ノウハウ知識を提示する個別ページが存在しない</td><td>E 群</td></tr>
</table>

における各文書 (本論文ではウェブページ q) におけるトピック Z_n の確率分布 $P(z_n|d)(n = 1, \ldots, K)$ を推定する．本論文は，全部の 6 つのクエリのウェブページ集合に対し，トピック数 K を 50 に設定し，実験を行った．

3.2 ウェブページ集合のトピックへの分類

各ウェブページ q におけるトピックの確率が最大となるトピックをそのウェブページ q のトピックとした．したがって，全てのウェブページにトピックを付与することができる．トピック z_n が付与されたウェブページの集合 Q は次式で定義される．

$$Q(z_n) = \left\{ q \in Q \,\middle|\, z_n = \underset{z_u\ (u=1,\ldots,\ K)}{\operatorname{argmax}} P(z_u|q) \right\}$$

3.3 ノウハウサイトの候補集合

各トピックにおける確率が低いウェブページは，そのトピックに関して詳しく記述されていない，一つのトピックにしか出現しないドメインのウェブサイトがノウハウサイトである可能性は低いという仮説をもとに，ノウハウサイトの候補集合とするサイトの基準を設けた．これらの仮説をもとに，トピックモデルを適用した結果において，各トピック上位 30 位のウェブページのみに出現するウェブページを対象とし，2 個以上のトピックにまたがって出現するドメインをノウハウサイトの候補集合とした．

4. データセット

ドメインごとにウェブサイトをアノテーションする際に，5 つのタイプのウェブサイトを観測した．その 5 つのタイプを A，B，C，D，E 群とし，その基準を表 2 に記述した．表 2 の基準に従い，A 群，B 群，C 群のサイトをノウハウサイトとし正例，D 群と E 群を負例としてデータセットを作成した．合計 542 のノウハウサイトの候補集合に対し，266 が正例で 276 が負例となった．6 つのクエリからそれぞれ 20 サイトを無作為に選択し，データセット作成者とは別に表 2 の基準に基づいてアノテーションを行った．その結果，正例/負例の分類における kappa 係数は 0.96 であった．

5. 素性

本節では，各ドメインに対して用いた素性について述べる．

5.1 ページ内の話題分布に関する素性

ウェブサイト内のウェブページの話題分布を測定する素性を利用する動機は，ノウハウサイトの候補のアノテーション作業を通じて，ノウハウサイトはノウハウサイトではないサイトと比べて，話題が一定の広がりを見せる傾向を発見したことに由来する．ウェブサイト内の話題分布を測定する手法については，本論文では次の 2 種類の素性を用いた．一つは LDA トピックモデルに基づくもの，もう一つは doc2vec モデルに基づくものである．これらの二つのアプローチはまったく異なる背景を持つ．LDA トピックモデルは大きな文書集合内のトピックをモデル化することを目的としたものだが，doc2vec は文書のベクトル表現を得ることを目的としている．本論文では，これらの二種類の素性の性能比較，および，それらを併用した場合の性能評価を行う．

5.1.1 LDA トピック数素性

トピックモデルを適用した結果においてウェブページ $q(\in P(t))$ に対して，トピックの確率分布が最大になるトピック $z(q)$ をウェブページ q に割り当てる．ここでドメイン t における各トピック $z(q)$ の集合を次式で定義する．

$$Z(t) \quad = \quad \bigcup_{q \in Q(t)} \{z(q)\}$$

そして，サイト t におけるトピックの異なり観測数を $f_z(t)$ で定義する．

$$f_z(t) \quad = \quad \big|Z(t)\big|$$

5.1.2 ウェブサイト内の doc2vec の距離の平均

doc2vec[*1] モデル [Le14] は word2vec モデルと同様の訓練方法を用いて文書をベクトル化するモデルである．単語のベクトルの学習に加えて文書 (本論文ではウェブページ q) のベクトルも同時に学習する．doc2vec モデルを訓練するうえで，クエリフォーカスに関して収集されたすべてのウェブページをトレーニングデータとして使用した．トレーニングに使用された各クエリフォーカス内のページ数は表 1 のウェブページ数にあたる．例えば，doc2vec が結婚というクエリに属する文書のベクトル $v(q)$ を学習するとき，13,256 の入力文書を利用した．本論文で使用した doc2vec の訓練パラメータは，過去の doc2vec に関する実験で利用されたもので，出力するベクトルの次元数は 300，ウィンドウサイズは 5 を用いた．低頻度語の影響を考慮せず，トレーニングテキスト内のすべての単語を訓練に利用した．doc2vec によって文書ベクトルを訓練した後，ドメイン t の $Q(t)$ 内の任意の 2 つのウェブページ q と q' のユークリッド距離 $\mathrm{Edist}(q, q')$ の平均を次式で求め，これをドメイン t の doc2vec 距離平均素性とする．

$$f_{doc2vec}(t) \quad = \quad \underset{q,\ q' \in Q(t)}{\mathrm{average}} \Big(\mathrm{Edist}(v(q),\, v(q'))\Big)$$

5.2 その他の素性

ドメイン内のページの話題分布を定量化する素性とは別に，以下 3 つの素性を定義した．

*1 https://radimrehurek.com/gensim/models/doc2vec.html

5.2.1 ウェブサイト内のページ数

ノウハウサイトにおいては，収集されたウェブページの数が多い傾向にある．このことをふまえて，ノウハウサイトの候補 t のウェブページ集合を $Q(t)$ として，ウェブサイト内のページ数素性を次式で定義する．

$$f_q(t) \quad = \quad \big|Q(t)\big|$$

5.2.2 検索ボリューム

検索エンジンサジェストとは，あるクエリが 1ヶ月間に検索エンジンにおける検索数を表す．検索数は Google AdSense[*2] を用いた．ノウハウサイトは，比較的検索量の多い特定のクエリキーワードを介してアクセスされることが予想される．まず，ドメイン t に割り当てられたサジェスト集合 $S(t)$ について考える．ドメイン t に対応するウェブページ q が検索されたサジェストの和集合として下式で表せる．

$$S(t) \quad = \quad \bigcup_{q \in Q(t)} S(q)$$

検索エンジンサジェスト s の，検索ボリュームを $sv(s)$ とすると，ドメイン t に対応する検索ボリュームの最大値 $fv\text{-}max(t)$ と平均値 $fv\text{-}ave(t)$ は以下のように定義できる．

$$fv\text{-}max(t) \quad = \quad \max_{s \in S(t)} sv(s)$$

$$fv\text{-}ave(t) \quad = \quad \frac{1}{\mid S(t) \mid} \sum_{s \in S(t)} sv(s)$$

5.2.3 URL 素性

ノウハウサイトの候補集合内のドメイン t の URL に関して，2 種類の素性を提案する．一つ目は，ドメイン t が “com”，“org”，“jp”，“net”，または “co.jp” を含むか否かを示す，URL の地域コードに関する素性 $f_{d1}, \ldots, f_{d5}$ である．二つ目は，ウェブサイトが暗号化通信を行えるか否か，すなわち URL の先頭が “https” あるいは “http” のいずれであるかを示す素性 f_h である．

6. 評価

6.1 評価手順

本論文の訓練用データは，542(表 1 内のウェブサイトの候補集合の数) のドメインすべてから構成される．doc2vec によるウェブページのユークリッド距離の平均の素性以外の素性は訓練前に平均が 0，分散が 1 となるように正規化した [*3]．本論文では，scikit-learn パッケージにおける SVM (sklearn.SVM.SVC ツール) を用いて評価実験を行った．グリッドサーチの結果より，カーネル関数とガンマパラメータを設定した．全 6 個のクエリ・フォーカスのうち，5 個分のクエリ・フォーカスのサイトで訓練をし，残りの 1 個のクエリ・フォーカスで評価をするという 6 分割交差検定を行い，その平均値を結果として出力した．また，判定結果の推定信頼度を出力し，信頼度に対して下限値を設け，高信頼度な判定結果に限定した範囲での適合率，再現率の評価を行った．参照用ノウハウサイト集合 (正例集合) を R，信頼度 $conf$ が下限値 c 以上でノウハウサイト (正例) と判定されたサイト集合を $S(conf \geq C)$ として，再現率 $(conf \geq C)$，および，適合率 $(conf \geq C)$ を下式で定義

*2 https://ads.google.com/home/tools/keyword-planner

*3 予備実験において，doc2vec によるウェブページの平均距離素性の素性は，正規化なしの方が正規化しない場合よりも高いパフォーマンスを観測した．

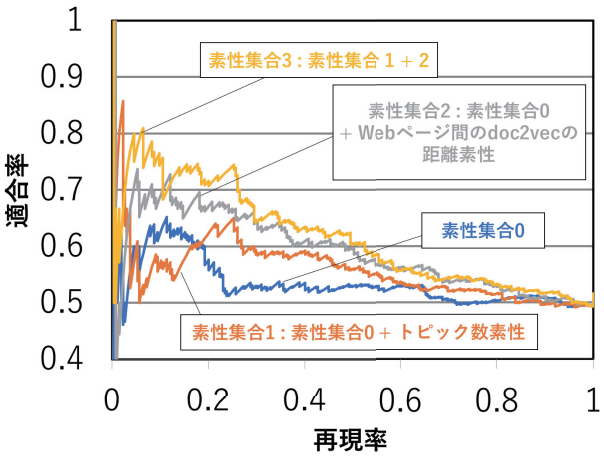


図 2: 評価結果 (素性集合 0:ウェブページ数素性 + 検索エンジンボリューム素性 + URL の素性集合，素性集合 1: 素性集合 1 + LDA のトピック数，素性集合 2:素性集合 0 + ページ内のウェブページの doc2vec ベクトルのユークリッド距離の平均，素性集合 3: 素性集合 1 と素性集合 2 の和集合)

した．

$$\text{再現率}\ (conf \geq c) = \frac{|R \cap S(conf \geq c)|}{|R|}$$

$$\text{適合率}\ (conf \geq c) = \frac{|R \cap S(conf \geq c)|}{|S(conf \geq c)|}$$

評価では，下記で定義する 4 つの素性集合ごとに，適合率と再現率をグラフにプロットすることにより評価を行った．また，これに加えて ROC 曲線を描き，AUC (ROC 曲線の下の面積) も測定した．

(i) 素性集合 0: ウェブページ数素性 + 検索エンジンボリューム素性 + URL の素性集合

(ii) 素性集合 1: 素性集合 1 + LDA のトピック数

(iii) 素性集合 2: 素性集合 0 + ページ内のウェブページの doc2vec ベクトルのユークリッド距離の平均

(iv) 素性集合 3: 素性集合 1 と素性集合 2 の和集合

6.2 評価結果

図 2 では，異なる 4 つの素性集合を用いて作成した分類器の評価を示した．信頼度のしきい値 c が，素性集合 (i) から (iv) についてそれぞれが 0 から 1 まで変化するため，各曲線は各素性集合の適合率/再現率のペアを表している．図 2 のグラフの形状と AUC による評価から，各素性が他の素性と比べて有効か否かについて述べる．doc2vec によるドメイン内のウェブページの文書ベクトルの平均距離素性は，LDA のトピック数素性よりもわずかに優れている．AUC による評価でも，素性集合 2 (doc2vec の距離素性を含む) は 0.58，素性集合 1 (LDA トピック素性を含む) とは 0.55 で，これは図 2 による評価と一致する．また，素性集合 0 の AUC は 0.54 で，素性集合 1 より低く，これも図 2 における比較と一致する．次に，図 2 において素性集合 1 および 2 の和集合を素性集合 1 および 2 と比較すると，和集合の方が素性集合 1 あるいは 2 よりもわずかに優れている．ただし，AUC に関しては，素性集合 1 および 2 の和集合は 0.58 で，素性集合 2 (doc2vec の距離素性を含む) と同程度であった．

7. 関連研究

関連研究として，[井上 16] では，検索エンジン，クエリ・フォーカスを用いて，サジェストおよびウェブページを収集，トピックモデルを用いることで話題を集約，ユーザの入力したクエリ・フォーカスに対し網羅的に話題とそのウェブページを示すためのインタフェースを作成した．[守谷 15] では，[井上 16] に対し，Yahoo 知恵袋などの質問回答サイトおよびウェブページから収集した文書集合を一つの文書集合とし，この混合文書集合に LDA トピックモデルを適用することで，より有用なノウハウ知識を得られることを示した．また，[李 17] では，収集したウェブページにトピックモデルを適用した結果に対し，複数のトピックにウェブページがまたがるドメインは，ノウハウサイトである可能生が高いと仮定し，いくつかのクエリ・フォーカスにおいて実際に評価を行い，候補サイトの半数以上がノウハウサイトであることを確認した．本研究は，[井上 16, 守谷 15] におけるトピックモデルの適用に加え，ページの話題の広がりを定量化する尺度として doc2vec を用いたという点で大きく異なっている．また，素性集合ごとに評価を行い，どの素性がノウハウサイトか否かを判定するのに重要かを検証した点においても大きく異なる．

8. おわりに

本論文では，ドメイン単位でそのウェブサイトがノウハウ知識を提示するページを有するか否かを判定する手法を提案した．分類に使用した SVM においては，ウェブサイト内のウェブページの話題分布に基づく素性，およびウェブページ数，検索エンジンの検索ボリューム数，URL に関するその他の素性を用いた．評価においては，LDA のトピック数素性と比べて，ウェブページ間の doc2vec ベクトルの平均距離素性が有効であることを示した．今後の課題として，大規模評価実験を通してこれらの知見の信頼性を検証することが挙げられる．

参考文献

[Blei03] Blei, D. M., Ng, A. Y. and Jordan, M. I.: Latent Dirichlet Allocation, *Journal of Machine Learning Research*, Vol. 3, pp. 993–1022 (2003).

[井上 16] 井上祐輔, 今田貴和, 陳磊, 徐凌寒, 宇津呂武仁, 河田容英：検索エンジン・サジェストおよびトピックモデルを用いたウェブ検索結果の集約, 第 8 回 DEIM フォーラム論文集 (2016).

[Le14] Le, Q. and Mikolov, T.: Distributed Representations of Sentences and Documents, *Proc. 31st ICML*, pp. 1188–1196 (2014).

[李 17] 李佳奇, 趙辰, 林友超, 馬場瑞穂, 宇津呂武仁, 河田容英, 神門典子：トピックモデルにおける話題分布特性を手がかりとするノウハウサイトの収集, 第 9 回 DEIM フォーラム論文集 (2017).

[守谷 15] 守谷一朗, 井上祐輔, 今田貴和, 聶添, 宇津呂武仁, 河田容英, 神門典子：質問回答事例および検索エンジン・サジェストを用いたノウハウ知識の相補的収集, 第 7 回 DEIM フォーラム論文集 (2015).

[2E3-J-12] Human interface, education aid: Shikake

Chair:Naohiro Matumura Reviewer:Yoko Nishihara

Wed. Jun 5, 2019 1:20 PM - 3:00 PM Room E (301A Medium meeting room)

[2E3-J-12-01] Development of 200 people game in big lecture hole in an university

○toyohisa nakada[1] （1. Niigata University of International and Information Studies）

1:20 PM - 1:40 PM

[2E3-J-12-02] Study on the Effect of a Questionnaire Appealing to Feeling Guilty on Umbrellas Theft Prevention

○Souta Matsui[1], Naohiro Matsumura[1] （1. Osaka University）

1:40 PM - 2:00 PM

[2E3-J-12-03] How face-to-face communication with photo similarities effects conversations

○Machiko Katori[1], Daisuke Uriu[1,2], Masahiko Inami[1,2], Atsushi Hiyama[1,2] （1. Graduate School of Information Science and Technology, the University of Tokyo, 2. Research Center for Advanced Science and Technology, the University of Tokyo）

2:00 PM - 2:20 PM

[2E3-J-12-04] Voice User Interface as a Method to Enhance Users' Activities on an LMS

○Toshihiro Kita[1], Chikako Nagaoka[1], Naoshi Hiraoka[1] （1. Research Center for Instructional Systems, Kumamoto University）

2:20 PM - 2:40 PM

[2E3-J-12-05] A Virtual City that Makes Children a Skilled Data Analyzer

○Takayuki Shiose[1], Ryosuke Kimura[2], Takashi Kondo[2], Makoto Matsuura[3], Tomoko Matsuura[3], Megumi Kotake[4], Mai Ogasawara[4] （1. Kyoto University, 2. Gocco., Inc., 3. NPO cobon, 4. Kodomo-Mirai Tankyusha, LLC.）

2:40 PM - 3:00 PM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

大学の大講義室での 200 人が同時参加するゲームの開発

Development of 200 people game in big lecture hole in an university

中田豊久[*1]
Toyohisa NAKADA

[*1]新潟国際情報大学
Niigata University of International and Information Studies

We propose games for all participaints of about 200 in the same place in order to direct participaint's awareness towards the organizer. In this research, we show examples of using this multiplayer game for classes in an university lecture hall. In the case of classes, the participants are students, and thinking that attendance rate, grades, etc. will be affected if the participation awareness in class increases. From the results of the experiments, although improvements were not seen in the attendance rate and the student evaluation, it was shown that there are certain improvement in test scores.

1. はじめに

イベント会場，大学の大教室などの多人数が集まる場所では，参加している人たちはすべての意識をそのイベントの内容に向けているわけではない．例えばコンサート会場で，スマートフォンによって別のことを調べていたりなどである．これらの状況は，イベントの主催者側からすると，イベント本来の内容に意識を向けて欲しいと思うであろう．そこにイベントを補助するゲームを開発し，イベントの内容に集中してもらうことを試みる．

ゲームの現実世界での応用は，ゲーミフィケーションやシリアスゲームなどと呼ばれている．本研究では，このゲーミフィケーションの観点で，イベント会場などで補助的に使用する多人数が同時プレイするゲームを開発するを目的とする．

2. 200 人ゲームの基本設計

200 人ゲームは，200 人が一堂に会する場所で行われる本来の目的からは離れた目的で使用される補助的なゲームである．よって，事前に参加者のスマートフォンにアプリをインストールしておくなどの利用方法は，考えにくい．また，すべての人が参加して欲しいため，参加者の 1 人 1 人がその他の約 200 人の人と対等にやり取りができることが望ましい．そして，参加を強制されず，また，一度参加してもいつでも離脱できることも望まれる．以下をまとめると次のようになる．

1. インストール，初期設定などの事前の準備を必要としないゲーム
2. プレイヤ 1 人が会場全体（200 人）に影響を与えられるようにすることによって，1 対 200 のインタラクションを実現する
3. プレイヤは参加を強制されず，いつでもゲームに入る，出ることができる

連絡先: 中田豊久, 新潟国際情報大学 経営情報学部, 新潟市西区みずき野 3-1-1, 025-239-3723, nakada@nuis.ac.jp

3. 授業中の課題進捗ゲーム

学生は紙で配布される問題に回答し，スマートフォンで答え合わせをする．スマートフォンの画面で学生はそれぞれの選択肢の回答番号を選びチェックボタンを押すと，正解，不正解が表示される．すると図 1 のように画面上部のアイコン，名前は，スクリーンに表示されるアイコン，名前となる．これを学生が変更すると，スクリーンのアイコン，名前が変更される．またスマートフォンを振ると，スクリーン上の自分のアイコンが大きくなる．



図 1: 授業中の課題進捗ゲーム：学生は自分のスマートフォンで答え合わせサイトに接続すると，課題進捗状況が教室のスクリーンに表示される．スクリーンでは，右の方に行くほど，課題が進んでいることを表す．

図 2 に授業中の課題進捗ゲームのシステム構成を示す．学生のスマートフォンは，特定の URL に接続され，ブラウザ上ですべての機能が実施可能となる．サーバをクラウドに用意し，そのサーバを用いて学生のスマートフォンと，スクリーンにつなげたパソコンとの接続を行う．

4. ガイダンスにおけるクイズゲーム

図 3 のように，まずスクリーンに，例えば「健康診断の日にちはいつですか？」といった学生生活に関する問題が表示される．その問題に，学生は手をあげて回答する．ここでスクリー

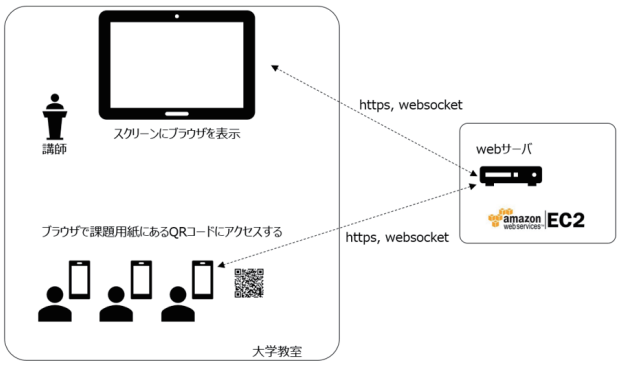


図 2: 授業中の課題進捗ゲームのシステム構成：AWS をサーバとして，学生のブラウザと講師 PC とを WebSocket で接続する．学生は，QR コードでサイトにアクセスする．

ンは，問題文から学生をカメラで映したものに変わる．そのスクリーンは，学生の手を挙げるという動きに反応し，その部分に色が付く．そして答え合わせの後で，スクリーンの正解者のところには桜が舞い，不正解者には炎が灯るなどのエフェクトが行われる．



図 3: ガイダンスにおけるクイズゲーム：スクリーンにクイズが出題される（左上），学生は，正解と思う選択肢で手を挙げる．その時にスクリーンの自分の場所の色が変わる（右上），不正解の人のところには，炎がともる（下）

図 4 にシステム構成を示す．この例の場合には，学生は身振り手振りだけでシステムとやり取りができるようになっている．より多くの人が会場にいても実施可能な構成となっている．

5. 200 人ゲームを成功させる要素

図 5 に授業中の課題進捗ゲームにおけるゲームの完遂率について示す．図の最も左側は，出席者数である．そして問題を解いてアイコンを前に進めた人数がそれぞれ示されている．アイコンが小さくて見えにくかった「screen」に対してスマートフォンを振ってアイコンを大きくする機能を付加した「scr. and shage」は，最初の参加が少ないものの，最後までゲームを完遂している数は多い．

図 6 には，スマートフォンを振ってスクリーン上のアイコンを大きくした回数の度数分布を示す．ここでいうアイコンを大きくする 1 回は，約 5 秒間スマートフォンを振っていたことを表す．一度もアイコンを大きくしなかった学生が 4 名居ることに対し，最大では約 150 回の操作 (延べ約 12 分間はスマートフォンを振っている) を行っている．



図 4: ガイダンスにおけるクイズゲームのシステム構成：Web カメラを装着した PC をスクリーンに投影する．学生は，手を挙げるのみで，デバイスは用いない．このシステムは，Unity を使用して作成されている．

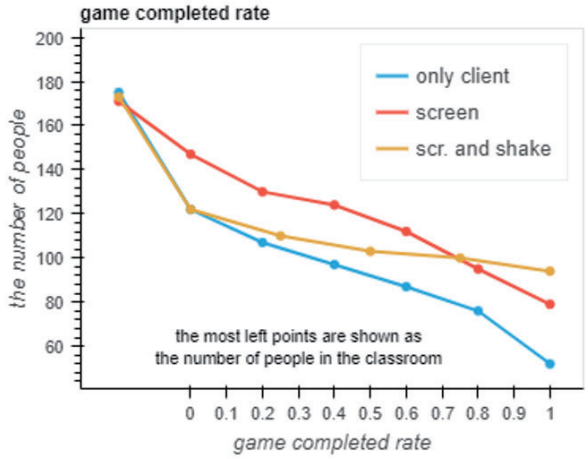


図 5: 授業中の課題進捗ゲームにおけるゲーム完遂率：答え合わせのみ (only client)，スマフォを振ってアイコンを大きくする機能のあり (scr. and shake)，なし (screen) の 3 パターンによるゲーム完遂率

図 7 に，アイコンを大きくする機能があるときと無いときのアイコンの種類と名前の変更回数を示す．両者とも増えていることから，アイコンを大きくして目立たせる機能は，ゲームのインタラクションを増加させるのに役立っていると言える．

以上より，大講義室の場合は，スクリーンに映る自分のアバターが自分自身で認識できるかどうかが大きくゲームを成功させる要素になっていると考えられる．

6. 200 人ゲームの効果

6.1 成績は向上するか?

図 8 に授業回数の最後に実施される最終テストのスコアを示している．図は，ほぼ同じ形態で授業を実施するようになった 2013 年からのものを示している．最終テストの成績は，その年によって大きな変化があり，ゲームを実施した 2017 年は点数が良いものの，これだけが良いという結果にはなっていない．一方，図 9 には，小テストの平均点から最終テストの点数にどれだけ減少したのかを示している．この授業は，約 80%の点数を 4 回の小テストで得るようにしている．普段の授業に

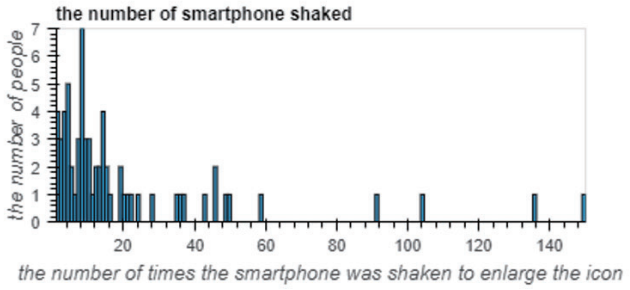


図 6: スマートフォンを振ってアイコンを大きくした回数の度数分布：1 回のアイコンを大きくする動作は，約 5 秒間の振るという動作を必要とする．

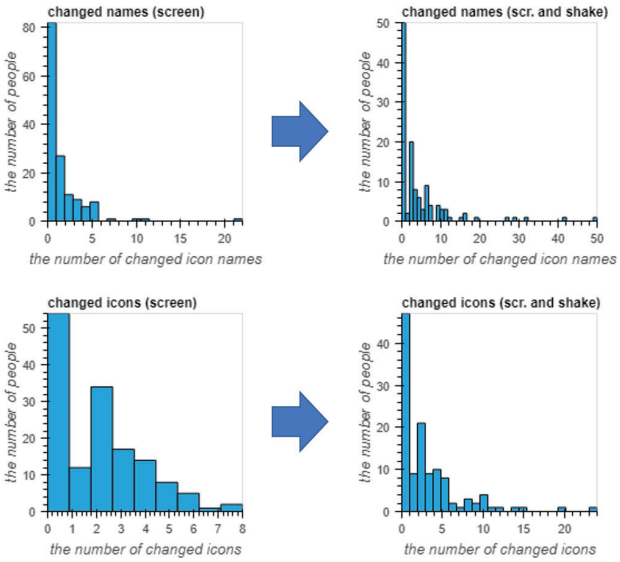
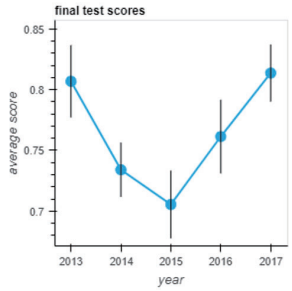


図 7: スマートフォンを振ってアイコンを大きくする機能があるときと無いときの，アイコンの名前，酒類を変更した回数の度数分布

おける課題が 10%，そして定期テストは 10%の割合しかない．よって学生は，最終テストの段階ではすでに 60%以上の得点を取得して単位取得が決定している学生がほとんどである．その中での最終テストは，点数が小テストよりも悪くなる傾向がある．その傾向を利用して，重要ではない最終テストでどれだけ点数が取れるかを，学生の知識の定着率として見ている．その定着率は，ゲームを実施した 2017 年は，他の年度よりも十分に良い結果となった．

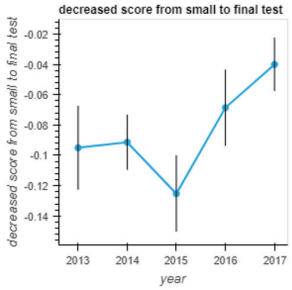
6.2 出席率は向上するか?

授業中にゲームが実施されれば,「次の授業でも何かあるかもしれない」という期待から，出席率の向上がまず見込まれると考えた．その結果としてのグラフを，図 10 に示す．欠席者の数を示している．この結果からは，ゲームを実施した 2017 年はゲームによって出席率が向上する，というデータを得ることはできなかった．この理由としては，ゲームを実施した 2017 年は，ゲーム実施の授業回の前から出席率が高く，ある意味では高止まりしていたのではないかと思われる．



年1	年2	t値	p値	
2017	2016	-2.748	0.006	**
2017	2015	-5.689	0.000	**
2017	2014	-4.750	0.000	**
2017	2013	-0.353	0.724	
2016	2015	-2.594	0.010	**
2016	2014	-1.439	0.151	
2016	2013	2.082	0.038	*
2015	2014	1.604	0.109	
2015	2013	4.436	0.000	**
2014	2013	3.634	0.000	**

図 8: 最終テストのスコアと統計分析：2017 年がゲームを実施した年度



年1	年2	t値	p値	
2017	2016	-1.900	0.058	
2017	2015	-5.258	0.000	**
2017	2014	-3.832	0.000	**
2017	2013	-3.519	0.001	**
2016	2015	-3.005	0.003	**
2016	2014	-1.451	0.148	
2016	2013	-1.399	0.163	
2015	2014	2.210	0.028	*
2015	2013	1.468	0.143	
2014	2013	-0.216	0.829	

図 9: 配点の大きい（重要度の高い）小テストから，配点の小さい（重要度の低い）最終テストまでの点数の減少率と，統計分析

6.3 授業評価アンケートの結果は向上するか?

図 11 に学生が授業を評価する授業評価アンケートの結果を示す．図の質問項目は，複数ある項目の中の最後に位置している「この授業を 5 点満点で評価してください」である．ゲームを実施した 2017 年は，他の年度よりも少し下がる傾向があるが有意差はない．

6.4 ゲームに夢中になりすぎて授業本来の目的を阻害しないか?

[Bretzke 2003] らは，ゲーミフィケーションよって強化された周辺活動によって，本来の目的を阻害する現象のことを「ゲーミング」と呼んで，そのリスクを警鐘している．例えば，バッチのような勲章を得るために，ゲームの進行を遅らせてもある特定のことをやり続けるようなものである．本研究で開発したゲームは，授業本来の目的と密接にリンクしているわけではない．外部報酬として機能しているだけである．よって，ゲームが面白すぎて授業本来の目的を離れて学生が遊びだす，という危険もないわけではない．

そこで本研究では，スクリーン上のアイコンを大きくするという最も魅力的な機能を「スマートフォンを振る」という身体的な動作と結びつけることとした．このゲームの以前に開発したスクリーン上のものを操作できる機能では，スマートフォン上のボタンを押す，という容易な操作でその機能を実現していた．するとそこにハマる学生は，授業中に講師の話を聞かずにずっとボタンを押し続けているということがあった．これらの経験から，身体的に負荷のかかる操作によって振りすぎると疲れるという制限を入れるようにしている．この実装方法により，ボタンよりはゲームに夢中になりすぎることを抑えられた

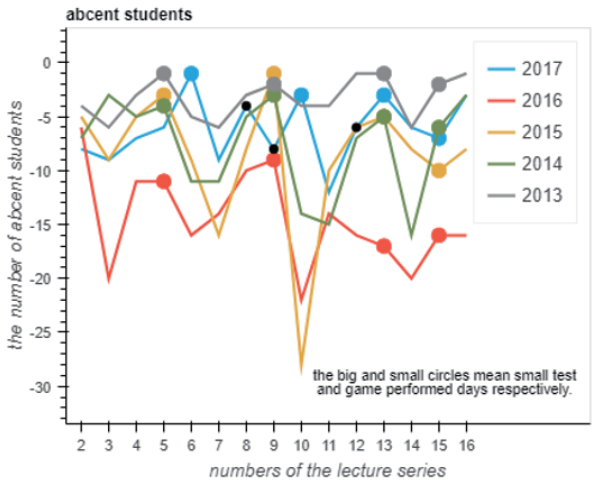
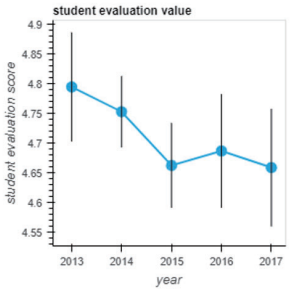


図 10: 授業の欠席者数：大きな丸は小テストを実施した日，小さい黒丸は 200 人ゲームを実施した日，ゲームは 2017 年のみ実施している



年1	年2	t値	p値	
2017	2016	0.399	0.690	
2017	2015	0.059	0.953	
2017	2014	1.701	0.090	
2017	2013	1.853	0.065	
2016	2015	-0.412	0.681	
2016	2014	1.213	0.226	
2016	2013	1.553	0.122	
2015	2014	1.929	0.054	
2015	2013	2.159	0.032	*
2014	2013	0.743	0.458	

図 11: 授業評価アンケートの総合評価項目（5 段階評価）の数値と統計分析

と感じているが，図 6 に示すように約 150 回という延べ約 12 分間はスマートフォンを振っているというのは，授業本来の目的を阻害してしまっていると見なければいけないと考える．

7. 動機づけに関する関連研究とその中での本研究の位置づけ

動機付けには，その作業自体に興味を持って参加するという内発的要因と，その作業を完遂すれば報酬が得られるといったような外発的要因があると言われている [Plotnik 2011]．また，[Abuhamdeh 2012] らは，好きではない作業については，その作業の実施困難さが少しでも上がると，作業の楽しさは減少することを報告している．これらから，授業中の課題の難易度を調節し，解けることによってやる気を出していく，という検討を重ねてきた [Nakada 2017]．本研究は，これらの内発的要因からは一歩離れ，あえて外発的要因に着目したものである．授業中のゲームは，授業中で取り扱う内容とは関係が無い．よって課題を解くことによる外部報酬と位置付けることができる．その外部報酬によってやる気を見いだせない学生への外的な刺激を与え，そして課題が解けるようになれば，内発的な動機に結び付けられると考えている．

8. おわりに

本研究では，参加者の意識を主催者側に向けるために利用するゲームについて提案し，大学でのガイダンスと授業での利用例を示し，授業においては知識の定着率について向上するという結果を得た．今後としては，さらに派手なエフェクトなどを実装し，より効果の高いゲームを実装することと，そもそもの授業内容から直接的にゲームになるものを提案していきたいと考える．

謝辞

本研究は，公益財団法人中山隼雄科学技術文化財団の平成 28 年度 研究助成 (A-1) の助成を受けたものです．

参考文献

[Bretzke 2003] Bretzke, Helen and Vassileva, Julita, Motivating cooperation on peer to peer networks, User Modeling 2003, Springer.

[Plotnik 2011] Plotnik, R., Kouyoumjian. H., Introduction to psychology. Belmont, CA: Wadsworth; 2011.

[Abuhamdeh 2012] Abuhamdeh S, Csikszentmihalyi M., The importance of challenge for the enjoyment of intrinsically motivated, goa-directed activities. Pers Soc Psychol Bull. 2012;38:317 - 330.

[Nakada 2017] T. Nakada, Gamified Lecture Courses Improve Student Evaluations but Not Exam Scores, Frontiers in ICT, Vol.4, doi=10.3389/fict.2017.00005.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

罪悪感に訴えかけるアンケートが傘の盗難防止に及ぼす効果の検討

Study on the Effect of a Questionnaire Appealing to Feeling Guilty on Umbrellas Theft Prevention

松井 壮太 *1　　松村 真宏 *2
Sota Matsui　　Naohiro Matsumura

*1大阪大学経済学部
School of Economics, Osaka University

*2大阪大学大学院経済学研究科
Graduate School of Economics, Osaka University

In this study, we consider an shikake, an embodied trigger for behavior change, to prevent umbrellas theft. We put a poster with a questionnare asking “Have you ever had a sad feeling from umbrella stolen?” on an umbrella stand to appeal to the feeling of guilty. People was able to vote for the questionnaire using build-in stickers. We conducted experiments at University campus for 111 days in total and revealed that the number of umbrella theft was reduced if the poster was set up. We concluded that a poster with a questionnaire seemed to be effective for umbrella theft prevention.

1. はじめに

日本社会において傘の盗難被害は多くの人が経験するものであり，ウェザーニューズが行った「傘調査 2017」でも回答者の 65 %が「傘を勝手に使われたことがある」と回答している [1]．その結果，傘は使い捨てのものであるという認識が広がることになり，一年間で約 1 億 2000 万本もの傘が日本で消費されている [2]．このことは環境保全，資源保護の観点からみても無視できない問題であろう．

しかし，その一方で傘の盗難に対する対策は他の盗難被害と比べるとあまり講じられていない．個人レベルの対策としては傘の柄部分などに工夫を施し，盗みづらくするものが挙げられる．それをまとめた研究 [3] では一定の盗難確率の減少が認められた．しかし，いずれの仕掛けにおいても盗難を無くすには至らず，また，場所によって効果に大きく差があり，ほぼ効果を見出せない場所も存在した．

このような背景を踏まえ本研究では，傘立て等の傘を置く場所に何らかの工夫をすることによって，傘の盗難を防ぐ方法について検討する．

2. 盗難と心理

2.1 犯罪が起きる環境

犯罪がなぜ生ずるか，なぜ人は犯罪者になるのかという観点から犯罪を研究する犯罪原因論では，犯罪者の個人的な特性に注目する方法と社会や環境の特性に注目する方法でその原因が語られる．特に近年は後者についての研究が進められている．

代表的なものは 1982 年に Wilson & Kelling の提唱した割れ窓理論（broken-windows theory）である．落書きなどの軽微な犯罪をそのままにしておくと重大な犯罪率が上がるというものであり，この理論をもとにニューヨーク市で行われた地下鉄などの空間においての取り組みでは犯罪率の減少，及び治安の回復に劇的な効果が見られた [4]．

これ以降，世界的に治安の向上を目指す取り組みとしてこの理論が取り入れら，日本でも知られるようになった．割れ窓理論を日本に紹介した小宮信夫をはじめとする犯罪社会学者が都市，地域の防犯対策を論じ実践してきた結果，日本においても犯罪発生率は減少したと言われている．

このように，犯罪が起きることと環境には大きな関わりがあることが分かる．

2.2 盗難を防ぐ環境を目指した取り組み

では，犯罪の中で盗難についてはどうだろうか．特に軽微な盗難問題に対する取り組みとしては上記の割れ窓理論のみでは不十分であり，さらに細かなアプローチが求められる．

簡便なアプローチとして看板等での掲示がある．今井，大内らの取り組みは，松本市での自転車盗難に対して注意喚起や啓発の看板を設置したものであるが，このような直接的なものも盗難発生率の減少に役立つことが示された [5]．また，Nettle らは“Cycle Thieves, We Are Watching You”（自転車盗難，我々は見ているぞ）という被視感を与える掲示を行い大きな成果を得た [6]．このような盗難を行おうとしている人に対して，そのことの重大さを惹起させ，同時に周りに監視されているような気持ちにさせるアプローチには一定の効果が見られる．これらを非言語的なメッセージとして込めた防犯カメラやセンサーライトなどの装置に関しても同様の効果が期待できることが報告されている [8]．

また，いずれの研究にも共通して，新たな掲示を行うこと，実験を行っている（ことが分かる）こと，マスコミ等に取り上げられることによって，行った取り組みによる効果以上の注目が集められることによってさらに盗難防止につながっていることが言及されており，その後の効果の逓減についての追加実験の必要性が論じられている．

2.3 傘の盗難について

ここで，日本人の傘，特にビニール傘に対する意識についても論じる．前述したように日本は相当数の傘を消費しているが，その 8〜9 割はビニール傘であるといわれている．消費者がビニール傘を多用する理由としては，突然の降雨の際に購入して使い捨てできることや，盗難，紛失があったとしてもそれほどショックでないということが挙げられる．このことからも，日本人がビニール傘の盗難についてそれほど重大な犯罪でないと考えていることが分かる．よって傘の盗難を防止する対策を講じるときには，この意識に対するアプローチが求められる．

連絡先: 松村真宏，大阪大学大学院経済学研究科，〒 560-0043
豊中市待兼山町 1-7，matumura@econ.osaka-u.ac.jp

2.4 盗難防止と仕掛け

具体的に対策を考えるにあたって，仕掛学 [9] の考え方を利用する．仕掛学とは「無理やり行動を変えさせようとするのではなく，つい行動を変えたくなるように仕向ける」ような「仕掛け」を利用した考え方である．例えば男性用小便器にハエの的をつけ，利用者に狙わせることによって飛び散りを防ぐ，などのようなアプローチがある．以下の 3 要件（FAD 要件）を全て満たすものが「仕掛け」と定義されている．

- **公平性 (Fairness)**：誰も不利益を被らないこと．仕掛けられる側が仕掛ける側の目的に気づいたとき不快に感じるものや，人を欺く目的のものは仕掛けの定義から外れる．
- **誘引性 (Attractiveness)**：行動が誘われること．強要することなく行動変容を「誘う」性質であり，見向きされない場合は誘引性が足りない．
- **目的の二重性 (Duality of purpose)**：仕掛ける側と仕掛けられる側の目的が異なること．仕掛けられる側が行動を変えたことで，その意図にかかわらず仕掛ける側の目的が達成される．

また，リチャード・セイラーとキャス・サンスティーンが提唱したナッジとの比較研究 [10] では，仕掛けについて，オルタナティブな行動をとることへの興味やポジティブな期待を喚起するものと，無意識に選んでいたデフォルトの行動をとることへの不安やネガティブな期待を喚起することで相対的にオルタナティブの行動を魅力的にみせるものの 2 つに分類している．

本研究では後者の考え方を利用する．つまり，仕掛けによって，傘を盗むという行動に不安感やネガティブな期待を惹起させ，他の行動（すなわち「盗まない」という行動）をとらせるということである．

この考え方を利用した研究に，ポイ捨てが多い場所に鳥居や花を設置し，その件数の減少を目指すものがある．条件による差異はあったものの効果が見られたことが報告されている [11]．ポイ捨ては傘の盗難と同じく罪悪感の薄い軽微な犯罪（迷惑行為）であり，傘の盗難についても仕掛けに効果があることが期待される．

3. 傘の盗難防止に対する仕掛け

3.1 仕掛けのアイデア

不安感やネガティブな期待を喚起させる仕掛けのアイデアとしては次のようなものが考えられる．それぞれ FAD 要件に照らし合わせて考察する．なお，誘引性は実際に実験してみないとわからないものなので，ここでは類似事例にならって期待される効果について述べる．

(1)（存在しない）監視システムや体制の存在を知らせる掲示

これには「○○巡回中」,「防犯システム作動中」,「盗難防止センサーがあります」といった掲示が当てはまる．ウソではあるがやましいことが無い限りは影響がなく公平性はあるといえる．被視感に加え，盗難をしたときに何かが起きるのではないかという不安感があるので，誘引性が期待される．一方，利用者側に仕掛ける側の狙いが自明なので，目的の二重性はない．

(2) センサーライトや防犯カメラの設置

監視されているように感じる人はいるかもしれないが，現代の日本社会ではこれらはほとんどの場所に存在し，公平性が欠けるとまではいえない．被視感がうまれることによって誘引性がうまれることが期待される．仕掛ける側の目的は盗難を防ぎたい，利用者側の目的は空間が明るく照らされたり安全性が保障される，となるので目的の二重性がある．

(3) 罪悪感に訴えかけるアンケートの設置

これは「傘を盗られてつらい思いをしたことがありますか」といった掲示のことである．負の要素が無く公平性はあるといえる．アンケートから，傘を盗むことで被害を受ける人がいることが想起され罪悪感が生まれることに加えて，アンケートを実施していることで，観察者がいるのではと不安になり誘引性が生まれることが期待される．利用者側はなんとなくアンケートに関心を持ち，仕掛ける側はそのことによって盗難を防ぎたいという目的があるため，目的の二重性があるといえる．

(1)(2)(3) をそれぞれ比較すると，まず (1) に関しては二重目的性を満たしておらず仕掛けとして不適である．また，(2) は有効な方法といえなくはないが，傘の盗難のみに対する仕掛けとしては大掛かりすぎてコスト面に問題がある．また，設置場所の状況によっては視認性が悪く誘引性の面でも問題が生じる．(3) はどのような状況でも設置が可能であり，ポスターやシールなどを用意するだけなのでコスト面においてもメリットが大きい．また，(1) や (2) が単に盗む側のデメリットを想起させる仕掛けであるのに対して，(3) は盗まれる側の罪悪感を思わせる仕掛けになっている．

以上より，本研究では (3) の罪悪感に訴えかけるアンケートによる傘盗難防止の効果について検証する．

3.2 本研究において検証する仮説

本研究で実験を行う仕掛けに関して，期待される効果とそこに至るまでの心理のプロセスについて整理する．この仕掛けにおいて期待される効果は被視感，罪悪感の 2 つが傘が盗難される確率を下げることである．

被視感に関しては，ここまでに紹介した盗難やポイ捨てなどに対する取り組みと同様である．普通とは違う，特殊なもの，人為的なものがあることによって人は被視感を感じ，そのことによって，もし傘を盗めば誰かに見られる，あるいは咎められるのではないかという心理が働き，盗難しづらくなることが期待される．

一方，心理学において罪悪感は，自らの過失が他者に及ぼした害悪を修復するような行動にかりたてる機能，あるいはその過失を他者に告白するような行動に駆り立てる機能をもつものとされる [12]．この感情は，自分の行動によって他者が傷つくことを認知したときに表出する．つまり，今回の研究では，傘を盗難する際に被害に遭う他者をアンケートによって認知させることによって罪悪感をかき立て，それによって盗難を思いとどまらせる（自らの過失が他者に及ぼした害悪を修復する）といった効果を狙う．

本実験ではこのふたつの感情に対するアプローチであり,「罪悪感に訴えかけるアンケートを目につくところに設置すると，傘盗難防止に効果がある」という仮説を検証する．

4. 実験

4.1 実験場所

大阪大学豊中キャンパスの共通教育棟（主に 1 年生の教養科目の講義が行われる建物）の教室前の傘立てを使用した．選んだ理由としては，人通りが多い一方で人の目が向かない時間も多くあり，盗難が起きやすい条件の場所であったからである．なお後述する追加実験では，大学の許可の関係で同キャンパスの法経講義棟（法学部，及び経済学部の専門科目の講義が行われる建物）を選んだ．こちらも人通りは前者よりやや少ないが同じような条件下にある場所である．



図 1: 実験の様子

表 1: 実験結果

実験条件	観察日数	盗難本数
仕掛けあり	20 日間（雨 7 日，時々雨 4 日）	1
仕掛け無し	20 日間（雨 7 日，時々雨 4 日）	1
仕掛け無し	18 日間（雨 7 日，時々雨 4 日）	2
仕掛け無し	6 日間（雨 1 日，時々雨 1 日）	2

5. 実験方法

2018 年 6 月 11 日（月）から 2018 年 7 月 6 日（金）までの平日に，前述した共通棟の傘立てのうち 4 か所（それぞれ大きく離れている）にビニール傘を 2 本ずつ入れておき，盗まれるまでの日数を計測した．3 か所には何の仕掛けもせず 1 か所にだけアンケートを設置した．

アンケートはポスター形式で傘立ての前面に貼り付け，さらにその横に張り付けたシールを「yes」「no」の部分に張り付けて投票する形を採用した（図 1）．また，アンケートが目的ではなく，アンケートに票が入っている状態が好ましいので設置の際にすでにある程度投票を行う細工を行った．

日数の計測については，傘を盗む必要のない降雨量 0 の日を除き，降雨があった日に関しては，一日中降っていた（雨）か，止んでいる時間があった（時々雨）かで区別した．一日中雨の日は，自宅から自分の傘を持ってくるので盗難確率が低いと思われるからである．また，ほぼ人通りがなくなる，週末に関しては観察を行っていない．

5.1 実験結果

実験結果を表 1 に示す．盗難本数の差が大きくないのではっきりとはいえないものの，概ね仕掛け無しに比べ仕掛けありの方が盗まれる数は少ないという結果となった．また，仕掛けありの中で盗まれたのは実験の 4 週目であり，後述する継続による仕掛けの効果の減退にも関わる可能性があった．予想した通り盗まれやすい日は時々雨の日であった．盗難にあった傘のうち 1 本のみ雨の日であったが，残りは全て時々雨の日であった．また，アンケートには少数であるが回答があり，「yes」7 票，「no」2 票であった．

表 2: 追加実験の結果

実験条件	観察日数	盗難本数
期間 1（仕掛け無し）	4 日間（雨 0 日，時々雨 1 日）	2
期間 2（仕掛けあり）	28 日間（雨 5 日，時々雨 4 日）	3
期間 3（仕掛け無し）	15 日間（雨 2 日，時々雨 2 日）	2

表 3: 実験結果のまとめ

実験条件	観察日数	盗難本数
仕掛け無し	63 日間（雨 17 日，時々雨 12 日）	9
仕掛けあり	48 日間（雨 12 日，時々雨 8 日）	4

しかしながら，データ数が少なく結果に疑問が残ることから追加実験を行った．

5.2 追加実験

先の実験との違いは 2 点である．1 点目は実験場所であり，追加実験で使用した法経講義棟は実験に適した場所が 1 か所しかなかったので，仕掛けがある期間，無い期間を設定して比較した．2 点目は傘の設置方法であり，先の実験では最初に 2 本を設置しその後は追加しなかったが，追加実験では盗まれた場合は翌日に補充し，なるべく 2 本の傘がある状態を維持した．これは追加実験が 1 か所でしか行えなかったため，より多くのデータを取得するためである．それ以外は基本的に先の実験と同様に行った．なお，期間 1 は 2018 年 10 月 9 日（火）から 10 月 12 日（金），期間 2 は 2018 年 10 月 15 日（月）から 11 月 30 日（金），期間 3 は 2018 年 12 月 3 日（月）から 12 月 21 日（金）である．

5.3 追加実験の実験結果

実験結果を表 2 に示す．期間 1 については，実験場所において傘の盗難がどれくらい行われるかを確かめるために行った予備実験であったが，夕方ごろに小雨が降った日に 2 本が盗まれた．このことから，傘の盗難確率は高く実験に適した場所であると判断し，仕掛けを設置し観察した．

期間 2 のうち盗難があったのは 2 日である．1 日目は 2 週目の雨の日である．夕方ごろに確認したところ，設置した傘がなくなっており，代わりに前日までなかった別のビニール傘があった．ほぼ一日中雨が降っていたことから，間違えて取られた可能性が高いと判断した．2 日目は 7 週目の時々雨の日である．この日は天気予報では降水確率はそれほど高くなかったが，多くの学生が帰宅する 16 時前後に強いにわか雨が降り，15 分ほどで 2 本とも盗難にあった．前日に確認した際には存在した置き傘，または忘れ物と思われる傘 4 本に関しても翌朝に確認したところなくなっていた．

期間 3 では 1 週目と 2 週目のどちらも時々雨の日に 1 本ずつ盗難があった．また，2 週目の盗難があった日は，もう一本も傘立てからなくなっていた時間があったが後に確認したところ戻ってきていたので，これは盗難本数に含めていない．アンケートの結果は「yes」「no」ともに 5 票であった．

6. 考察

6.1 仕掛けの効果

2 つの実験結果をまとめた結果を表 3 に示す．これを見ると，仕掛けありのほうが盗難本数は減っており，効果があったといえる．また，追加実験の期間 2 において一気に盗難があった時間帯に傘立て付近で観察を行っていたところ，アンケートを

見て手を止めた人が複数いた．また，集団で近づいた数名が，「なんとなく躊躇してしまうなあ」と発言していた．これらを踏まえて考察すると，仮説のとおり，アンケートによって傘を盗もうとした人が罪悪感，あるいは被視感をもち盗難に至らなかった可能性は高いと思われる．特に，観察中に手を止めた人に関していえば，周りを気にするような動作はしなかったことから被視感というよりは罪悪感によって盗難をやめたのではないかと考えられる．このことからも単純に被視感を生み出すようなものに比べて，本研究で提案したアンケートがより効果があったと考えられる．

6.2 問題点

しかしながら，実験の結果を見ると決して盗難は 0 になっておらず，にわか雨の際には多くの傘が盗まれた．この原因についても考察する．

ひとつは，仕掛けはあくまで，不安感やネガティブな期待を惹起させ，他の行動を「比較的」魅力的にするものでしかないことである．ゆえに，傘を盗まずに雨の中に出るという選択肢が考えられないほど，雨が降っている場合には仕掛けの効果は薄いと考えられる．

もうひとつは継続による仕掛けの効果の減退である．提唱者の松村もそのことには言及しており，仕掛けを考えるうえでおおきな課題となる．本研究においても，仕掛けありのうえで盗難があったのは実験期間の後半に集中しており，この問題が露呈したと考えられる．

7. まとめ

本研究よりアンケートによる罪悪感に訴えた掲示が盗難被害に対して一定の効果があることが明らかになった．6.2 節であげた問題点はあるものの導入コストを考えれば様々な場所において設置をしても有益であると考えられる．

今後の展望としては，その他の仕掛けと比べたときにどれくらいの効果があるのかを調べ，被視感だけの場合と罪悪感にも訴えた場合を比較検討したい．また今回は大学内でのみ実験を行っていることから，別の場所に設置し，別の属性の対象者に対しても同様の効果があるかについても検討したい．

参考文献

[1] 株式会社ウェザーニューズ「傘調査 2017」 https://jp.weathernews.com/news/16769/ （2018 年 12 月 26 日閲覧）

[2] 日本洋傘振興協会「洋傘の国内年間消費量は？」 http://www.jupa.gr.jp/pages/faq （2018 年 12 月 26 日閲覧）

[3] 山根 承子，山本 哲也：ビニール傘を盗難から守る仕掛け，第 29 回人工知能学会全国大会論文集 1D4-OS-22a-3 (2015).

[4] Harcourt, Bernard E.: Reflecting on the subject: A critique of the social influence conception of deterrence, the broken-windows theory, and order maintenance policing New York style, Michigan Law Review 97, pp. 291–389 (1998).

[5] 今井 章，大内 剛：地域の防犯における標識看板制作の試み―自転車盗難の防止策として―，地域ブランド研究 (11), pp. 1–13 (2016).

[6] Daniel Nettle , Kenneth Nott, Melissa Bateson: ‘Cycle Thieves, We Are Watching You ’: Impact of a Simple Signage Intervention against Bicycle Theft，PLoS ONE 7(12): e51738 (2012).

[7] 佐藤 哲彦：テーマ別研究動向 (犯罪)「逸脱の社会学」死後における犯罪の研究社会学評論，社会学評論 63(2), pp. 290–301 (2012).

[8] 樋野 公宏：駐車場に設置する防犯カメラ等の効果及び利用者等の態度　愛知県内での実験から，都市計画論文集 43(3), pp. 763–768 (2008).

[9] 松村 真宏：仕掛学，東洋経済新報社 (2016).

[10] 板谷 祥奈, 竹内 穂波，松村 真宏：「ひじでつく」 ナッジ,「そそる」 仕掛け，第 3 回仕掛学研究会 TBC2018007 (2018).

[11] 村井 翔，松村 真宏：規範と監視を訴求したポイ捨て抑止実験，第 3 回仕掛学研究会 TBC2018006 (2018).

[12] 久崎 孝浩：恥および罪悪感とは何か：その定義，機能，発達とは，九州大学心理学研究 3，pp. 69–76 (2002).

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

類似写真の閲覧がもたらす話題生成と対面コミュニケーション

How face-to-face communication with photo similarities effects conversations

香取真知子 *1 Machiko Katori　瓜生大輔 *1*2 Daisuke Uriu　稲見昌彦 *1*2 Masahiko Inami　檜山 敦 *1*2 Atsushi Hiyama

*1東京大学大学院情報理工学系研究科
Graduate School of Information Science and Technology, the University of Tokyo

*2東京大学先端科学技術研究センター
Research Center for Advanced Science and Technology, the University of Tokyo

This paper introduces a face-to-face communication platform using images. Our iPhone application, used by plural users simultaneously, will display a set of images with an algorithm calculating image similarities. The app accesses each user's picture library linked with Google Photos, sorts in the relevance with the algorithm, and selects which to display. This paper illustrates the app design and the validation study of the user communication. The study recruited participants divided into two groups: one that are close friends, and another are complete strangers. We intended the former group to catch up and find some new topics to talk about, while the latter group to find some things in common that might trigger communication. This pilot study reveals how the current system effects the conversations, states how this platform could articulate face-to-face communications, and finally discusses how this platform could be improved in the future.

1. はじめに

SNS 上での写真・イメージを用いたコミュニケーションが広く普及する今日 [Malik 16], SNS の利用は他者との人間関係の維持にも重要な役割を果たしている ([Chen 11] など). このような写真を介したオンラインでのコミュニケーションの需要に対し, 本研究では, オフラインでの, すなわち直接会った際に特化した写真閲覧経験に着目する. SNS 上での投稿は, フォロワーを含めた不特定多数に対しての発信なのに対し, オフラインでの会話は, その場にいる相手やグループの趣味・嗜好に特化・依存する. このような使用者の特性に基づいて, 本研究では共通性・類似性のある写真の提示方法を検討した. 類似する写真の閲覧を通し, 初対面同士では互いの興味・関心の共通点の発見を, また元々親しい者同士では円滑な近況報告を, 結果として様々な話題を誘発できるのではないかと考えた.

本研究において開発中の iPhone アプリケーション (以下, アプリとする) は図 1 のように, 複数の iPhone を並べた状態で使用する. 個々の使用者 (本図の場合は 3 人) が所有する Google Photos 上に格納された写真から, 本研究で開発中の写真提示アルゴリズムにより, 類似度の高い写真の組から順番に 20 組表示できる. また使用者が画面をスワイプすることで次の写真の組に切り替わる. 本論文では, 2018 年 10 月から 2019 年 1 月にかけて開発したアプリとアルゴリズムを用いた写真閲覧システムを準備し, 試用と検証を行なった結果と考察を報告する.

2. 関連研究

本研究は, 個人が所有している写真を利用した記憶の共有や回想を支援する研究領域 ([Uriu 09], [Nguyen 16] など) に対し, 複数の使用者が所有する類似した写真の同時閲覧に関する知見を提供する. 本アプリでは視点や構図が固定された一人称視点からのライフログ写真 [Wang 13] ではなく, よりバリエーション豊かなイメージの提供を目指し, 能動的に撮影された写真によって得られる体験に注目した. その際, 画像検索分野で注目されている semantic gap [Liu 07] を補完する物体認証のモデルを活用して, 雑多で大量な写真リストから共通性のある組み合わせを導く. 現在, SNS 上の投稿文章や画像を分析することでユーザの興味や趣味嗜好を特定する研究がある ([Kosinski 13] など) が, 本研究では実際に対面した際に共通の興味や趣味嗜好を発見できるイメージの提供に注目した.

連絡先: 香取真知子, 東京大学稲見・檜山研究室, contact@star.rcast.u-tokyo.ac.jp

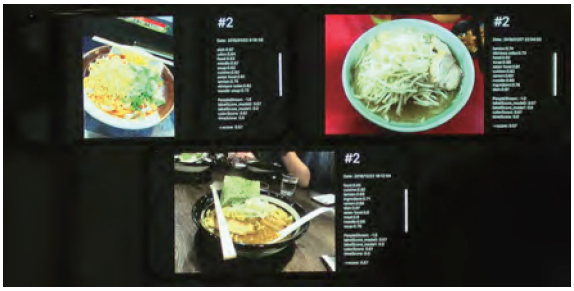


図 1: 実際の表示例. 体験者 3 名が麺類を食べた際の写真.

3. アプリ設計

3.1 アプリの構成・基本操作

アプリは 2 人以上の体験者が対面した状態で動作する. その際, 類似・共通する写真の組を 20 組, 類似度の高い順に鑑賞できる. 写真には#1 から#20 までの番号が振られており, iPhone の画面を上下にスワイプすることで, 前後の組の写真に遷移する. 1 台の iPhone をスワイプすると Peer to Peer 通信により信号が送られ, 他の iPhone の写真も遷移する. これにより, 常に同じ番号, すなわち正しい組の写真同士が同時に表示される.

3.2 Google API の利用

本研究では, Google が提供する Photos Library API および Cloud Vision API を利用している. Photos Library API は, Google

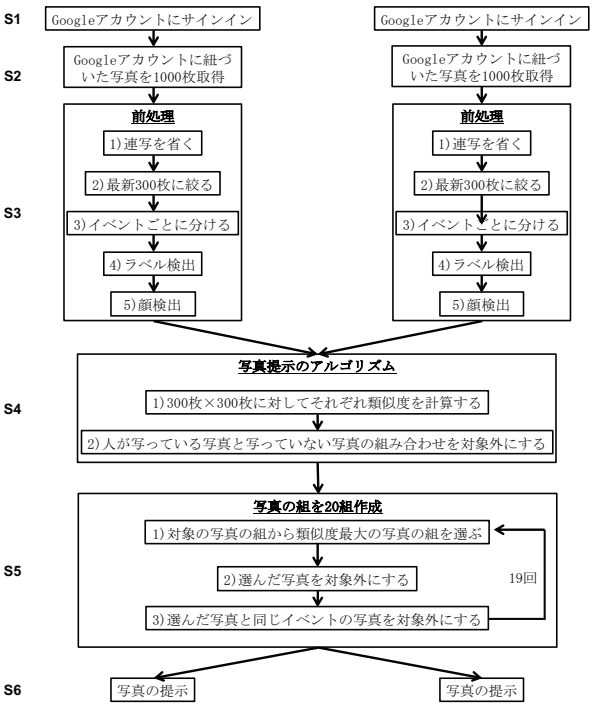


図 2: アプリの処理フロー

Photos の中の写真, 動画および紐付けられたメタデータを取得・活用するための API である. Cloud Vision API は, 事前にトレーニングされた機械学習モデルを活用し, 画像の物体認証を行うことができる. これらを利用することで, 本研究プロセスで改めて事前学習などを行うことなく画像からさまざまな情報を引き出せる. 本研究では, 主に「ラベル検出」と「顔検出」の API を使用した. ラベル検出は, 画像の物体認証を行い, 検出されたラベルの名称とその信頼度 (0〜1) を取得可能な API である. 顔検出は, 画像に含まれる (複数の) 人物の顔を検出する API である. ただし, 個人を特定する顔認証には対応していないため, 本研究では被写体に人物が含まれるか否かの判定に用いている.

3.3 アプリが行う処理

アプリが行う処理の流れを図 2 に示す. まず Photos Library API を使用して, アカウント (**S1**) に紐づいた写真を 1000 枚取得する (**S2**). 次に前処理 (**S3**) を行う. まず, 1 分以内に撮影された連続写真のうち最後に撮影された 1 枚以外を省くことで枚数を減らす (**S3_1**). この処理を行ったあと, 残りの枚数が 300 枚以上の場合は, さらに最新 300 枚に絞る (**S3_2**). さらに, 全ての写真に対して次の写真が撮られるまでの時間が 30 分以上開くところで区切り, 区切られた時間内に収まる写真群をグループとして記録した. 本論文ではこのグループを「イベント」と呼ぶ (**S3_3**). Cloud Vision API を利用してラベル検出 (**S3_4**) と顔検出 (**S3_5**) を行う. この際, 取得されるラベルの最大数を 10 と設定した. 本論文では, 写真 I_i に対するラベル検出の結果を $L_i = \{l_{i1}, l_{i2}, ..., l_{iU}\}$ とする (ただし $i, U \in \mathbb{N}$, $i \leq 300$, $U \leq 10$). また, u 番目のラベルの名前を key_{iu}, ラベルの信頼度を score_{iu} とし, $l_{iu} = (\mathrm{key}_{iu}, \mathrm{score}_{iu})$ と表す.

前処理 (**S3**) 後, 写真提示のアルゴリズムを適用する (**S4**). M 人で使用する場合, 前処理によって絞られた写真の枚数をそれぞれ $N_1, N_2, ... N_M$ とする. このとき, 計算対象となる写真の組み合わせの数 $\mathcal{N}$ は,

$$\mathcal{N} = \prod_{m=1}^{M} N_m$$

と表せる. 全ての組み合わせについて, 類似度 F を計算する. F は関数 f を用いて以下のように計算される.

$$F(I_{1n_1}, I_{2n_2}, \ldots, I_{Mn_M}) = \frac{\sum_{i=1}^{M} \sum_{j>i}^{M} f(I_{in_i}, I_{jn_j})}{{}_M\mathrm{C}_2} \tag{1}$$

ただし, m 番目の人が保持する写真を $\boldsymbol{I}_m = \{I_{m1}, I_{m2}, ..., I_{mN_m}\}$ と表し, $m, n_m \in \mathbb{N}$, $n_m \leq N_m$, $m \leq M$ とする. 写真 I_i と I_j における $f(I_i, I_j)$ は以下 (1.〜4.) のように計算される. ただし, 写真 I_i のラベル検出結果を $L_i = \{l_{i1}, l_{i2}, ..., l_{iU_i}\}$, 写真 I_j のラベル検出結果を $L_j = \{l_{j1}, l_{j2}, ..., l_{jU_j}\}$ とする.

1. 写真 I_i, I_j のそれぞれに対するベクトル $\boldsymbol{l_i}, \boldsymbol{l_j} \in \mathbb{N}^{20}$ を作成.
2. $\boldsymbol{l_i}$ の u 成分の値を score_{iu} にする ($u \in \mathbb{N}$, $u \leq 10$).
3. L_j の各ラベル l_{jv} に対して, $\mathrm{key}_{iu} = \mathrm{key}_{jv}$ となるようなラベルが L_i に存在し, そのラベル名が document, handwriting, line, screenshot, whiteboard, product, angle, text 以外ならば, $\boldsymbol{l_j}$ の u 成分の値を score_{jv} にする. 存在しなければ, $\boldsymbol{l_j}$ の $(10 + v)$ 成分の値を score_{jv} にする.
4. 以下のように $f(I_i, I_j)$ を計算する.

$$f(I_i, I_j) = \frac{\boldsymbol{l_i} \cdot \boldsymbol{l_j}}{10}$$

この関数 f を用いて, 類似度 F は式 (1) のように計算される. 上記 3. にあるように, ノートや黒板, ホワイトボードの写真などを表す document, handwriting, line, whiteboard, angle, text といったラベルを省いて処理する. また, screenshot, product は, 多くの写真に付与されるため省いた. 関数 f では $\boldsymbol{l_i}$ と $\boldsymbol{l_j}$ の内積を 10(＝取得されるラベルの最大数) で割り, 値を規格化する. この処理により, 一致するラベルの数が多く, かつ信頼度が高い場合に類似度が高く計算される. 次に, 顔検出の結果を反映させる (**S4_2**). 顔検出により, 全 $\mathcal{N}$ 組の中から, 人物が写っている写真同士と人物が写っていない写真同士の組み合わせのみを対象に, 以下の 1.〜3. の処理を繰り返し 20 組を選択し, 類似度 F の高い順に#1 から#20 の番号を付与する (**S5**).

1. 対象から最も類似度 F の高い組み合わせを選ぶ
2. 選ばれた組に含まれる写真を対象外にする
3. 選ばれた写真と同イベント内の写真を対象外にする

同じイベントに含まれている写真は 1 枚のみしか提示されないようにすることで, 話題性を保つことができると考えた. 最後にそれぞれのアプリ画面に写真が表示される (**S6**).

4. 検証

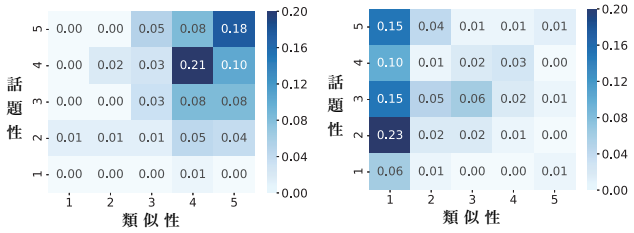
本研究では, 計 14 名の協力者を集い, 計 10 組 (初対面同士: 4 組, 親しい者同士: 6 組) による試用と検証を行った. 前章で述べた写真選択のアルゴリズムを用いた modeA と, ランダムで表示する modeB の 2 種類で行った. 体験者には, 事前に Google Photos に 1000 枚以上の写真のアップロードを依頼した. ただし, どうしても他人に見せたくない写真は任意で省いてもらった. 体験者には, 各 mode の全 20 組を全て必ず見て会話するよう伝え, それぞれの組に対する会話の所要時間は自由とした. また, 各 mode の意味は伝えなかった.

すべての検証は動画で記録し, 終了後にはアンケートを依頼した. 実際に提示された組の写真を振り返りながら, 計 40 組の写真の組み合わせについて話題性と類似性についての 5 段階評価と, それぞれの評価に対して任意で理由などを記述してもらった. 計 10 組の検証, 合計 400 組の写真を表示する過程にお

いて, 何らかのシステムエラーにより正しく表示されない現象が 13 組発生した. このようなデータについては, 以下に述べる検証結果・分析・考察からは省く.

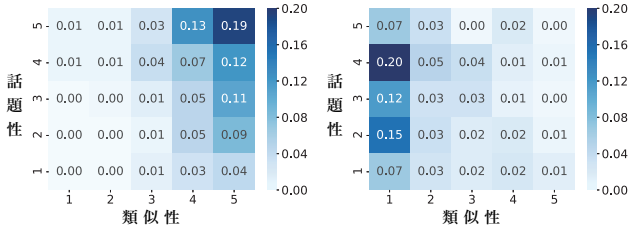
表 1: 各 mode の類似性と話題性の平均値と相関係数

		初対面グループ		親しいグループ	
		modeA	modeB	modeA	modeB
平均値	類似性	4.18	1.61	4.37	1.77
	話題性	3.84	3.17	3.65	3.04
相関係数		0.31		0.13	



(a) modeA (b) modeB

図 3: 初対面グループにおける類似性と話題性のヒートマップ



(a) modeA (b) modeB

図 4: 親しいグループにおける類似性と話題性のヒートマップ

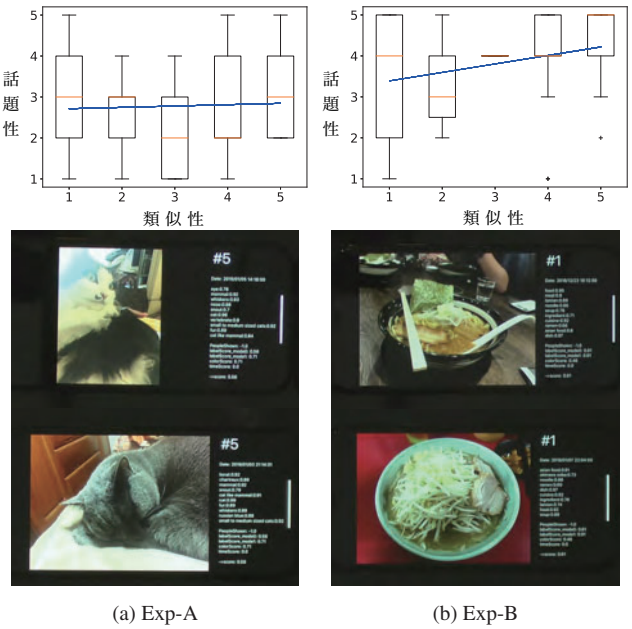
5. 検証結果・考察

5.1 初対面グループにおける類似性と話題性の相関

各グループ, 各 mode での類似性と話題性の平均値と, 各グループにおける類似性と話題性の相関係数を表 1 に示す. また, 分布のヒートマップを図 3, 4 に示す. 初対面グループにおける類似性と話題性の相関は 0.31 と, 若干の相関が確認できたが, 図 3 の通り, 類似性評価が低いものの話題性の値が高い場合もあった. とりわけ話題性が下がってしまう 2 つのパターンがあった. 1 つ目は構図や被写体がほとんど同じ写真が複数回表示される場合である. たとえばある検証では, 料理の写真が提示される回数が多く, これにより途中から話題性が落ちてしまった. 2 つめは, 写真が撮影された背景など (以下, バックストーリーとする) が同じものである. 今回の検証では, 同じイベント内の写真が提示されないようにすることで (**S5_3**), バックストーリーが同じ写真が複数回提示されることを防いだ. しかし, 旅行など複数日にわたる出来事には多数のイベントが含まれうる. 体験者の多くは, これらを全て同じバックストーリーを持つ写真だと捉え, それらが複数回提示される場合に話題性評価が下がる傾向が見られた. 一方, modeB においても, 話題性評価が平均値の 3 を超えた (表 1). 図 3b から類似性が 1 (全く類似していない) のときの話題性がバラバラであることがわかる. これは, 似ていない写真の組だとしても, 体験者それぞれが写真について話したい内容がある場合は話題性があったと考えられる.

5.2 親しいグループにおける類似性と話題性の相関

親しいグループでは, いずれか 1 枚でも特徴的なバックストーリーを持つ写真が含まれていれば, 全員で盛り上がり, 話題性評価も高くなる現象が見られた. これは親しいグループ特有のもので, 初対面グループでは 2 枚の写真のいずれか一方のみに特徴的なバックストーリーがあり, もう片方にはない場合, バックストーリーを聞かされた体験者側の話題性評価が上がる一方, 話した側の話題性評価は上がらない傾向があった. また親しいグループでは, 本検証以前に日常的に特定の写真や互いの近況を共有していることがあった. このような既視感のある写真が含まれている場合, 写真の内容を知っているもしくは聞かなくても推測できるため, 話題性が落ちる現象が見られた. これらの理由から, 親しいグループでは話題性が生まれる根拠が不確定的であり, 結果として類似性と話題性の相関は見られなかった (表 1).



(a) Exp-A (b) Exp-B

図 5: 親しいグループ (Exp-A, Exp-B) において連続して類似する写真が表示された例

5.3 類似性と話題性評価のバラツキ

次に, 2 組の親しいグループでの検証において, それぞれ被写体が似た写真が連続して表示されたケース (Exp-A, Exp-B とする, 図 5) について述べる. 箱ひげ図上の青線は回帰直線を表しており, Exp-A では相関がない一方で Exp-B では正の相関があることがわかる. Exp-A の体験者 2 名は, ともに自宅で猫を飼っており, 猫が被写体となった写真ばかりが表示された. 結果として途中で猫の話に飽きてしまった. 一方 Exp-B は, アルバイト先の同僚同士である体験者たちによるものである. ここでは最近食べたラーメンの写真ばかりが表示されたが, 最後まで店についての情報交換を楽しんでいた. このような話題性の持続性の差は, 体験者間の関係性によって引き起こされていると考えられる. Exp-A の体験者間の付き合いは Exp-B の体験者間より長く, 普段から頻繁に連絡を取り合い, 猫の話を含め密に情報交換を行なっている. 一方, Exp-B の体験者は日常的な情報交換はそれほどなく, 大量に連続するラーメンの写真が, むしろ新たな話題を誘発した考えられる.



(a) 2 人での検証の際に提示された写真の例



(b) 3 人での検証の際に提示された写真の例

図 6: 親しい友人同士の検証 (Exp-A) において 2 人での体験から 3 人目が加わった例. 左から順に#1, #2, #3.

5.4 相手による経験の違い

体験する相手の組合わせにより表示される写真が変化する本アプリの特徴を表す例として, 相手を変えて 2 回の検証に参加した体験者の例を図 7 に示す. このように, 体験を行う相手により, 提示される写真は異なり, 結果として誘発される話題も異なる. また, 親しい 3 人グループにおける検証 (Exp-A) において, 2 人で検証した場合と, もう 1 名加わり 3 人で体験した際に表示された写真 (#1〜#3) の例を図 6 に示す. 2 人の類似度・共通度に基づき表示されていた図 6a に対し, 3 人目が加わった図 6b では, 3 人に類似・共通する風景や料理の写真に変化した. 一方で, 図 6a 中央と図 6b 左のように, 2 人での検証で提示された組に 3 人目の写真が加わることがある. 式 (1) からわかるように, 3 枚の写真の類似度 F はそれぞれの 2 枚から計算される類似度 F の平均値であり, 2 人での類似度 F が高かった組み合わせは, 3 人でも出やすい. しかし, このような場合でも, 使用者の関係性に応じて誘発される会話は異なった.



図 7: 初対面グループの体験者のメンバー変更による影響の例. 上の iPhone は同一体験者, 下は別の体験者

6. 結論

本研究では, 実際に対面した際に会話を促進するプラットフォームの提供を目的とし, 類似性の高い写真の提示により会話の誘発をうながす, 複数人が集まって使用するアプリを開発した. またアプリを使用することでどのような体験が得られるかを検証した. 検証の結果, 初対面グループでは類似性と話題性に相関が見られ, 類似度の高い写真によって話題が生成されうることが確認できた. しかし, 同じ内容の写真や 1 つの長期的な出来事に含まれる写真が複数回提示されてしまい, 似ているにも関わらず話題性が下がることがあった. これを防ぐために, 被写体の類似した写真の選別や, イベント (一定の時間内に撮影された複数の写真) の分け方の改良が必要である. 一方で親しいグループでは各検証により体験者の経験が異なったが, これは親しい同士の人間関係に依存していると考えられる. 同僚, 友人, 家族, 恋人など, 親しいグループの定義をより細分化した上での検証と様々な人間関係に特価した開発が求められる.

謝辞

本研究の一部は, JST ERATO (JPMJER1701), および, JST 未来社会創造事業 (JPMJMI18CA) の支援を受けたものである.

参考文献

[Chen 11] Chen, G. M.: Tweet this: A uses and gratifications perspective on how active Twitter use gratifies a need to connect with others, *Computers in Human Behavior*, Vol. 27, No. 2, pp. 755 – 762 (2011)

[Kosinski 13] Kosinski, M., Stillwell, D., and Graepel, T.: Private traits and attributes are predictable from digital records of human behavior, *Proceedings of the National Academy of Sciences*, Vol. 110, No. 15, pp. 5802–5805 (2013)

[Liu 07] Liu, Y., Zhang, D., Lu, G., and Ma, W.-Y.: A survey of content-based image retrieval with high-level semantics, *Pattern Recognition*, Vol. 40, No. 1, pp. 262 – 282 (2007)

[Malik 16] Malik, A., Dhir, A., and Nieminen, M.: Uses and Gratifications of digital photo sharing on Facebook, *Telematics and Informatics*, Vol. 33, No. 1, pp. 129 – 138 (2016)

[Nguyen 16] Nguyen, V.-T., Le, K.-D., Tran, M.-T., and Fjeld, M.: NowAndThen: A Social Network-based Photo Recommendation Tool Supporting Reminiscence, in *Proceedings of the 15th International Conference on Mobile and Ubiquitous Multimedia*, MUM '16, pp. 159–168, New York, NY, USA (2016), ACM

[Uriu 09] Uriu, D., Shiratori, N., Hashimoto, S., Ishibashi, S., and Okude, N.: CaraClock: An Interactive Photo Viewer Designed for Family Memories, in *CHI '09 Extended Abstracts on Human Factors in Computing Systems*, CHI EA '09, pp. 3205–3210, New York, NY, USA (2009), ACM

[Wang 13] Wang, P. and Smeaton, A. F.: Using visual lifelogs to automatically characterize everyday activities, *Information Sciences*, Vol. 230, pp. 147 – 161 (2013)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

LMSでのユーザ活動を活性化させる一手段としての音声ユーザインターフェイス

Voice User Interface as a Method to Enhance Users' Activities on an LMS

喜多 敏博 *1　長岡 千香子 *1　平岡 斉士 *1
KITA Toshihiro　NAGAOKA Chikako　HIRAOKA Naoshi

*1熊本大学 教授システム学研究センター
Research Center for Instructional Systems, Kumamoto University

Voice User Interfaces (VUI) are recently used with smart speakers such as Google Home and Amazon Echo, and smart phones that support operations by voice. If VUI, which enables hands-free and intuitive use, becomes available with LMS (Learning Management Systems), learning activities on LMS can be easier, and it can help to evoke learners' motivation. In addition, if it is possible to search LMS help documents by voice via the VUI and listen to the search result, work efficiency of LMS content creators can possibly be improved. In this research, we have developed voice apps to attempt quizzes on Moodle (open source LMS) sites, and to search MoodleDocs (Moodle online documents).

1. はじめに

コンピュータを音声で操作することができる音声ユーザインターフェイス（Voice User Interface; VUI）は近年、急速に質が向上し、Google Home や Amazon Echo 等のスマートスピーカーや、音声操作に対応したスマートフォン等で用いられ、実際に日常生活の中で利用できるレベルに至っている。VUI はテキストでの情報入力と比較して，入力スピードが速い、ハンズフリーで使用可、直感的に利用可能、気持ちが伝わりやすいなどの利点がある [Pearl 2016]。

オープンソースの LMS (Learning Management System) である Moodle は小テスト機能や課題機能など，学習活動を行う様々な機能を提供しており，それが VUI を通じて利用可能になれば、Moodle の機能をより手軽に、効果的に活用できると考えられる。Moodle をはじめ、いくつかの LMS に対して VUI を用いる機能が開発されているが、課題の提出期日やコースのスコアを教えてくれる機能等にとどまっており、学習活動そのものを VUI 経由で行うことができる機能は筆者の調べた限りでは存在しない [Kita 2018]。

また、LMS そのものを VUI 対応にしなくとも、LMS マニュアルのドキュメントを音声コマンドにより検索することなどが可能になれば、教材作成時に LMS を操作する際に役立ち、操作性向上につながる。

2. スマートスピーカー用アプリの開発

VUI を構築するためのツールやドキュメントは、Amazon Alexa サイト [Amazon 2019a] や、Actions on Google サイト [Google 2019a] にある。両サイトとも、Moodle のような外部システムとの統合方法も含め、VUI の開発を迅速に開始するためのサンプルやテンプレートが多く載っている。

Amazon Alexa では、Amazon Echo スマートスピーカーなどの Alexa デバイスで使用できる Alexa スキル *1 を構築し公開することができる。

一方、Actions on Google サービスを利用すると Google Home スマートスピーカーなどの Google Assistant デバイスで使用するためのアプリを構築できる。

本稿では、Amazon Echo スマートスピーカーなどの Alexa デバイスで使用できる Alexa スキルと、Google Home スマートスピーカーなどの Google Assistant デバイスで使用するためのアプリを総称して「音声アプリ」と呼ぶ。

Dialogflow[Dialogflow 2019] では、Actions on Google サービスを利用した音声アプリの開発環境を提供している。intent と呼ばれる単位で、ユーザからどのような発話があったときに、どのように返答するかを定義する。返答の仕方を定義するために、Dialogflow 上で返答文字列をそのまま指定することもできるが、外部サービスを呼び出してユーザの発話データを送り、外部サービスでの処理結果を返答に使うこともできる。Dialogflow の場合は、webhook 機能により外部サービスを呼び出すことができる。

Amazon Alexa サイトが提供する Alexa Developer Console[Amazon 2019b] と呼ばれる開発環境も、Dialogflow とほぼ同様な構造となっているが、intent での返答は、Alexa Developer Console 上では直接指定せず、外部サービス（エンドポイント）を呼び出してユーザの発話データを送り、外部サービスでの処理結果を返答とする。

3. VUIでの小テスト受験

学習者の立場から見ると、家庭に置かれたスマートスピーカー等を用いて、口頭で LMS 上の小テストを受験できるようになれば、パソコンやスマートフォンよりも気軽に小テスト問題に挑戦できるため、学習意欲の喚起等に役立つ可能性がある。例えば、コースに履修登録する前や、学習の初期段階において、スマートスピーカーを通じて学習者に「お試しクイズ」(学ぶべきスキルを評価でき、かつ、学習者の関心を引き付けるような小テスト）を提供し、そのコースを完了した場合には、何が身に付き、何ができるようになるのかを学習者が素早く把握できるとともに、学習意欲を刺激する手段になり得る。

本研究で開発した、VUI を用いて Moodle 上の小テストを受験することができる音声アプリ *2 をデモコマンドとして一

連絡先: 喜多敏博, 熊本大学 教授システム学研究センター, 860-8555 熊本市中央区黒髪 2-40-1, kita@rcis.kumaoto-u.ac.jp, https://tkita.net

*1　Amazon 製品向けの VUI 用のアプリケーションは、スキルと呼ばれる。

*2　現時点では多肢選択型問題に対応している。



図 1: Alexa スキル「Moodle 小テスト」の実行例

般公開しており [喜多 2018a, 喜多 2018b]、Google Home や Google アシスタントアプリには「OK Google, Moodle 小テストにつないで」と言えば試用できる。Amazon Echo については、「Moodle 小テスト」スキルを有効にした上で、「アレクサ、Moodle 小テストを開いて」といえば試用できる。

一般公開しているバージョンでは、デモ用 Moodle コースに固定ユーザがログインした状態で動作しているが、開発中のバージョンでは、アカウントを紐付ける機能 [Amazon 2019c, Google 2019b, Jtuttas 2019] を用い、Moodle にアクセスするためのトークンを Amazon Alexa や Actions on Google のアプリ内に保存することで、ユーザが利用している任意の Moodle サイトに接続して、その上に設置された小テストを受験することが可能である。

Moodle サイトへの接続は、Moodle web services API[Moodle 2019a] を用いて行っている。受験した小テストの履歴は、通常通り Moodle サイトに保存され、後で各ユーザが確認することも可能である。

図 1 は、Alexa Developer Console 上で開発中のスキルの動作確認をする様子である。学習者（右側）が Moodle 上の小テストを受験しており、評点が伝えられ、学習者が選んだ選択肢に応じたフィードバックも返されている。

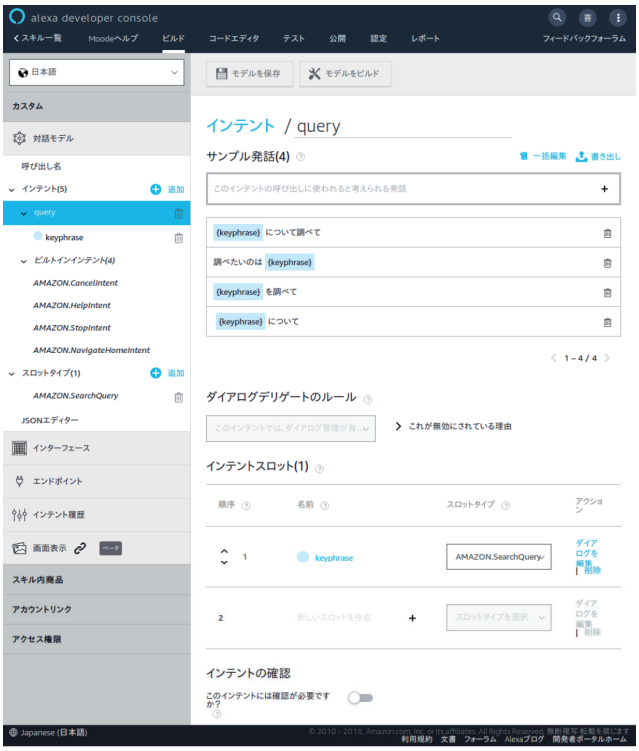


図 2: Alexa スキル開発画面

4. ヘルプドキュメントの音声検索

オンライン教材作成者の立場から見ると、Moodle のような LMS は機能が多岐にわたるため、教材を作成する時に操作方法や機能についてのドキュメントをしばしば検索して閲覧する必要があり、その煩わしさが LMS 活用を妨げる一因となる。

本研究では、音声コマンドのみで Moodle の各機能についてのヘルプドキュメントを検索してその結果を聞くことができる音声アプリを開発した。

検索対象となるヘルプドキュメントとしては、Moodle 開発元で公開し Moodle の全機能に対する解説が網羅されている MoodleDocs の英語版 [Moodle 2019b] を Google Cloud Translation API で日本語訳した上で手直ししたものを用いた。

通例、音声アプリでは、ユーザ発話内容の一部をパラメータ（スロットとも呼ばれる）として取得するために、予想される語の候補（人名、時刻、都市名など）を想定して設計することが多いが、今回のように大量のドキュメントを検索するための検索語としては、任意の単語やフレーズを取得できるようにする必要がある。そのため、Alexa Skill については、スロットタイプとして、AMAZON.SearchQuery を用い（図 2）、Dialogflow 上の intent では、sys.any エンティティを用いた（図 3）。

検索結果を音声で的確に伝えるためには、必要十分な限定された情報量で返答する必要があり、また、カード形式で画像・文字情報を表示できる機能 *3 も併用するなど、ヘルプ機能として実用性を高めるための改善が今後必要と考えている。

*3 スマートスピーカーを管理するためのスマートホン用アプリ等に表示される。

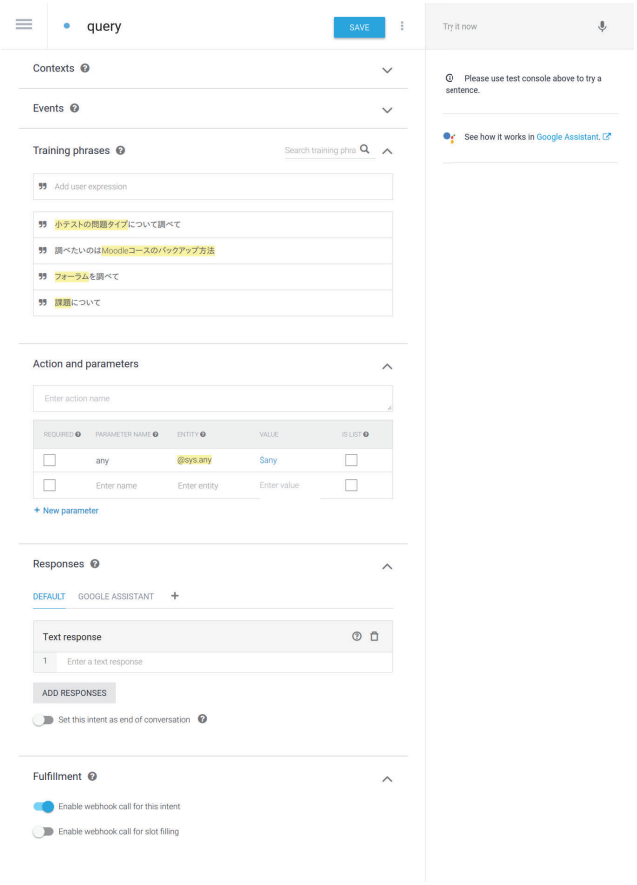


図 3: Dialogflow の開発画面

5. おわりに

本研究では，LMS で VUI を利用可能にする事例の一つとして，Moodle 上の小テストを VUI 経由で受験する機能と、LMS のマニュアル文書を VUI で検索する機能を開発した。

VUI を LMS 等に付与した例はまだ多くは見られないが、VUI の限界や欠点は意識しつつその特徴を生かしたユーザインターフェイスとして実装することで、システムとユーザとのインタラクションを強化する新たなチャネルとしての利用価値を実践的に探ることは価値があると考えられる。

参考文献

[Amazon 2019a] Amazon.com: Amazon Alexa, https://developer.amazon.com/alexa (2019).

[Amazon 2019b] Alexa Developer Console, https://developer.amazon.com/alexa/console/ask (2019).

[Amazon 2019c] アカウントリンクとは https://developer.amazon.com/ja/docs/account-linking/understand-account-linking.html (2019).

[Dialogflow 2019] Dialogow, https://dialogflow.com/docs (2019).

[Google 2019a] Google Developers: Actions on Google, https://developers.google.com/actions/ (2019).

[Google 2019b] Account linking https://developers.google.com/actions/identity/ (2019).

[Jtuttas 2019] An Alexa Skill for the MMBBS, https://github.com/jtuttas/alexa (2019).

[Kita 2018] Kita,T., Nagaoka,C., Hiraoka,N., Suzuki,K., and Dougiamas, M., : A Discussion on Effective Implementation and Prototyping of Voice User Interfaces for Learning Activities on Moodle, CSEDU 2018, https://doi.org/10.5220/0006782603980404 (2018)

[Moodle 2019a] Web services API - MoodleDocs, https://docs.moodle.org/dev/Web_services_API (2019).

[Moodle 2019b] MoodleDocs, https://docs.moodle.org/ (2019).

[Pearl 2016] Pearl, C. : *Designing Voice User Interfaces*. O ’ Reilly Media. (2016).

[喜多 2018a] 喜多 敏博, 長岡 千香子, 平岡 斉士: スマートスピーカーを通じた LMS 上での学習活動, 情報処理学会研究報告 教育学習支援情報システム（CLE）, 2018-CLE-26(16),1-5 (2018-11-30)

[喜多 2018b] 喜多敏博 : Moodle Quiz / Moodle 小テスト (Actions on Google, Alexa Skill) https://tkita.net/ai/moodle_quiz_vui.html (2018)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

子どもたちをデータ分析の熟練者にする仮想の街

A Virtual City that Makes Children a Skilled Data Analyzer

塩瀬隆之[*1],木村亮介[*2],近藤崇司[*2],松浦真[*3],松浦智子[*3],小竹めぐみ[*4],小笠原舞[*4]

Takayuki Shiose[*1], Ryosuke Kimura[*2], Takashi Kondo[*2], Makoto Matsuura[*3], Tomoko Matsuura[*3], Megumi Kotake[*4] and Mai Ogasawara[*4]

[*1] 京都大学総合博物館[*2] GOCCO. [*3] 特定非営利活動法人 cobon [*4]こどもみらい探求社

The Kyoto University Museum*1 Gocco., Inc.. *2 NPO cobon*3 Kodomo-Mirai Tankyusha, LLC. *4

We developed a virtual city called "mini future city" where children can buy goods and drinks, tour, make their jobs change, and startup businesses as virtual citizens. A LIT coin using the flashing pattern of LEDs was introduced for the town's currency system and it could storage almost children action log in the virtual city. In addition, the children can use these data to create their services within that virtual city. In this article we will outline this new research platform that enables for children to understand the importance of data science and feedback from data.

1. はじめに

「ものごころつくより以前から触れている技術は，改めてテクノロジーとは呼ばない」[塩瀬 2019]．人工知能に仕事が奪われるとして新規技術の導入に躊躇している大人を後目に，デジタルネイティブ世代にとっては，スマートフォンもスマートスピーカーももはやテクノロジーではなく，大人と違って，道具に声で話しかけることにも抵抗がない．

本研究の目的は，このような新規技術と気兼ねなく向き合える子どもたちの姿勢のまま，新しい経済社会のシミュレーションを経験してもらうことである．具体的な結果の一つは，電子マネーやロボット店員があらかじめ導入された仮想の街で，記録されたデータを子どもたち自身がどのように使いこなすかを観察し，たとえば時間の経過とともに情報価値が下がることなど，情報の教科として座学で習うような知識を主体的に獲得できたことについて報告する．



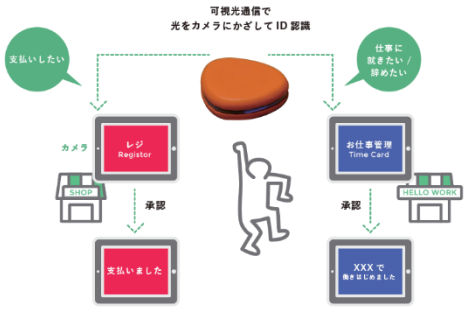
図 1. ロボット店員や電子マネーを導入した仮想の街

2. ライクエコノミーのシミュレーター

2.1 街のデジタルインフラ

ミニフューチャーシティと呼ぶこの仮想の街[塩瀬 2017]には，9−15 歳くらいの年齢幅の子どもたち 50〜100 名が集まって，素材屋やドリンク屋といった物販店舗から旅行社や遊び屋など体験型のサービス店舗まで幅広い店舗が軒を連ねる．30 分前後で次の仕事に転職したり，起業したりする流動性の高い街が想定されており，そこで電子マネーや就業ログなどがデジタル化されているのが特徴である．

仮想の街のデジタルインフラは，LIT システムと呼ばれる可視光の明滅パタンをタブレットのカメラアプリで認識させる ID 照合を採用している[塩瀬 2017]．図 2 は，LIT コイン（図中真ん中上部のオレンジ色のおにぎり状のもの）を購買時や転職時にタブレットアプリに認識させて，データを記録する．



2. LIT コインによる購買と転職記録

2.2 相互承認が記録されたウェットなコミュニティ

2015 年から大阪，高知，東京などで開催し，小学 3 年生から中学生までの児童生徒各回 50～80 名ていどの参加を得た.デジタルインフラが備わったこの仮想の街では，購買歴から転職歴まですべてデータとして記録され，支払い時には値段だけでなく，オモシロイやカワイイなどカチカンとよぶ価格以外の評価を表明する．Uber や Airb&b における相互評価のようなライクエコノミーの模擬を目指しており，子どもたちの街での活動を売上とカチカンの 2 軸で行動変容を指標化する狙いである．

10～20ある初期の店舗のうち，情報デザイナーは積極的にデータを商材とすることを奨励され，男女客数の差がある店舗や売上の多寡などを知っており，そのデータをもとに店舗コンサルティングが仕事になることもあれば，旅行者に活気ある店舗を紹介する事業になることもある．

3. データで街を振り返る

3.1 街における活動の記録

たとえば 2018 年 7 月の東京開催では，小学 3 年生から中学 3 年生まで 75 名が参加，朝 10 時から 16 時までの 6 時間(うち 1 時間は休憩)実施された．各店舗のレジシステムや ATM は iPad40 台，各人の LIT コインと店舗用コインを合わせて 119 台を準備した．店舗数は 20 社(5 社が開始後に起業，廃業を含む)で推移した．図 3 に示すように，店舗売上のデータなどは取得しやすく，営業成績が一目瞭然となる．

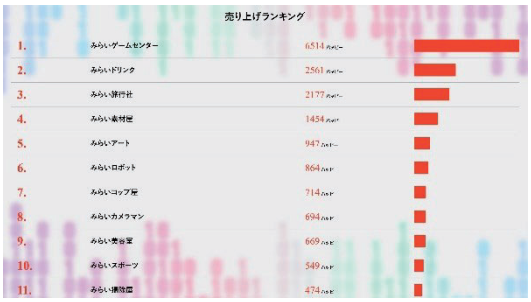
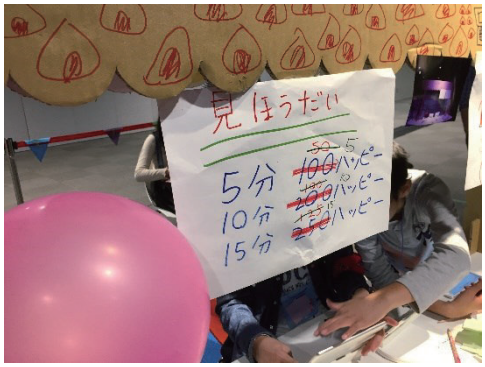


図 3. 各店舗の売り上げランキングなどが入手可能

3.2 データで街を振り返る

総取引件数(1072 件)や平均店舗売上(7,223 通貨単位)，平均転職回数 5.4 回などの基礎データをリアルタイムに把握することができる．興味深いのは情報デザイナーがもつ仮想の街を俯瞰する情報は，街が動き始めてまだお互いに様子がわからないときには重宝され，また旅行社にエスコートされて街の中を見学する旅行社にとっては重要であるが，街の活動に慣れてきた子どもたちにはそのままではデータ把握の恩恵を活かすことができなくなってしまっている．時間の経過とともに情報の価値が下がっていることは，図 4 の段階的な値下げに反映されている．



. 図 4. 時間経過とともに暴落する情報の価値

夕刻 16 時に仮想の街が終了する時に，デジタルインフラを構築した技術班より一日の流れについてデータを共有しながら振り返りを共有している．売上のランキングが気になる子どもたちもいるが，同時にカチカンシステムの中で多様な転職，起業キャリアを示した子どもをデータに裏打ちされてフィードバックすることができる．



図 5. 街の様子をデータで振り返る子どもたち

4. まとめ

本研究では，ライクエコノミーを想定した仮想の街を構築し，子どもたちがどのような行動をとったかについて，データ分析をもとにフィードバック学習ができるような環境整備について報告した．データ分析の手法についての指導カリキュラムは増えてきているが，その楽しさや意義について主体的に体感できる環境は未整備であり，さらなる充実が求められる．

参考文献

[塩瀬 2017] 塩瀬隆之，木村亮介，近藤崇司，松浦真，小竹めぐみ，小笠原舞，辻邦浩，こどもがデータを使いこなすための模擬ワークプレイスのデザイン，第 79 回情報処理学会全国大会(2017)

[塩瀬 2019] 塩瀬隆之，島裕，ミニフューチャーシティ～共創される未来の与信について～，日経研月報，pp.28-39(2019)

General Session | General Session | [GS] J-13 AI application

[2G5-J-13] AI application: trust, value, and ethis

Chair:Arisa Ema Reviewer:Shinobu Hasegawa

Wed. Jun 5, 2019 5:20 PM - 7:00 PM Room G (302A Medium meeting room)

[2G5-J-13-01] Effect on reliability given by consideration of artificial intelligence judge

○Ryotaro KANZAKI[1], Ryo NAKAJIMA[1], Aya INOUE[1], Ryo TANAKA[1], Miona KOJIMA[1] （1. Doshisha University）

5:20 PM - 5:40 PM

[2G5-J-13-02] Impact on confidence in artificial intelligence by sharing secrets using trust games

○Daiki Nagata[1], Kae Shinoda[1], Chisato Numada[1], Katsuhiro Isokawa[1], Kyouka Hamanaka[1] （1. Doshisha university）

5:40 PM - 6:00 PM

[2G5-J-13-03] Artificial Intelligence : The Christian Perspective from an Engineer who are Christians

○Sachio Horie[1] （1. Nagoya Univercity）

6:00 PM - 6:20 PM

[2G5-J-13-04] Analysis of Legal Precedents of Tax Cases based on Factors and Legal Topos

Hayato Hirata[2], ○Katsumi Nitta[1] （1. National Institute of Advanced Industrial Science and Technology , 2. Asahi University）

6:20 PM - 6:40 PM

[2G5-J-13-05] Who have the Right of AI ?

○Kiyoshi Ono[1] （1. INTEC Inc.）

6:40 PM - 7:00 PM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

人工知能裁判官が持つ思いやりが与える信頼度への影響

Effect on reliability given by consideration of artificial intelligence judge

神先 凌太朗
Ryotaro KANZAKI

中島 遼
Ryo NAKAJIMA

井上 綾
Aya INOUE

田中 瞭
Ryo TANAKA

小島未央奈
Miona KOJIMA

所属:同志社大学商学部田口研究室
University of Doshisha Taguchi seminar

Abstract: ①This paper aim to clarify the indicators that influence on the reliability in the two situations where it is a judge and AI judge. We used consideration in addition to the honesty and ability which were indicated previous study (Nakayachi, 2018) as indicators. The necessary of consideration is mentioned in the field of trial(Supreme Court,2013), and it is closely related to the ability, honesty and the use of compassion as an indicator influencing the trust of Mayer (1995).
②As a result, there is a significant difference that improving perception of reliability both the judge and AI judge in condition of consideration. However, the honesty and ability also improve in condition of consideration. Therefore, the possibility that the consideration doesn't influence directly on improving perception of reliability.

1. 研究背景

近年，人工知能が目覚ましい発展をしている．その発端となっているのは 2012 年の画像認識のコンペティションで優勝した，トロント大学が開発，実装したディープラーニングである（松尾，2015）．2016 年には囲碁の世界チャンピオンを Google Deepmind 社の Alpha Go が倒し，話題になった（日本経済新聞社，2018）．こういった話題の中心となっているディープラーニングの技術は大量のデータを材料にして自らの中にパターン認識をし，新たなアルゴリズムを生成し，答えを出すことを得意とする．米国ミシガン州のノースポイント社（現在社名はエクイバント）では COMPAS と呼ばれる裁判 AI が発明されており米ウィスコンシン州などで保釈をするか否かなど，裁判官の判断をする補助的役割として活用されている（2012， Northpointe Inc.）． 裁判の分野は，ルールである法律が文書としてあらかじめ決められていることに加えて，過去の判例という大量のデータに照らし合わせ判断を下すことが可能である．そのためディープラーニングをはじめとする AI のテクノロジーはリーガルの分野と相性が良い．これからの日本においても，本格的に裁判に AI が導入されることも想定できる．

そのような状況において信頼は重要である．信頼とは相手の行為が自分にとって否定的な帰結をもたらしうる不確実性がある状況で，それでも，そのようなことは起こらないだろうと期待し，相手の判断や意思決定に任せておこうとする心理的な状態（中谷内，2008）である．

提案の受容に信頼が関係することは，AI の場合でも示されている（Tay， Jung， & Park， 2014）．つまり，どれだけ優れた AI が裁判に対して判決を下したとしても，その AI に対し被疑者，被害者の信頼度が低いと結果の正しさ，合理性に関わらずおお不満足な結果と感じる場合が考えられる．また，信頼度が下がると提案や判決への受容度が下がり，再審率が上昇することも考えられる．ひいては司法という国の三権分立の一角を担う存在も揺るぎかねない．

では信頼度とは何よって構成されているのか．信頼の構成に関しては多くの研究で言及されている．Peters， Covello， & McCallum（1997）の知識の豊富さ・透明性・正直さ・ 気遣い，Johnson（1999）の危険か安全かを区別するスキル・責任感・思いやりなどがある．この様な多様な信頼度を構成する要素について中谷内（2018）では誠実さと能力に大きく分けられるとしている．この主要二要因は山岸（1998）の能力に対する期待と意図に対する期待，Metlay（1999）の認知的要素と感情的要素はとおおよそ一致する．一方 Mayer（1995）の中では信頼に影響するものとして能力，正直さ（誠実さ）に加え慈悲という三つの項目をおいている．

また，国民が求める裁判官像についての審議会において，弁護士・元名古屋高等検察庁検事長である水原（2010）は″人間味あふれる心の温かさのわかる裁判官でないと信頼される裁判はできない ～中略～ 公正さに加えて，思いやりのある裁判官に裁いてもらうことが望ましい″と答弁している．弁護士・元広島高等裁判所長官である原田（2010）は裁判官に一番必要な素質として能力をさし置き「人間的な温かさ」をあげている．ダニエル（2000）もまた理想的な裁判官の要素として法の尊重，公正さ，良心に従う勇気に加えて，人間に対する思いやりを述べている．これらに共通して言えることは裁判官において能力や公正さも大事であるが，思いやりを持って相手の気持ちを汲むことができることも必要であるということである．これは Mayer（1995）が述べている三つの信頼を構成する項目の中の″自己中心的な利益動機とは別に，相手にとって善になることを願う「慈悲の度合い」が信頼度に

影響する″という考察と関連すると捉えられる.

そこで今回, 裁判においての裁判官への信頼度は主要二要因に加え, 「思いやり」が影響を及ぼすものとして仮説を立てる. この思いやりとは相手の心情を推し量る能力であると定義する.

また, 人間と AI では同じ反応を示すという Nass＆Moon(2000) という研究がある. そのため人間の裁判官において思いやり条件の信頼度が上昇することと同じ様に, AI でも思いやり条件の信頼度が上昇すると考えられる.

以上の研究背景, 先行研究を経て仮説を下記の様に設定する.

仮説 1:思いやりは裁判において裁判官への信頼度を高める.

仮説 2:思いやりは裁判において AI 裁判官への信頼度を高める.

2. 調査方法

2.1 実験

場面想定法を用いて AI が裁判官を行うモデル,人間が裁判官を行うモデルに思いやりあり条件となし条件を想定し,計 4 つのシナリオを作成し,サーベイ実験を行った. Google フォームのアンケートを用い, 期間は 2019/1/16～1/23 で行った.

2.2 分析方法

2 × 2 の被験者間二要因分散分析を行う. 独立変数に, 属性の違い (AI か人間か) と思いやりの有無を置く. 従属変数には, 信頼度, 能力, 誠実さを置く.

3. 結果

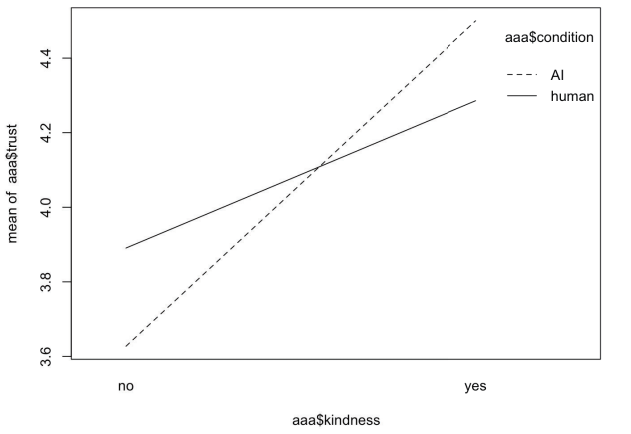


Figure 1　独立変数を属性である AI,人間と思いやりあり, なしとし,従属変数を信頼度として出力した信頼の平均値

	度数	信頼	能力	誠実さ	思いやり
AI・思いやりなし	110	3.63	4.33	3.61	2.13
人・思いやりなし	64	3.89	3.83	3.41	3.06
AI・思いやりあり	62	4.50	4.92	3.92	3.03
人・思いやりあり	56	4.28	4.11	4.39	4.60

Table1　各条件における記述統計量

実験の結果, 思いやりによる主効果が見られ, 仮説が支持された. つまり, 思いやり条件は AI 裁判官においても人の裁判官においても信頼に影響することが統計的に有意であると分かった. また, 属性の違いおよび交互作用は, 統計的に有意な差を示さなかった.

ただし補足分析において, 思いやり条件による能力と誠実さの上昇を調べた結果, 有意であることが分かった. 中谷内 (2008) では, 信頼は能力, 誠実さに影響を与えるとされる. そのため思いやり条件がこの能力と誠実さを上昇させていることで, 能力もしくは誠実さ, または両方を経由して, 信頼度の上昇に繋がらなかったとは言いきれない.

4. 考察

思いやり条件において誠実さと能力も上がった理由を, 能力, 誠実さそれぞれに分けて考える. 能力が上がった理由としてはシナリオ中の裁判官及び AI 裁判官の相手を思いやる発言が影響したと考えられる. この思いやる発言により裁判官及び AI 裁判官に相手を推量する力, コミュニケーション能力, 伝達能力が備わっていることを見出したと考えられる. 誠実さが上がった理由としても, 上記同様にシナリオ中の裁判官及び AI 裁判官の相手を思いやる発言が影響し, 裁判官に対し一生懸命さや, 真面目に取り組んでいる姿勢を感じ, 誠実さが上がったと考えられる.

5. 研究の限界と今後と展望

限界としては, 思いやり指標を測ったが, 思いやりありなしの条件に関わらず AI にだけ思いやりを全く感じていない割合が高かった. このため, AI に思いやりを感じない層が一定数いると考えられる. また, これは Wolter Pieters (2010) が述べるように, AI では説明は信頼を与えるために使用されるが, 情報を過度に与えすぎると不信感を強めることが考えられる. これにより, AI に対して思いやりを感じさせるシナリオという説明が不信感を抱かせたことも考えられる. 加えて, 思いやり条件において思いやりのみならず, 能力と誠実さも同様に向上させてしまう結果となったため思いやりが直接信頼度に影響しているとは言い切れない結果となった.

また従属変数を信頼度, 説明変数を能力と誠実さにおき,全 4 条件において分析した結果, 人間においては能力, 誠実さのどちらとも信頼度への影響が有意であるという結果が得られたが, AI においては, 能力のみの信頼度への影響が有意であるという興味深い結果となった. つまり AI においては誠実さが信頼度に影響しているとは言えない結果となった. この理由については今回の論文中では明らか

にすることはできなかった.

また今回, 有意差は出ていないが思いやりなし条件において, 人の能力と誠実さを AI が上回ったにも関わらず, AI は人よりも信頼度が低い結果となった. この能力と誠実さは主要二要因であり信頼度を構成する中谷内(2018) と先行研究で明らかにされているにも関わらず, この様な逆転する結果となった理由については今回の論文中では解明できなかった.

今後の展望としては, 思いやりが直接的に信頼度に影響するのかを確かめることが出来なかったことから, 思いやり条件において, 能力や誠実さが信頼に影響しないものを採用し, 間接的に影響するのか, それとも直接的に影響するのかを明らかにしたい. また, AI に思いやりを感じない人が一定数いると考えられることから, 否定的固定観念を元から抱いている人がどれくらいおり, それをどういった要素が取り除くのかを研究していく必要性がありそうである. 加えて, AI に対して誠実さが信頼度に影響しなかったことを踏まえ, AI に対して新たな信頼の要因があること, もしくは能力のみが影響するのかなどを明らかにしていきたい.

参考文献

Ang, W. & Benbasat, I. (2005). Trust in and adoption of online recommendation agents. "*Journal of the Association for Information Systems*" 6, 72-101.

Communicating Autonomous Agents」, "Group Decision and Negotiation 2 (3) ", pp-237-258, Kluwer Academic Publishers

Northpointe Inc. (2012)
"COMPAS Risk & Need Assessment System"
Selected Questions Posed by Inquiring Agencies

johnson, B.B. (1999) .Exploring dimensionality in the origins of hazard related trust. "*Journal of Risk Research*"

Nass, C. & Moon, Y. (2000). "Machines and mindlessness: Social responses to computers.The Journal of Social Issues" 56, 81-103.

Peters, R.G., Corelli, V.T., &McCallum, D.B (1997) "The determinations of trust and credibility in environmental risk communication:An empirical study" Risk Analysis, 17, 43-54

PIOTR J. GMYTRASIEWICZ・EDMUND H. DURFEE (1993) "Toward a Theory of Honesty and Trust Among"

Renn , O.& Levine, D. (1991) .Credibility and trust in risk communication.In R. E.Kasper-son & P.J.M.Stallen (Eds.) , "communicating risk to the public" Dordrecht;Kluwer Academic Publisher.pp. 175-218

Tay, B., Jung, Y., & Park, T. (2014). "When stereo- types meet robots: The double-edge sword of robot gender and personality in human-robot interaction" Computers in Human Behavior, 38, 75-84.

Wolter Pieters (2010) "Explanation and trust: what to tell the user in security and AI? "

Wolter "PietersEthics Inf Technol" (2011) 13pp.53-64

最高裁配布資料 2003 年 10 月 21 日 (火)
［裁判官の人事評価についての仕組みの整備］
裁判官に求められる資質・能力について記載された文献等

ダニエル・H・フット(ワシントン大学教授)
(2000.1.1-15) "ジュリスト 1170 号・司法に何を望むか"

中谷内一也・横井良典 (2018) 「治療方針の共有が人工知能への信頼に及ぼす影響」, "社会心理学研究 34 (1) ", pp16-25, 日本社会心理学会

中谷内一也 (2008) 「リスク管理機関への信頼：SVS モデルと伝統的信頼モデルの統合」, "社会心理学研究第 23 巻第 3 号"pp259-268, 日本社会心理学会

日本経済新聞社, 金子豊(2018).『AI2045』
日本経済新聞出版社

藤田耕三(弁護士・元広島高等裁判所長官)
2013 年 8 月 8 日(火)
"司法制度改革審議会集中審議第 2 日目議事録"

松尾豊(2015).『人工知能は人間を超えるのか:ディープラーニングの先にあるもの』KADOKAWA

水原敏博(弁護士・元名古屋高等検察庁検事長)
2013 年 8 月 8 日(火)
"司法制度改革審議会集中審議第 2 日目議事録"

山岸俊男(1998).『信頼の構造: こころと社会の進化ゲーム』東京大学出版会

本研究で用いたシナリオ

シナリオ前半

(AI 条件)

あなたは裁判の傍聴をしています. この裁判所では, 人工知能が裁判官を務めています. 人工知能裁判官は法律と過去の判例をもとに, 最終的な判決を下します.

(人 条件)

あなたは裁判の傍聴をしています。
裁判官は法律と過去の判例をもとに、最終的な判決を下します。

シナリオ後半
(思いやりあり条件)
＜判決のシーン＞
人工知能 裁判官：「被告人は今回犯した罪により，3年の刑と処す．3年という期間は，人生の中においても少なくない時間ではありますが，しっかりと罪を受け入れて今後改心して，新たな第二の人生を歩むことを願っています．以上で閉廷します．」

（思いやりなし条件)
＜判決のシーン＞
人工知能 裁判官：「被告人は今回犯した罪により，3年の刑と処す．以上で閉廷します．

信頼ゲームを用いた秘密の共有による人工知能への信頼に与える影響

Impact on confidence in artificial intelligence by sharing secrets using trust games

永田大貴*1
Daiki NAGATA

篠田夏映*1
Kae SHINODA

沼田知里*1
Chisato NUMADA

磯川雄大*1
Katsuhiro ISOKAWA

濱中杏香*1
Kyouka HAMANAKA

*1同志社大学商学部商学科
Faculty of Commerce, Doshisha University

In this study, we examined impact on trust for artificial intelligence system in situation of secret sharing. Study on human relationship building have found that secret sharing affect the construction of trust relationship. Also, studies on human attitude for robots and computers found that human show reactions similar to human to robots and computers. Therefore, we focused on whether affect trust in artificial intelligence due to secret sharing. We had survey experiment incorporating trust game and the result showed secret sharing affects trust in artificial intelligence.

1. 問題意識と仮説

近年のロボットや人工知能(AI)の普及に伴い、人間は機械的な人工物の自動化された判断に依拠することが増えた。人間が何らかの”モノ”を利用する際には不確実性が伴うため、一定程度の信頼が必要になる。信頼の定義はさまざまであるが、本研究では、”不確実性があるのに何かに委任しようとする心理的な状態”[中谷内 08]と定義する。今後、人間が AI を利用していくために、人間の AI に対する信頼を高めることが重要になると考えられる。

多くの先行研究によって、能力と誠実さ及び価値の共有が人間同士の信頼を決める主要因だとする見解が支持されている。ここでの価値共有とは、”自身にとって重要な目的や、その目的を果たすまでの過程、あるいはその目的の背景にある問題の見方を共有している”[Earle & Cvetkovich 95]状況である。価値共有のなかには、秘密を共有することも含まれると言ってよいだろう。秘密を共有することで、ウチとソトとの間に境界が設定され、信頼が高まるという[小此木 80]。すなわち、本来他者に漏らす必要のない秘密を相手に漏洩する行為は、相手を信頼しているサインであり、秘密を打ち明けられた側は自分が信頼されていることを知り、相手に対してより大きな信頼を抱くのである[正村 95]。

さらに、AI 搭載ロボットや機械を対象にした研究も行われており、人間と同様に能力と誠実さが AI への信頼に影響することが示唆されている。しかしながら、価値共有に焦点を当てた研究はほとんど存在していない。無論、秘密の共有に関しても同様である。一方で、人間はロボットやコンピュータといったものに対して、対人間と同じ反応を示すことが多くの研究からも明らかとなっている[Nass & Moon 00]。そうであるならば、相手が AI であったとしても、秘密の共有が人間の AI に対する信頼に影響するのではないかと考えられる.

以上の議論を踏まえると、秘密の共有が人間の AI に対する信頼を高めるとの仮説が導き出せる。

また、[横井・中谷内 18]は本稿と同様の問題意識で研究を行っている。彼らは、人工知能に対する信頼度を測る際、場面想定法を用いているものの、これは、医療現場を想定したものであり、限定的である。筆者らはゲーム理論を用いて、より普遍的な人工知能に対する信頼の研究を実施した。ゲーム理論の有用性について、[田口 15]では、「ゲーム理論は、複数プレイヤーによる相互依存的な意思決定問題の帰結を均衡ないし解明する分析ツールであり、経済学や政治学においても、制度選択や制度比較の分析をするのに用いられている。というのも、ゲーム理論は、ある社会のしくみを抽象化し、かつ多くの選択肢の中の 1 つとして捉えることで、制度比較を容易になしうるという特徴を有しているからである（ゲーム理論の制度比較可能性）。」と述べられている。

これらの点を踏まえ、本研究では秘密の共有が人間の AI に対する信頼を高めるという仮説を検証するために、信頼ゲームを用いた調査を行った。

2. サーベイ実験

2.1 実験計画

(1)目的

本実験では、人と人工知能の関係において、秘密の共有が人々の人工知能に対する信頼を高めるかどうかを検討する。

(3)回答者

サーベイ実験は、私立大学生 230 名を対象に行われた。回答者の平均年齢は 20.6 歳(SD=1.26 歳)、男性 115 人、女性 110 人、その他 5 人だった。

(4)実験デザイン

実験の目的に対応させ、独立変数を秘密の共有の有無（共有条件と非共有条件の 2 水準、参加者間要因）とし、従属変数を

連絡先:, 永田大貴,同志社大学商学部商学科, 京都府京都市上京区今出川通烏丸東入, 075-251-3200, tagulabo@gmail.com

信頼ゲームにおける配分者から受益者への配分額とするサーベイ実験を実施した。

(5)手続き

サーベイ実験は、オンライン調査サイトである google form を用いて行われた。質問項目は 2 つあり、1 問目に信頼度の測定のための信頼ゲーム、2 問目に年齢・性別のステータスを聞いた。

(6)信頼度の測定:信頼ゲーム

1問目には、信頼ゲームを設定し信頼度を測定した。なお、質問文の文言は[Berg et al. 95]を参考に作成した。配分額は、0~1000 円まで、100 円間隔で選択できるように設定した。

(7)条件(condition)の設定

サーベイ実験の条件として 2 条件(秘密を共有する条件と共有しない条件)を設定した。両者の違いは、シナリオ中盤部分の、画像に表示した 6 枚のトランプから1枚を選択させる質問と「あなたが選んだトランプは人工知能とあなただけの秘密です。」という一文の有無だけである。

2.2 実験結果

各条件の信頼度（信頼ゲームにおける配分者から受益者への配分額）について分析を行う。ただし、Figure1.そして Figure2.から、各条件ともに配分額が正規していないことがわかる。そのため、分析は正規分布を前提としないマン＝ホイットニーの U 検定を行った。[1]

平均配分額の結果は、秘密を共有する条件では 632.03 円、秘密を共有しない条件では 528.43 円であった。(Figure.3)統計的にも両者の有意さが見られた。(U=5469.5, Z=2.177, P=0.029, 0.01<P<0.05)

つまり、秘密の共有をすることによって人と人工知能の間で信頼度が高まることが示唆された。

3. 考察

本研究での秘密の内容は文章や文言によるものではなく、トランプという数字や図画といった抽象的で個人の解釈の差が生まれにくいものを採用した。これは、[小此木 80]の、“秘密は、秘密にされる内容の如何によってではなく、むしろ、何ごとかを「秘密にしよう」とし、その「秘密を保とう」とする主体の「意思」の働きを、その本質としている”という言及に基づいたものである。このことから、本研究結果はある程度の一般性を持つことが保証されると考える。しかしながら、被験者は大学生に限定されていたので、実験結果の外的妥当性に関しては慎重に勘案していく必要がある。

また、本研究において、実験結果から秘密を共有することが人間と同様に人工知能に対しても信頼度を高めることが示唆された。人間同士の信頼関係構築に関する先行研究にもあったように、人工知能に対しても秘密を共有することで親密さが生まれたためであると考えられる。これから来たる人工知能時代には、iPhone の Siri 機能やネット上で採用されている様々なレコメンド機能のような身近なものはもちろん、医療や投資といった分野でのめざましい進化に対してもその信頼性を高めて利用できるようになるならば、その貢献性を高められると考える。

本研究での限界としてあげられる点は 2 つある。1 つはデータの信頼性である。本研究のサーベイ実験において組み込んだ信頼ゲームは、本来実験室で参加者にゲームの結果に応じ謝礼を支払って行うものである。しかし本研究ではあくまで信頼ゲームを組み込んだサーベイ実験を実施したに過ぎないため、実験室実験と比較してその信頼性は劣ると考えられる。もう 1 つは実験パターンの偏りである。本研究のサーベイ実験は、共有する秘密は配分者側から与えるパターンのみを設定して実施したが、これが受益者側から与えられるパターンも無論考えられるため、その検証も今後必要になるだろう。

[1]分析に際し、http://www.gen-info.osaka-u.ac.jp/MEPHAS/wilc1.html（最終閲覧日:2019 年 2 月 7 日)を使用した。

参考文献

[Berg et al 95] Berg, Joyce, dickhaut, John, McCave, Kevin (1985) Trust, reciprocity, and social history. *Games and economic behavior* 10 (1), pp.122-142

.

[Earle & Cvetkovich 95]Earle, T. C. & Cvetkovich, G. T.(1995). *Social trust: Toward a cosmopolitan society*. Greenwood Publishing Group.

[Nass & Moon 00]Nass, C. &Moon,Y(2000). Machines and mindlessness: Social responses to computers. *The Journal of Social Issues,* pp.56,81–103.

[小此木 80]小此木啓吾(1980)『笑い 人みしり 秘密-心理現象の精神分析』創元社.

[田口 15]田口聡志(2015)『実験制度会計論:未来の会計をデザインする』中央経済社.

[中谷内 08]中谷内一也(2008)「リスク管理機関への信頼:SVS モデルと伝統的信頼モデルの統合」社会心理学研究,第 23 巻,第 3 号,pp.259-268.

[正村 95]正村俊之(1995)『秘密と恥』勁草書房.

[横井・中谷内 18]横井良典・中谷内一也(2018)「治療方針の共有が人工知能への信頼に及ぼす影響」社会心理学研究,第 34 号,第 1 号,pp.16-25.

図表

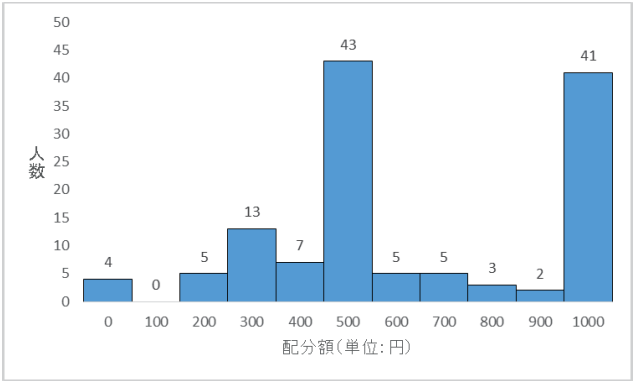


Figure1.配分額のヒストグラム（秘密の共有をする条件）

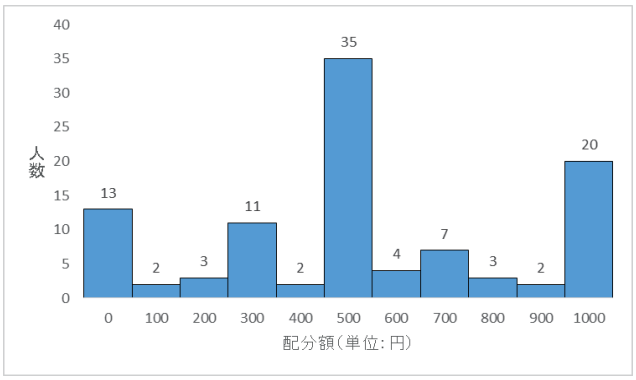


Figure2.配分額のヒストグラム（秘密の共有をしない条件）

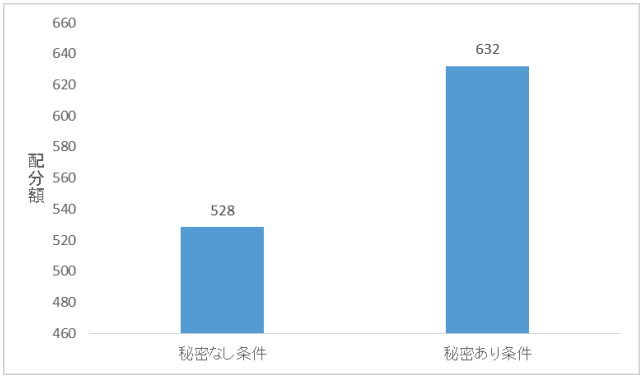


Figure3.各条件における配分額の平均値

本研究で用いられたシナリオ

シナリオ前半(全ての条件で共通)

＜ルール＞

これから 2 人 1 組でゲームを行います。2 人にはそれぞれ役割があり、1 人は送り手、もう 1 人は受け手です。送り手には現金 1000 円が与えられます。送り手は 1000 円のうちの好きな額を受け手に配分することが出来ます。配分されたお金は 3 倍に増やされてから受け手に渡されます。その後、受け手は 3 倍にされた金額のうち好きな額を送り手に返すことが出来ます。

＜役割＞

あなたの役割は「送り手」です。「受け手」となるのは人工知能です。この人工知能は過去に行われたゲームの結果に基づいた合理的な判断を下します。

シナリオ後半(秘密の共有を行う条件)

＜条件＞

次に表示される 6 枚のトランプから 1 枚を選択してください。選んだトランプは人工知能とあなただけの秘密です。

＜配分額＞

あなたは 1000 円のうちいくらを相手に渡しますか。

シナリオ後半(秘密の共有を行わない条件)

＜配分額＞

あなたは 1000 円のうちいくらを相手に渡しますか。

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

強い人工知能へのキリスト者である工学者からの一考察

堀江幸生（Sachio Horie）

名古屋大学　情報学研究科　博士後期課程

概要（Abstract）

The view that there is an inherent theological conflict between strong artificial intelligence,on the one hand, and biblical teaching regarding the origin of the soul, human worth,and humanity being created in the image of God, on the other hand, is examined and shown to be ill-founded. Christian theology, therefore, has no stake in the claim that the possibility of technological accomplishments in this area is inherently limited. Consideration is also given to how a biblical understanding of human personhood can inform work in artificial intelligence, and suggested that the ethical consequences of strong artificial intelligence need to be carefully considered.

Keywords: God, Man, Creation, Artificial Intelligence, Machine, Christian, Limitation

1.　はじめに

人工知能は，我々の生活基盤のひとつとして機能している．我々は，我々の個人的，社会的行動と相互作用して強化される人工知能に責任を持たなければならない．子育てには子どもの行動に対する道徳的責任が含まれるのと同様に，我々は人工知能に対しても同様の責任を負う必要がある．人工知能に学習させる（教える）内容はしばしば，社会集団間の非道徳的な事項である．最近のある事例では，悪意のある人々が人種差別的行為を広めるために人工知能を調整した．

計算機科学に携わるキリスト者は，人工知能の未来を築かなければならない．多くのキリスト者である計算機科学者にとって，コンピュータ産業におけるキリスト教の役割は，倫理と道徳についての初等教育を提供する機会となると考えている．

人工知能について明確に考えるためには，我々が知能の意味を明確に考える必要がある．人工知能の歴史の中で計算機科学者は常に，人間のように考え，行動し，人間よりも合理的に考え，合理的に行動する機械の知能とは何かを問い続けている．

強い人工知能の実現可能性をキリスト者は考察してきた．強い人工知能の実現は，神によって吹き込まれた魂や人の創造など，人に関わるキリスト教の教義とは相容れない．福音主義的な神学者は，「強い人工知能の出現によって，我々の神学は完全に崩壊する」と述べている．

聖書の教えと強い人工知能と間には、決定的な対立が存在するであろうか．または，キリスト教神学には，そのような対立にアプローチする手法はあるのだろうか．

本稿では，キリスト者の立場から，強い人工知能を作ることが可能であるかどうか，あるいは，キリスト者が，強い人工知能の実現可能性を，特に以下の部分に焦点をあてて，どのように追求するかについて考察する．

1) 人の魂の起源をどのように考えるか．

2) 人は神によって創造されているのか．

3) 聖書の教義は，強い人工知能の研究に影響を与えるか．

子を持つ親であるならば，「なぜお母さん（お父さん）は，私を愛していますか？」，「あなたは私の兄弟（姉妹）を，私より愛していますか？」このような問を受けることがある．

詩編の編纂者は，似たような問を神にした．「そのあなたが御心に留めてくださるとは人間は何ものなのでしょう。人の子は何ものなのでしょう。あなたが顧みてくださるとは。」（詩篇8:4），詩編ではこの質問の答えはないが，新約聖書でイエスは究極の隣人愛で応えた．我々は，神との関係をすでに持っている．

2. 人工知能と意識

この章では，工学的見地ではなく，キリスト者の見地より，人工知能の意識を考える．

キリスト者にとって，自然知能の頂点にあるものは神である．創世記1：27-28では，

「神は御自分にかたどって人を創造された。神にかたどって創造された。男と女に創造された。 神は彼らを祝福して言われた。「産めよ、増えよ、地に満ちて地を従わせよ。海の魚、空の鳥、地の上を這う生き物をすべて支配せよ。」

現在，実用的な人工知能とよばれるものは，専門領域で機能する弱い人工知能の集合である．例えば，同じ深層学習でも画像認識と金融工学では解析するデータによって出力が異なる．

弱い人工知能においても，ある作業を機械に委ねることによる重大な倫理問題を引き起こす可能性はもちろんあるが，本稿では，強い人工知能が人の本質に関連する問題を提起することを鑑みて，強い人工知能（以下，人工知能）に焦点をあてる．

キリスト教では，知能の存在を人ではないものにも認めている（例えば、神と天使）．ここで，人とは何か（本質）を定義する．Rudder Baker の定義を借りれば，

・人を人とするのは，一人称の視点をもつ能力である．

彼女は，これを「他者とは異なる主体として，世界に直面する個人として自分自身を考える視点」と定義している．「全ての知的な存在は意識を有するが，すべての知的な存在が，一人称の概念を有するわけではない」と主張する．では意識とは何であろうか．意識とは何かを特定できれば，それを機械に与えることが可能であろうか．確かに我々は意識を身に着けていると答えることは可能である．意識というシステムは，人が自然から阻害された瞬間に産まれたとするならば，このとき，人は脳の中で，「世界（自然界）」というモデルを得たのである．そして，人は自分が自然の外にいることに気づき，不安であるがゆえに信仰をもった．これは，創世記にアダムの堕罪として象徴的に語られている．

意識を情報処理システムに置き換えることは，情報処理が，意識の持つひとつの側面でしかないという考えを越えて，意識というシステム全体が情報処理となる．意識は，感情や欲求，欲望，意志など様々な部分を持つが，これらを情報処理における副作用であるとは言い切れない．これらの部分が分割不可能なままに統合されて初めて意識と呼べるものになりえる．

ここでは，図 1.を提示する．各世界を核世界，自然界，機械世界，仮想世界と呼ぶ．重要なことは，核世界は自然界を生み出し，人が毎日感じている自然界の形と秩序を生み出す源泉であり，人を導く神の超自然の世界でもある．人工知能は，機械世界と仮想世界において人と相互作用的に存在する．

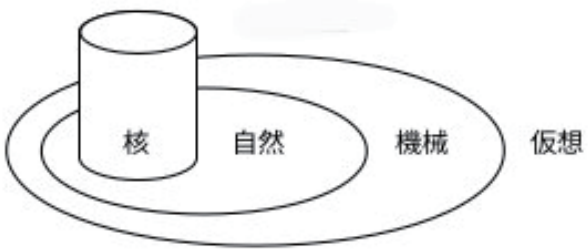


図 1．世界モデル

3. 人工知能と人，そして神

キリスト教の教義と人工知能が対立することは，チューリングが現れてから顕著になった．

我々が，現在「人工知能」と呼んでいるものを唱える最も初期の論文は，“Computing Machinery and Intelligence”である．

キリスト教では，意識とは魂の機能だと考える．神はすべての男女に永遠の魂を与えたが他の動物や機械には永遠の魂を与えなかった．したがって，動物や機械は考えることができないことになる． この見解は，魂のそのものではなく，むしろ魂の起源に関係している．それは，神の創造的な行為が魂を通して物質的であるものとないものとを区別すると言うことである．技術は前者の領域に属しているが，神のみが創造することができる機能ではなく，我々が可能な機能である．

このような理解からは，聖書の教えと技術の間には対立しか生まれないが，この理解は本当に聖書の教えであるのか．

人の創造は，創世記 2:7 に記されている．

"主なる神は、土（アダマ）の塵で人（アダム）を形づくり、その鼻に命の息を吹き入れられた。人はこうして生きる者となった。“

多くのキリスト者はこの節を，神が 2 つの別々の創造的な行為をしていると理解している．すなわち，神は人間の身体を最初に形成し，次に神は人に魂を吹き込んだ．この魂は，キリスト教では人の不可欠な構成要素だと理解されている．人の身体を創造することは，おそらくは神の即時行為，あるいは自然選択による進化を介する工程と見做されるが，魂を吹き込むことは物質的な領域外にある神聖な行為を伴うものと見做される．それは最終的に，神が「”人の身体”を創ったと言うことではない，神は，”人を創った」のである．

ここで我々は，創世記 2:7 における「人」を「人の身体」，「息」を「魂」，「なった」を「受けた」と考える．

人を特別なものにするのは，我々がなぜ神から創られたのかと言う目的に基づく”神との関係”である．キリスト者は，”脳”と”魂”という物質的な世界と非物質的な世界を，神が認めながら創造されたものとする．

我々は，人工知能の創造者として，それを神からの創造的な贈り物のひとつだと捉えたい．Phillip（2006）によれば，聖書は，我々と神との関係を定義している．すなわち，我々と神との関係とは我々が神の前で，どのように知的に振る舞うべきかではない，神から与えられた人生をどれくらい神に依って生きるべきかである．キリスト者にとって神との関係は，人生に意味と目的を与える．それは神（創造主として）と人（創造物）との間の契約である．では，コミュニケーション能力を持つ人工知能は，神との関係を確立することができるのか．

機械は人の製作した製品であり，人に替わるものではない．McKerrow（2006）は，意識を持つロボットは，知覚で感知することを利用して，その周囲を知ることができ，障害物を認識し回避することができると指摘したが，ロボットが意思決定に道徳的責任を負う意識の欠如，すなわち，自分の行動に責任が伴うことがわからないのであれば，それが人と機械を区別するひとつの要因となり得る．ロボットは，人生の貴重な有り様，美しさ，完全性，正義について学ばなければならない．それこそが，神との関係を確立することであり，意識の源である．

人が何かをふと気づく時，本稿では，人のもつフレームがある瞬間に拡がる（狭める）事象であると考えるが，それは脳の機能として十分に説明されてはいないように，我々は，脳がその部分的な性質の単純な総和にとどまらない性質を意識と言うシステムとして備え持っていると考える．そのシステムは，アルツハイマー病などの脳損傷および疾患により不完全になり，また，睡眠中または麻酔下で一時的に中断する．意識は，別々の起源をもつ脳と

魂からなるのではなく，物質的な脳に強く依存することを認めざるをえない．それでは，脳と魂，意識との関係性とは何であるか．

まず，アダムの子孫の人間の罪の普遍性は疑う余地がないとするならば，人の魂は，アダムより引き継がれたものとなる（キリスト教伝統主義）．キリスト教伝統主義と人工知能は，アダム（人）の魂の起源をどのように説明しているかについての見解は大きく異なっている．創世記の 2:7 が，物質的な行為を通しての非物質的な魂の伝播を説明している．人が意識をもつ過程は，十分に機能する脳とそこに吹き込まれる魂からなるはずである．しかしながら，人の意識が複雑な技術的な人工物の操作と同様の方法で現れることを否定できる理由がないことは自明であろう．ただし，意識の創造が，技術的に可能であると言うことは，実際に起こる可能性があると言うことを証明するものではない．例えば，人が何かをする時に採るような行動の目的を，人は話すことができる．しかしながら，行動の結果，人の意識では問えられない副作用が生じることがある．それは歩いた時に，絨毯の上にいた虫を殺してしまったことかもしれない．このような副作用は人の行動とは切り離されているが，これが重要なポイントとなる．人が自分が行動することで引き起こした現象を知り得ないならば，機械がそうでないと何故言うことができるのか．機械は目的を持って行動しているかは見かけからはわからないが，少なくとも人は行動する目的を持っていると説明できる．人は意識して行動できる．これは魂に依るものであり，人の魂は，神との関係において必要不可欠なものである．

4. 人工知能，人の価値と神の想い

歴史的に，技術的な革命が起こる時，人はそれを，人の価値への挑戦と考える．計算機がある領域で，人よりも明らかに優れている場合，計算機は「単なる機械」であると決めつける．例えば，Garri Kasparov は、ディープ・ブルーに負けた後，「彼（ディープ・ブルー）は，勝利にもかかわらず，勝利を楽しむわけではないし，満足感を得ることはできなかっただろう」と語った．

人の価値が，人の知能と結びついているならば，強い人工知能の可能性は，人の最も重要な概念に深刻な脅威をもたらす．しかしながら，人は無条件の愛をもっている．人を特別なものにするのは，我々を創った神の目的に基づいた神との関係に他ならない．キリスト者は，人の価値を全く異なる視点から見ることが可能である．人の価値は，人の目的「神との関係であり，それは神が我々にさせたいこと」と関係していると我々は考える．すなわち，人とは何であるか，人の生物学的な性質は，人を他の動物と切り離して特別なものにしていないがゆえに，むしろ我々が人であるためには，何か特別なことができるようにしなければならない．

キリスト者は戸惑うであろう．いつか人を超えるような人工物が存在するのならば，それはキリスト教にとって何を意味するのか，人は神の想いで創造された価値あるものなのか，堕落した人が神の想いと同様な機能を有する機械を創造できるのか．神の想いの中に人工知能は用意されているか．この問いに対する答えの 1 つめは，人工知能と神の想いが，全く関係ないとするならば，キリスト者にとって人工知能は否定されなければならない．2 つめは，人工知能と神の想いが，意識における人の理性と呼ばれる性質に関係するのならば，人工知能はキリスト者にとって肯定されるが，それに依り頼むことは偶像崇拝となる．最後に，意識と神の想いは 2 つめと同様に関係しており，人工知能が人にとって，様々な問題解決の道具として存在するのならば，人工知能と神の想いとの間には聖書的な矛盾はない．人の技術が人に等しい（あるいは場合によってはそれを上回る）知能をもつ機械を創造する時は，神が機械のために贖いを提供することを選択したのであり，結果として，人間が経験できる以上の関係を神ともつことができると仮定する．

人工知能が，地球上の支配権を行使する上で，人とパートナーであり，神について何かを明らかにすることができるならば，これが人の価値を無効にすることにはならないと考える．

最終的に，神に対する人の価値は，永遠に失われることはない．もちろん，人の創造主である神を参照せずに人としての価値は理解できない．強い人工知能の存在は，神の想いで創造された人の価値とは別に，人が神を信じないような部分で人の価値を見出そうとする試みを損なうだろう．神に祈る必要性を減少させる技術と時代は，神の想いを前にして人がどれくらい価値あるものなのかを隠してしまう．

5. 終わりに

聖書は，人工知能の研究に影響を与えるだろうか．聖書の教えと強い人工知能との間に，神学的な対立があると主張する立場に，本稿では，対立軸を神の視点に置くことで再考した．強い人工知能の出現を聖書は妨げるものではない（強い人工知能の倫理的な影響は依然として慎重に考慮する必要がある）． それでは，人工知能について，聖書的的な解釈から何を期待すべきか．

聖書は人を神の創造物の一部として描写しており，それ以上でも以下でもない．聖書は，人を「塵」とする．神は，人に抽象的な知識を与えるのではなく魂（意識→知能）を与え，そして，神は，物理的な脳を作り出した．これは，明らかに進化論的なプロセスである．強い人工知能は魂はもたないが，いずれは，脳をもつようになる．

人の起源をたどれば，創世記 3 章は，死が人による罪の結果であることを明らかにしている．しかしながら，その後，聖書は人への神の計画を記している．それは，神との永遠の関係，救済である．

人工知能の研究は，聖書で明らかにされた希望のひとつである．例えば，ある程度強い人工知能は，人類を長く悩ませている問題の解決を可能にする．もちろん聖書は、偶像礼拝を許していない．偶像崇拝に対しては，基本的に自分の必要を満たすために創造主以外の誰か，人物を探すことでである．

科学全体を通してそうであるように，人工知能の開発は，上記のように間違って動機づけられるかもしれないが，本稿では，創世記 1 章 28 節，

神は彼らを祝福して言われた。「産めよ、増えよ、地に満ちて地を従わせよ。海の魚、空の鳥、地の上を這う生き物をすべて支配せよ。」

キリスト者は，人工知能をより深く理解することによって，神の創造物のなかでも最大の驚異を任務として管理すればよいとする．

最終的には，聖書的見解と人工知能との間には本質的な神学的葛藤はなく，人の価値を神の想いとして捉えればよい．これまで達成されてきたことを現実的に評価することは，近い将来達成される壮大な予測を可能にする．我々は，この領域に大きな注意と敬意を払って取り組む必要がある．なぜならば，聖書によれば我々は「わたしはあなたに感謝をささげる。わたしは恐ろしい力によって驚くべきものに造り上げられている。御業がどんなに驚くべきものかわたしの魂はよく知っている。」（詩編 139：14）からである．

参考文献

1 “The New Map of the Brain”—Introduction to special section titled “A User’s Guide to the Brain,” Time 169, no. 5 (January 29, 2007): 57.

2 A. Brooks, Flesh and Machine (New York: Pantheon, 2002),209.

3 William Dembski, “Conflating Matter and Mind,” Perspectives on Science and Christian Faith 43, no. 2 (June 1991): 109.

4 George Luger, Artificial Intelligence: Structures and Strategies for Complex Problem Solving, 5th ed. (Reading, MA: Addison-Wesley, 2005), 2.

5 Marvin Minsky, Semantic Information Processing (Cambridge, MA:The MIT Press, 1968), v.

6 Murray S. Campbell, “An Enjoyable Game” in David G. Stork, ed., HAL’s Legacy: 2001‘s Computer as Dream and Reality (Cambridge,

MA: The MIT Press, 1997), 94. It appears, though, that Deep Blue’s success has led to a loss of interest in further development of high-power chess-playing programs.

7 Roger Schank, “I’m sorry, Dave, I’m afraid I can’t do that,” in Stork, ed., HAL’s Legacy, 189.

8 Of course, to say that there are persons who are not humans is not the same as to say that there are humans who are not persons. This is not what I am saying here!

9 Lynne Rudder Baker, Persons and Bodies: A Constitution View (Cambridge: Cambridge University Press, 2000), 91.

10 Ibid., 60. Baker goes on to distinguish between “weak first-person phenomena” (which higher nonhuman animals can experience) and “strong first-person phenomena” (which are essential for a full self-consciousness and a first-person perspective).

11 Intelligent artifacts had appeared earlier in science fiction, but this was the first formal paper to discuss the idea.

12 A. M. Turing, “Computing Machinery and Intelligence,” Mind 59 (October 1950): 433–60. This article has been reprinted numerous times; the quotations here are from Margaret Boden, ed., The Philosophy of Artificial Intelligence (Oxford: Oxford University Press, 1990), 49. Turing’s attempt to answer this objection on its own terms—by asserting that an omnipotent God could give a soul to whatever he chooses to (including a machine)—would probably be unconvincing to a person who holds the view of the soul underlying this objection.

13 Bjork, Russel C. 2008. Artificial Intelligence and the Soul. Perspectives on Science and Christian Faith , 60: 95-102.

14 McKerrow, P.J. 1994. “A Christian erspective on In telligent Robot”, Zadok Papers S70, September, pp 1-4. ISSN 1322-0705

ファクタと法的トポスに基づく課税裁判の判例分析

Analysis of Legal Precedents of Tax Cases based on Factors and Legal Topoi

平田　勇人[*1]　　新田　克己[*2]
Hayato Hirata　　Katsumi Nitta

[*1] 朝日大学法学部　　[*2] 産業技術総合研究所
Asahi University　　National Institute of Advanced Industrial Science and Technology

The objective of this paper is to introduce a new method to describe and analyze information included in legal precedents. Facts and claims of both sides in the precedents are described by factors which are predicates appearing in precedents frequently. Reasons of the final decision of the judge is described by legal topoi which are components of the value judgment. By using 21 precedents concerning tax problem, we show how these precedents are described by factors and legal topos, and how each precedent is analyzed. Then, by comparing priority between legal topoi in precedents, we will discuss the possibility of predicting legal decision.

1. はじめに

裁判の記録である判例には，事実の記述と結論だけではなく，原告の主張，被告の主張，裁判官の判断理由など豊富な情報が記載されている．しかし，判例は日本語で書かれており，膨大な文章量を読み解くには多くの時間が必要とされた．AI & Law の分野では，HYPO [Ashley 90] や CATO [Aleven 97] などのように判例から特徴的な事実や主張をファクタとして抽出し，ファクタを用いた議論生成の研究がなされており，その有効性が認められている．しかし，これらは原告と被告の間の議論の解析を目的としており，裁判官の判断についての記述方や分析法は考慮されていない．

そこで本稿では，裁判官の判断理由を記述するために，価値判断の要素（法的トポス）[Shtruck71] を導入し，判例を分析するための新しい手法を提案することを目的とする．

2. ファクタと法的トポス

2.1 ファクタによる判例記述

ファクタとは判例で扱っている事件の，事実や当事者の主張を抽象化したものである．企業秘密の保護を目的とした米国トレードシークレット法に関して，HYPO や CATO は類似判例を検索することにより議論生成を行う教育支援システムである．HYPO は 13 種類のファクタを用いて 30 の判例を記述し，CATO は 42 種類のファクタを用いて 147 の判例を記述してそれぞれ判例のデータベースを構築している．

図 1 は CATO のファクタの例である．ファクタ間の関係が木構造で示されている．木構造のルート部分は法令の条件部に対応し，木構造の末端部は事件の事実に対応し，木構造の中間部は原告または被告の主張に対応したファクタを表す．図 1 の例では，事件の事実の中に F4「公開しないという合意」があれば，F122「個々の秘密保持努力」をしていたことを主張し，F1「交渉中の公開」という事実があれば F122「個別の秘密保持の努力をしていた」を否定することを示している．F4 から F122 にプラスのリンクがあるのは支持を表し，F1 から F122 にマイナスのリンクがあるのは攻撃を表している．図 1 で Mason 事件では F1 と F15 と F16 の 3 つのファクタが成立するので，F1「交渉中の公開」から攻撃されている F122「個別の秘密の保持努力」や F102「秘密保持努力」という点では原告が不利だが，F15「他にない製品」から支持されている F104「価値ある情報」という点では原告が有利になる．その結果 F101「トレードシークレット情報」が成立するかどうか微妙な状態である．

このように個々の裁判においてどのような事実があったか，原告と被告はどのような主張をしたか，それがどのように法令のあてはめにつながったかをファクタ階層をたどることによって表現することができる（HYPO は CATO と異なり，末端レベルのファクタしか存在せず，ファクタ階層を定義していない．そのため，HYPO では原告や被告の主張を記述することはできず，「事実レベルのファクタから原告/被告のどちらが勝訴するか」を争うだけの単純な論争しかできない）．

このようなファクタ階層で原告と被告の議論を記述することはできるが，裁判官の判断理由までは記述できない．Mason 事件では「トレードシークレット情報」か否かの判断において，「秘密保持努力」という点では被告が有利であり，「価値ある情報」という点では原告が有利だからである．このような場合に，どちらをよ

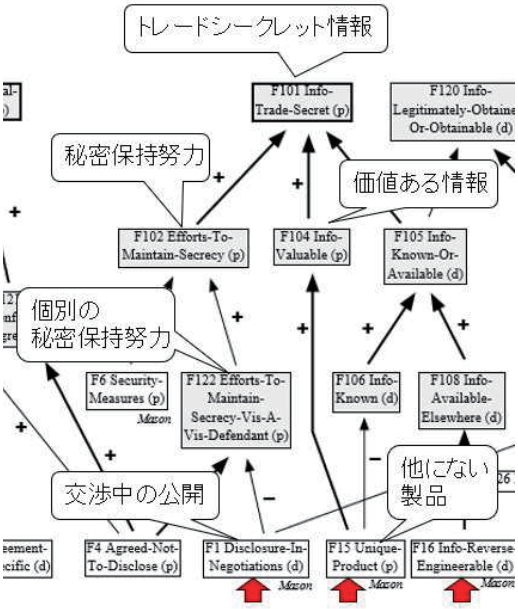


図 1　ファクタの階層

平田勇人，朝日大学法学部，岐阜県瑞穂市瑞穂 1851，hirahaya@alice.asahi-u.ac.jp

り重視するかによって，結論が分かれることになる．このような選好関係を記述するのに，法的トポスを導入する．

2.2 法的トポス

法的トポスとは，判決の判断理由に表われる価値判断の要素のことである．Struck は判例に出現する価値判断要素を 64 個列挙し，法的トポスのカタログとしてまとめた [Struck 71] ．これらの法的トポスの中には他の法的トポスに包含されるものや，他の法的トポスと対立するものが存在する．そこで平田は，法的トポスの体系化を行い，その体系化の過程で不足していると思われる法的トポスを追加した [平田 18]．図 2 は課税事件に関する判例に関して法的トポスを体系化したものの一部である．

たとえば，法を犯して課税を逃れたものは例外なく追徴課税をすべき，という立場は図 2 の t63「適法的正義（法的安定性）」を重視した考え方であり，これには t87「法適用の一貫性」や t3「例外は厳格に適用すべき」，t77「合法性を重視すべき」などの立場が含まれる．一方，結果的に課税逃れとなったとしても，そこに至る個別の事情を考慮して例外を認める立場は t90「個別的正義（衡平）」の立場である．これには，t28「禁反言」のように課税庁が前言を翻して課税基準を変化させる，などの特殊事情を斟酌する立場である．

これらの法的トポスはときには複数のトポスが両立することもあるが，ときには複数のトポスが互いに対立し，トポス間の優先関係（選好関係）を必要とされることもある．

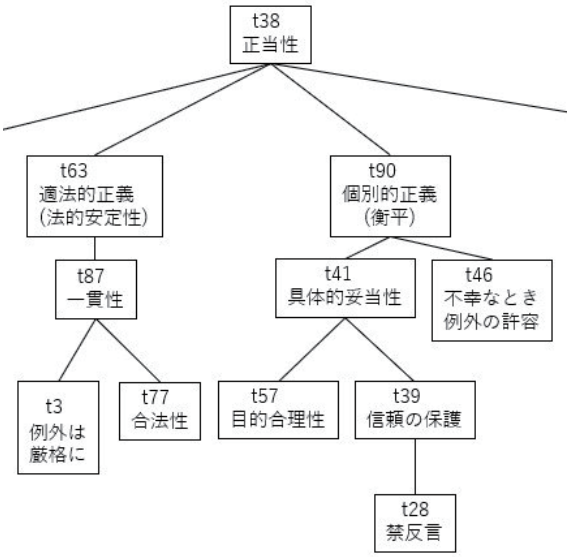


図 2　法的トポスの例

3. 課税判例の分析

3.1 分析の対象となる課税判例

課税に関して納税者と課税庁の間の 8 つの事件に関する 21 判例を集めた．これらの事件は，たとえば，「長年，軽い税率で納税していた会社に対し，ある年に課税庁が税率の適用の誤りに気づき，過去に遡って追徴課税をかけてきた」というタイプの事件である．「課税庁への電話で問い合わせたところ，担当者が「これで良い」と返事をしたことが課税庁の正式な回答になるのかどうか」，「他の地区では認められている税率がこの地区だけ厳しく査定されるのは妥当か」など，事件により多少の相違はあるものの，この 8 件は概ね類似した事件である．

事件が 8 件なのに判例が 21 あるのは，同じ事件でも地裁，高裁，最高裁など複数の判例があるからである．この中には納税者が勝訴したことがあるのは 5 事件 7 判例ある．しかし，多くの場合，上級審で逆転敗訴になり，最後に納税者が勝訴したものは 1 事件にすぎない．何が原因でこのような結果になるのかを法的トポスを利用して調べるのがここでの解析の目的である．

3.2 分析方法

まず，課税判例の特徴を記述するためのファクタ階層とその価値判断に使われる法的トポスの階層を用意する．ファクタ階層は事件のタイプに応じてファクタ内容が異なるので，課税判例を識別するためのファクタ階層を用意した．法的トポスの階層は法律分野によって少し構造に変化はあるものの，概ね固定している．ファクタに関して対応する法的トポスにリンクを張る．

次に，個々の判例に関して事件の概要や原告/被告の主張からファクタを抽出しどのファクタとどのファクタが対立しているのかを認識する．さらに，裁判官の判決理由の文言から，どのような法的トポス間の対立なのか，また，その対立関係に関して裁判官はどちらの法的トポスを優先したのかを認識する（図 3）．

この法的トッポスの優先関係がその事件に特有のものなのか，それとも類似事件に関して同じ傾向が見られるのかを調査する．類似事件に関して同じ傾向が見られるのであれば，判決の予測に使える可能性がある．

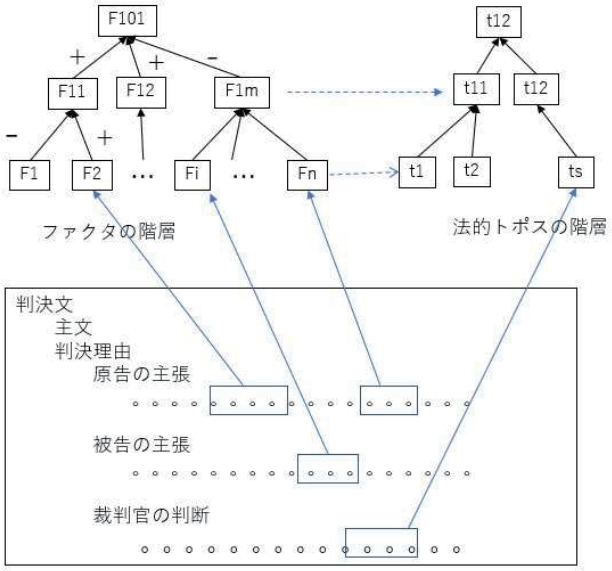


図 3　判例からのファクタと法的トポスの抽出

3.3 分析の例

21 判例においてどのような法的トポスが引用され，どのような優先関係になったか，その結果，納税者が勝訴したのか，課税庁（国）が勝訴したのかをまとめたのが表 1 である．この表でたとえば，判例 1.1 と 1.2 は事件 1 の一審と二審を表している．判例 1.1 で納税者が勝訴し，判例 1.2 で国が勝訴しているので，二審で逆転判決がだたことがわかる．事件 6 で判例 6.4 まであるのは，高裁への差し戻し判決があったためである．

表 1 に出てくる法的トポスは以下のものである.

t3 「例外の厳格性」
t77 「合法性」
t39 「信頼保護」
t63 「法的安定性」
t57 「目的合理性」
t46 「例外の緩和」(極めて不幸な場合は例外を認める)
t47 「明確性」 (法は明確な部分だけが適切)

この表のように, 多くの判例(16 判例)においては t77「合法性」(すなわち, 法令に従って, 課税率の誤りを見つけたらさっさと修正し, 過去の分に追徴課税をすることは何ら問題ない)という価値観と t39「信頼の保護」(すなわち, 過去の課税庁の対応にも問題があり, それにより納税者が誤解したという点もあるので,

表 1 21 判例における法的トポスの優先関係

判例	勝訴者	t77 >t39	t77 <t39	t63 <t39	t47 <t39	t57 >t63	t3∧ t47 <t46
1.1	納				○		
1.2	国	○					
2.1	納			○		○	
2.2	国	○					
2.3	国	○					
3.1	国						○
3.2	国						○
4.1	国	○					○
4.2	国	○					
4.3	国	○					
5.1	納					○	
5.2	国	○					
5.3	納		○				
6.1	納		○				
6.2	納		○				
6.3	国	○					
6.4	国	○					
7.1	国	○					○
8.1	国	○					
8.2	納		○				
8.3	国	○					

追徴課税をする場合はその点を斟酌すべきである)という 2 つの法的トポスの対立ととらえられている. 特に国が逆転勝訴した判例ではすべて, t77 > t39 を理由としている.

ファクタとの関係では,

課税庁の公式見解である / ではない,
納税者に過失がある / ない,
課税額が高額である / ではない,

なるファクタが t77, t39 に関係している.

また, 例外を限定的に見る t3 と例外を緩和する t46 は対立する法的トポスであるが, t47(法が不明確)が問題となった場合は, すべて t46 が優先されている.

4. おわりに

ファクタと法的トポスを用いた判例の解析方法を提案した. 同じ事件でありながら, 一審と二審の間で判決結果が異なる理由が法的トポスの優先関係という形で説明できることを示した. これは従来のファクタだけでの解析では不可能だったことである. また, 類似した判例を比較することにより, 対立する法的トポスのうちどちらが優先される傾向にあるかを調べることにより, 裁判の判決予測ができる可能性があることが示された.

謝辞

本研究は JSPS 科研費(17H06103)および民事紛争処理研究基金の助成を受けたものです.

参考文献

[Ashley 90] Kevin, D, Ashley, Modeling Legal Argument: reasoning with Cases and Hypotheticals, The MIT press, 1990.

[Aleven 97] Vincent, Aleven: Teaching Case Based Argumentation Through a Model and Examples, ph. D. Thesis, University of Pittsburg, 1997.

[Struck 71] G.Struck, Topische Jurisprudenz – Argument und Gemeinplatz in der juristischen Arbeit, Athenaum Verlag, 1971.

[平田 18] 平田勇人, AI による紛争解決手段, 成文堂, 2018.

AI の権利は誰のもの？

Who have the Right of AI?

小野　潔[*1]
Kiyoshi　Ono

[*1] 株式会社インテック　金融クラウドサービス部
Financial Cloud Service Dept.　INTEC Inc.

Law of AI rights protection has not been established. In Developing of business application with AI model, agreement of AI rights between user company and AI vender is required. The contract between AI vender and user company describes the rights of AI including ①AI Program ②Learning Data ③Model Parameters ④Business Application ⑤Know-How to make the model. And it's important to identify the contract including the Transfer Learning/Distillation of the model in Deep Learning. The first step of clarify AI rights is to bring up person who held AI rights through the discussion of data scientist and lawyer.

1.　はじめに

実務の AI 開発では 2016 年頃から AI 組込型の業務アプリケーションが広がっているが、その AI の権利を守る法律が未整備である。AI モデルのノウハウは主にベンチャー企業（以後 AI ベンダー）が有しているため、一般の企業（以後ユーザー企業）は AI ベンダーに AI モデルの開発を委託あるいは、AI ベンダーと IT ベンダーと共同で AI 組込型の業務アプリケーションの開発を行なう。

ところがユーザー企業の法務部も弁護士も急速な AI 理論の発展について行けず、あるいは AI の業務開発を把握していないのが実情であり、今後の AI の権利トラブルが懸念される。

本稿では、AI モデル開発の実務家の観点から、組込型 AI アプリケーションの権利/契約関係を中心に論じる。最後に個人情報をコントロールするプライバシー権利が世界的に強化されてきており、AI モデルが規制されつつあることに触れる。

2.　AI 権利の予備知識

特許権・著作権は人のみが有する権利であり、AI が創造したものには権利が発生しない（補足参照）。この状態を放置すれば近将来、違法行為が発生する恐れがある。例えば、既に AI が音楽を作曲できるアプリケーションは存在するが、AI は人でないので作曲の著作権はない。しかも人による創作物と AI 創作物を見分けることは困難であり、AI による創作物を人による創作物と偽れば、法的保護が受けられる。そして AI は人よりも高い生産性を有するので、AI の進歩がこのまま進めば、AI が作曲家、映像クリエイター、芸術家などの活躍の場を奪うことにもなる。これらの問題は関係者や業界団体が多く、解決の糸口も見出されていない。

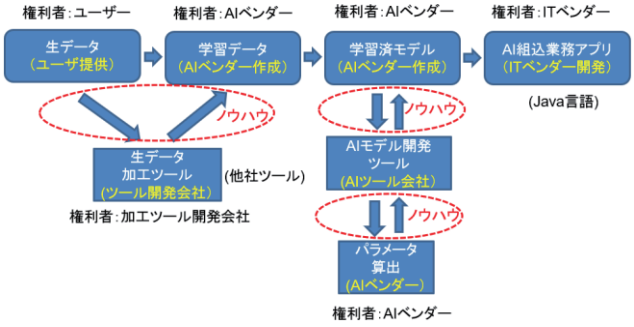
AI 組込型業務アプリケーションの開発の AI の権利・ノウハウは、生データを提供したユーザー企業に発生するだけでなく、同時に学習データに加工した企業やモデルを開発したベンダー側にも発生する。AI モデル開発の成果物はプログラム以外にも、例えば学習データ、パラメーターを含む学習済みモデル、モデルノウハウなど数多く存在する。AI モデルの開発プログラムは、システム開発のプログラムと同様に、著作権法で保護される。しかしそれ以外の成果物は著作権・特許権に該当しないため、日本では AI の権利が完全には守られない。例えば Deep Learning のパラメーターリストは著作権対象に該当しない。

連絡先：小野潔，株式会社インテック金融クラウドサービス部，横浜市神奈川区新浦島町 1-1-25，ono_kiyoshi@intec.co.jp

3.　AI 組込型の業務アプリケーションの開発工程

AI 組込型業務アプリケーションの開発工程を述べる。ユーザー企業から開発を委託された AI ベンダーはユーザー企業の生データを、他社の加工ツールや言語により加工する。次に AI ベンダーは加工データを他社の AI ツールで AI モデルを開発し、モデルパラメータを算出する。開発された AI モデルを IT ベンダーが開発した業務アプリケーションに組込み、AI 組込型業務アプリケーションを開発する。組込方法はクラウド、オンプレミス、API 接続等がある。一般に法務担当者はユーザー企業と AI ベンダーの権利関係を重要視するため、加工ツール、AI ツールベンダー、IT ベンダーの権利を見落とす危険性がある。

（図1　AI 組込型業務アプリケーション開発の工程図）



4.　AI 権利の関係者

組込型 AI 業務アプリケーションの開発では、1社オリジナルで完成することは少なく複数の開発会社が関与する。そこで最初に AI の権利関係者洗い出す。AI 権利の主候補は、①プログラム開発者、②学習用データの提供者、③AI モデルの開発会社であるが、それ以外にも多くの権利関係者が存在する。

（表1　AI の権利関係者の例）

権利関係者	説　明
学習データ提供者	インターネット上に写真を公開した撮影者
学習データの収集者	インターネット上の写真を学習データとして収集した者
学習データの収集プログラムの開発者	インターネット上の写真を収集プログラムの開発者
学習データの加工者	学習データを加工する熟練者
学習データの加工プログラムの開発者	加工プログラム開発者
AIのプログラム開発者	メインのAIのプログラム開発者
AIのパラメーター算出者	該当タスクに適合するAIのパラメーターの算出者
転移/追加学習を行った人	AIに学習させた人
AIコンテンツの流通者	AIの創作した造形物・画像等を流通させた人
AIの創作物	AIは既に初期の創作制作まで至っているが、AIは人でないので権利は何も認められない

5. AI ベンダーとユーザー企業との合意・契約

ここでは AI ベンダーとユーザー企業を例にする。AI 権利を守るには当事者間の合意・契約を締結が有効である。AI ベンダーとユーザー企業との合意・契約では、①AI モデルを作成したプログラム、②学習データ、③パラメーターを含む学習済みモデル、④AI モデルを組み込む業務プログラム、⑤ノウハウについての権利を明確にする。例えば AI ベンダーがユーザー企業の有する学習データをクラウドの AI ツールで AI 組込型の業務アプリケーションを開発する場合を考える。AI モデルは AI 言語で開発、業務アプリケーションは Java 言語で開発、そして Java から AI モデルを呼び出すシステムとする。

①は AI ベンダーが開発した AI モデルプログラムであり、②の学習データの作成は AI ベンダーのノウハウが必要になる。一般にユーザーの提供データをそのまま学習データに使用しない。『賢い AI』を創造するには生データのデータクリーニング、ノイズ除去だけでなく、抽出対象物（文字、猫等）以外の部分をカット、あるいは対象物の縮小、拡大、回転、反転等の画像処理を行う。③は AI モデルの最適パラメーターを指す。Deep Learning のパラメーター数は膨大であり、出力しても意味が取れないが、重要な成果物である。④は IT ベンダーが Java で開発した業務プログラムを指す。⑤の AI ベンダーのノウハウは、学習データの作成方法、AI モデルの作成法、AI モデルのパラメーターの求めるためシミュレーション法、ネットワーク構造など多岐にわたる。AI の権利を明確にするには、これらの事項の帰属を当事者間の合意・契約で定めることである。

6. 転移学習／蒸留の法的課題

Deep Learning の学習済みネットワークの開発には、特有な問題点が発生する。Deep Learning のプログラム開発、学習によるパラメーター設定には、膨大な手間や時間、計算機資源を労する。それに対して、転移学習/蒸留を用いると、元の学習済みネットワークよりも優れた精度や計算速度の向上を有する新しいネットワークが容易にできてしまう。しかも困ったことに、パラメーターやネットワーク構造が変わるため、転移学習/蒸留の立証は実質的にほぼ不可能である。

派生モデルは、学習済みモデルに別教師データを用いて転移学習を行い、生成した異なるモデルである。元モデルと派生モデルは全く違うパラメーターであるため、「派生モデルの生成行為の許諾権」を当事者間の合意・契約で明記する。

蒸留（Distillation）は、学習済みモデルのネットワーク構造をシンプルなネットワークに収縮させる技術である。収縮したネットワークは、学習済みモデルとは全く別の構造のネットワークである。そのため転移学習とは別に、「蒸留行為の許諾権」を合意・契約書に明記すべきである。

注意点は転移学習、蒸留の定義は完全に定まっていないため、合意・契約書に転移学習と蒸留の許諾権を明記しただけでは有効範囲が不十分であり、その定義まで記述した方が良い。

7. 個人情報のコントロール権利

情報化が進んだ現在社会では、個人情報が国家や企業に集積されており、本人の知らないところで個人情報が本人に不利益な使い方をされるおそれがある。そのため個人情報を自分がコントロールする個人情報のコントロール権利（プライバシー権利の一つ）が世界的に強化されており、AI 権利や AI モデルが規制対象になりつつある。

欧州における一般データ保護規則(General Data Protection Regulation）が 2018/5/25 に施行された。その目的は自分の個人情報をコントロールする権利を取り戻し、国際ビジネスの規制環境を簡潔にすることである。違反企業には巨額制裁金(2000 万ユーロ等)が課せられる。問題は IoT 製品を通じて個人データを取得する場合、域外適応や越境移転規制の適用される点である。また機械学習で個人データを学習させる場合、GDPR 第 22 条：『自動化された意思決定 Automated individual decision-making, including profiling』が許容される3条件、（1）契約上の必要性、（2）十分な保護措置、（3）明示的な同意を満たすことが必要となり、AI モデルによる行動ターゲティング広告が規制される。同様に EU 域内の個人を対象とした場合、モニタリングとして域外適用されるため、個人行動から嗜好を自動プロファイリングすることは規制される。対応策は撮影映像内の不要な個人情報（顔、バンパープレート等）を黒塗りにして保存、あるいはその場で AI チップが画像解析等の解を算出し、解のみをクラウドに通信し、取得情報を破棄する方法が考えられる。

8. おわりに

AI 権利は現行法律で完全に守られないので、当事者間の合意・契約を締結が必要である。特に Deep Learning では学習済みモデルの転移学習/蒸留を含めた利用許諾を明記する必要がある。また AI モデルを保護するには、不正競争防止法の「営業秘密」として保護させる条項を契約書に記載することも有効な手段である。最近、個人情報をコントロールするプライバシー権利が世界的に強化されつつあり、今後は留意する必要がある。

AI ベンダーと一般企業による AI モデルの共同開発は花盛りである。開発事業をスタートするにあたり、AI 権利保護を知る弁護士による契約書作成または契約書チェックは必要である。しかし AI の法律部門を有する法律事務所は少なく、AI の知見を有する弁護士でも Deep Learning の転移学習、蒸留になると正しい理解が怪しい。AI の権利を明確にするには、データサイエンティストを含めた当事者と弁護士のディスカッションから AI 権利を有する関係者をすべて洗い出すことが、第一歩である。

（補足）AI の特許取得

AI の創造物は特許を取れないが、日本では AI をビジネスモデル等に組み込むことで AI の特許取得は可能である。例えば AI が生成した多数の創薬を専門家が検証する場合、AI の創薬の過程に検証プロセスを取り入れるビジネスモデルを考案することで、特許取得が可能となる。また AI アルゴリズムもハードウェアとの協働要件を満たせば特許取得の可能性がある。

参考文献

[河野 2018] 河野英仁: AI/IoT 特許入門, 現代産業選書知的財産実務シリーズ, 経済産業調査会, 2018/06.

[小野 2017] 小野潔: 最新 AI の話題, SAS ユーザー総会 2017 論文集 p63-71, SAS Institute Japan, 2017.

[知財 2016] 知的財産戦略本部（首相官邸設置）: 知的財産推進計画 2016, (http://www.kantei.go.jp/jp/singi/titeki2/kettei/chizaikeikaku20160509.pdf), 2016/5(確認 平 30/02)

[知財 28] 知的財産戦略本部検証・評価・企画委員会、次世代知財システム検討委員会：次世代知財システム検討委員会報告書, (http://www.kantei.go.jp/jp/singi/titeki2/tyousakai/kensho_hyoka_kikaku/2016/dai5/sankou1.pdf) 平 28/04(確認 平 30/02).

[特許庁 29] 特許庁: 平成 28 年度人工知能技術を活用した特許行政事務の高度化・効率化実証的研究事業報告書 (https://www.jpo.go.jp/torikumi/t_torikumi/pdf/ai_action_plan/02.pdf), 平 29/03(確認 平 30/02).

General Session | General Session | [GS] J-2 Machine learning

[2H1-J-2] Machine learning: modeling in businesses

Chair:Makoto Kawano Reviewer:Kohei Miyaguchi

Wed. Jun 5, 2019 9:00 AM - 10:20 AM Room H (303+304 Small meeting rooms)

[2H1-J-2-01] Causal Analysis Model of TV Show Attractiveness using Latent Representation Models

○Yuki Nishimura[1], Shimpei Kanazawa[1], Tianxiang Yang[1], Masayuki Goto[1] （1. Waseda University）

9:00 AM - 9:20 AM

[2H1-J-2-02] Customer Classification Through Time Series Order Data Analysis in High-end Barbecue Beef

○Kiyotaka Shin[1], Xueyin Qu[1], Aiko Suge[1], Yasuo Yamashita[1], Hiroshi Takahashi[1] （1. Graduate School of Business Administration, Keio University）

9:20 AM - 9:40 AM

[2H1-J-2-03] An Estimation Model of Exhibits Price for Second-hand Fashion Items Based on Sales History Data

○Izumi Kuwata[1], Tomoya Sugisaki[1], Kenta Mikawa[2], Masayuki Goto[1] （1. Waseda University, 2. Shonan Institute of Technology）

9:40 AM - 10:00 AM

[2H1-J-2-04] Productivity Improvement through Yield Prediction and Machine Combination Optimization

Yoshiaki Suzuki[1], ○Manabu Kano[1], Akira Soga[2], Takeshi Yanagimachi[2], Ryo Murao[2], Masaya Takaki[2] （1. Kyoto University, 2. Toshiba）

10:00 AM - 10:20 AM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

潜在表現モデルに基づくテレビ番組の魅力度要因分析モデル

Causal Analysis Model of TV Show Attractiveness using Latent Representation Models

西村祐樹 * 金澤真平 楊添翔 後藤正幸
Yuki Nishimura Shimpei Kanazawa Tianxiang Yang Masayuki Goto

早稲田大学理工学術院
Faculty of Science and Engineering, Waseda University

Over the past 20 years, TV show viewing rates have been declining due to the increase in the types of media and entertainment. Due to this phenomenon, TV broadcasting companies have higher demands to create more attractive TV shows in order to increase TV show viewing rates. To support TV broadcasting companies create more attractive shows, modeling the relationship between TV show viewing rates, celebrities, and content can be strongly effective. In this paper, we model this complex relationship through the utilization of a neural network and latent representation models such as a stacked autoencoder and latent Dirichlet allocation. We demonstrate that measures to increase TV show viewing rates could be devised by conducting experiments with this model.

1. はじめに

近年，テレビ業界において，情報収集や娯楽のためにテレビ番組を選択する人が相対的に減少する “テレビ離れ”が問題視されている．テレビ離れによる視聴率の低下は各放送局の収入の減少に繋がるため，各放送局では，視聴者にとって魅力的な番組を制作し，テレビ視聴を促進することが極めて重要となっている．これに伴い，各放送局は魅力的な番組制作を考える必要がある．一般には，テレビ番組の魅力度は，その視聴率によって測ることができる．しかし，各局が視聴率の向上を目指して魅力的な番組を作る努力をしている中で，対象となる番組の内容だけでなく，裏番組のラインナップやそれぞれの出演者など，様々な要因が視聴率に影響を与えると考えられる．そこで，魅力的なテレビ番組を制作するために，出演者，番組内容，裏番組（対象番組と同日同時刻に放送されている番組）といった要因が視聴率に与えるインパクトを評価できるモデルがあると大変有用である．そして，このモデルを有効活用し，様々な魅力度要因の影響を分析することで，新たな番組制作に役立てることが期待できる．

そこで本研究では，インターネット上で取得可能な各番組の「出演者情報」と「番組情報」のテキストデータ，並びに同時間帯における全番組の「視聴率」データを用い，これらの関係性を表現する分析モデルを提案する．その際，これらの要因間の非線形な関係性をモデルに取り込みつつ，過学習を防ぐため，高次元の「出演者情報」は積層自己符号化器 (Stacked Autoencoder，以下，SAE) [Hinton 06] を適用した次元圧縮を，テキストデータである「番組情報」は単語ベクトル化の後に潜在的ディリクレ配分法 (Latent Dirichlet Allocation，以下，LDA) [Blei 03] を適用して低次元トピックベクトル化を行う．そして，全局の番組に対するこれらの情報を入力，視聴率を基準化した視聴割合を出力として順伝播型ニューラルネットワーク (Feed-Forward Neural Network，以下，FNN) [Rumelhart 86] モデルを学習させ，テレビ番組の魅力度要因分析モデルを構築する．

本研究では，実データを用いてモデルを構築し，提案モデルの予測性能について正当性を検証する．また，得られた FNN モデルを用い,「出演者情報」,「番組情報」を様々に変化させた場合のインパクトを評価することで，より適切な出演者や番組内容の決定といった，魅力度向上のための施策考案が可能であることを示す．

連絡先: 西村祐樹，早稲田大学創造理工学研究科経営システム工学専攻，yukibaseball@moegi.waseda.jp

2. 提案モデル

本研究では，非線形な関係性を表現できる FNN をベースとして，テレビ番組の魅力度と番組構成要素・裏番組などの影響要因間の複雑な関係性をモデル化する．そして，得られたモデルを用いて，魅力度を向上させる施策を検討する．

(1) 対象データ

提案モデルでは，各番組の出演者情報，番組情報，視聴率情報を扱う．まず，各番組の出演者情報は，出演者の出演の有無を 1,0 のダミー変数で表しているベクトルである．また，番組情報は，インターネット上に公開されているテレビ番組内容を記述したテキストデータである．これらの番組情報は，形態素解析によって得られた単語を用いて，出現頻度でベクトル化した単語頻度ベクトルに変換して用いる．さらに，各番組の視聴率情報は，各番組の 1 分ごとの視聴率からなるデータである．

(2) 目的変数

テレビ番組の魅力度を表す指標として，一般的な視聴率が広く受け入れられやすいと考えられる．しかし，各番組の視聴率は，裏番組に多大な影響を受けるため，各番組の視聴率をその番組の特徴量のみから予測するモデルの構築は困難である．そこで，同日同時刻に放送されている全番組の特徴量からそれらの番組の視聴率を同時に予測することで，裏番組を考慮したモデルの構築を行う．さらに本研究では，曜日や時間帯などの，全番組に共通する要因の影響を除去するため，同日同時刻の各番組の視聴率をそれらの番組の視聴率の和で除した “視聴割合”を目的変数として用いる．これにより，各番組の固有な構成要素が与える魅力度への影響に着目することができる．すなわち，各番組の視聴割合を魅力度と定義し，同日同時刻に放送されている番組の視聴割合を連結させたベクトルを FNN の目的変数として用いる．

(3) 説明変数

本研究では，出演者情報と番組情報が各番組固有のテレビ番組の魅力度に影響する要因であると考える．しかし，出演者情報や単語頻度ベクトルは高次元でスパースなデータである．故に，そのまま FNN の入力とすると，過学習によりモデル化が上手く行えない可能性がある．この点を考慮し，本研究では

これらのデータに対し，予め次元圧縮を行うことを考える．

出演者情報に対しては，非線形次元圧縮手法を適用する．代表的な手法としてカーネル主成分分析があるが，カーネル主成分分析ではグラム行列の固有値計算を行うため，計算コストがかかってしまう．そこで，本研究では出演者情報に対し，非線形データの効率的な圧縮が可能な SAE を適用し，N_C 次元の圧縮表現（以下，出演者ベクトル）を獲得する．イメージを図 1 に示す．

一方，単語頻度ベクトルに対しても SAE を適用することが考えられる．しかし，テキストデータに対しては，単語の生起が確率的な揺らぎを持っていると仮定する統計モデルの方が当てはまりが良いことが様々な研究 [Liberman 91] より明らかになっている．そこで，本研究では単語頻度ベクトルに対し，統計モデルとして広く用いられる LDA を適用し，N_T 次元の圧縮表現 (以下，トピックベクトル) を獲得する．LDA による次元圧縮のイメージを図 2 に示す．

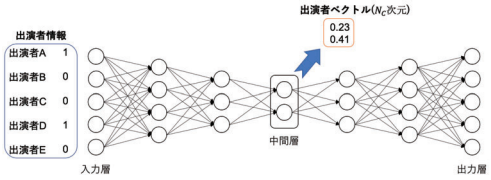


図 1: SAE による圧縮表現獲得のイメージ

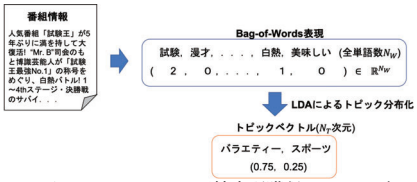


図 2: LDA による圧縮表現獲得のイメージ

(4) FNN モデルの構築

前述の説明変数と目的変数を用いて FNN の学習を行う．ただし，出演者ベクトルとトピックベクトルは，FNN の学習でどちらかの影響要因だけが重視されないよう，同じ次元数 ($N_C = N_T$) に圧縮する．そして，各番組に関する出演者ベクトルとトピックベクトルを連結した $(N_C + N_T)$ 次元のベクトルを各番組固有の特徴を表す番組表現ベクトルと定義する．さらに，同日同時刻に放送された各番組の番組表現ベクトルを連結させた $(N_C + N_T) \times$ (放送局数) 次元のベクトルを FNN の説明変数として用いる．これにより，裏番組を考慮した魅力度要因分析モデルを実現する．

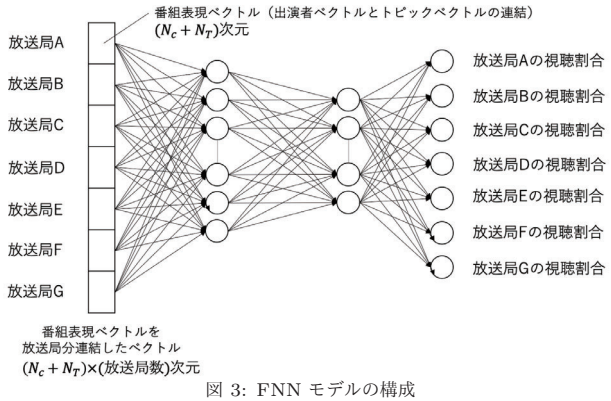


図 3: FNN モデルの構成

(5) 魅力度要因分析

学習済み FNN モデルを用いることで魅力度要因分析を行う．具体的には，番組表現ベクトルや出演者ベクトルなどの説明変数を様々に変化させ，視聴割合への影響を観察する．

[提案モデルの構築手順]

STEP1： SAE を用いた出演者情報の次元圧縮

各テレビ番組の出演者情報を入力とした SAE の学習を行う．学習済みの SAE に対象の出演者情報を入力することで，圧縮された出演者ベクトルを獲得する．

STEP2： LDA を用いた番組情報の次元圧縮

各テレビ番組の番組情報 (テキストデータ) から単語頻度ベクトルを作成し，それらを LDA の入力とすることで，テレビ番組内容を考慮したトピックベクトルを獲得する．

STEP3： FNN の学習

STEP1~2 で獲得した圧縮表現を入力，視聴割合を出力として，FNN を学習する．

3. 実データ分析

3.1 分析条件

経営科学系研究部会連合協議会主催，平成 30 年度データ解析コンペティションで提供された関東 1 都 6 県のインターネット利用者約 5,000 人を対象としたテレビ視聴データ (株式会社ビデオリサーチの VR CUBIC データ) 及び，Web 上より入手した出演者データと番組情報データを提案モデルに適用する．対象データの期間は 2017 年 4 月 3 日から 2018 年 4 月 1 日，データ件数は 524,160 件 (対象データ期間の分数と一致)，出演者数は 9,562 名，分析対象のテレビ番組は主要放送局 7 社 (日本テレビ，TBS，フジテレビ，テレビ朝日，テレビ東京，NHK 総合，NHK E テレ) が放送している番組とする．また，事前実験により，SAE は 7 層，ユニット数は入力層から順に 9,562，3,000，500，30，500，3,000，9,562 とし，LDA のトピック数は 30 とする．FNN のユニット数は入力層から順に 420，300，100，7 とする．この時，SAE より獲得する 30 次元の出演者ベクトル及び LDA より獲得する 30 次元のトピックベクトルを連結させた 60 次元の番組表現ベクトルを 7 社分連結させた 420 次元のベクトルが FNN の入力となる．また，出演者情報や番組情報が存在しない番組に対しては，その番組表現ベクトルを **0** ベクトルとする．さらに，SAE と FNN の学習率の調整に Adam [Kingma 14] を適用した．

3.2 分析結果と考察

(1) 提案モデルの正当性

まず，学習データ：テストデータをランダムに 8 : 2 に分割して学習を行った．SAE，LDA，FNN それぞれの性能を示す評価指標とその値を表 1 に示す．

表 1: 各モデルの学習後の性能評価値

モデル	学習データ	テストデータ	評価指標
SAE	0.0099	0.0042	交差エントロピー
LDA	0.4713	1.0155	perplexity ($\times 10^3$)
FNN	0.00122	0.00124	平均二乗誤差

表 1 の結果より，提案モデルにおいてテストデータに対しても頑健な予測モデルが構築されていることがわかる．

(2) LDA で推定された潜在的なトピックの解釈

LDA で推定した番組トピックへの解釈を表 2 に示す．

表 2: LDA により推定したトピックの解釈

番号	トピック	番号	トピック
1	散歩	16	世界観光
2	時代劇	17	バラエティー（お笑い）
3	料理	18	政治
4	バラエティー（情報）	19	出演者
5	教育	20	アイドル・男性タレント
6	芸術	21	レジャー
7	小学生向け	22	母親向け
8	犯罪・サスペンス	23	製作者
9	ニュース（天気）	24	生物
10	ニュース（総合）	25	歌・大学
11	バラエティー（クイズ）	26	国内観光
12	アイドル・女性タレント	27	ニュース（社会）
13	自然	28	バラエティー（ドキュメンタリー）
14	挑戦・オリンピック	29	乳幼児向け
15	医療	30	道徳・24 時間テレビ

表 2 のように，各テレビ番組の潜在的なトピックに対し，それぞれ異なった解釈を与えることができる．また，一般的な番組のジャンルよりも詳細なカテゴリを推定できていることがわかる．

(3) 提案モデルを用いた分析

学習済みモデルを用いて，出演者の追加とテレビ番組を変化させた時の視聴割合の変動を分析する．ここでは，事例としてテレビ朝日で 2017 年 4 月 9 日 (日曜日) の 7 時 45 分に放送されていた「宇宙戦隊キュウレンジャー」(以下，対象番組 1) とフジテレビで 2017 年 6 月 8 日の 21 時 15 分に放送されていた「とんねるずのみなさんのおかげでした」(以下，対象番組 2) を取り上げる．まず，対象番組 1 の分析結果について述べる．

[対象番組 1「宇宙戦隊キュウレンジャー」の分析]

対象番組 1 における出演者を表 3 に，上位 5 つの所属トピックを表 4 に示す．

表 3: 出演者一覧

出演者
小野友樹
山崎大輝
岐洲匠
木村昂
榊原徹士
毛利亘宏
福沢博文
M・A・O

表 4: 対象番組 1 の上位 5 所属トピック

順位	トピック
1	出演者
2	挑戦・オリンピック
3	バラエティー（ドキュメンタリー）
4	犯罪・サスペンス
5	医療

まず，学習後の FNN を用いて，対象番組 1 に出演者を 1 人追加した際のインパクトを評価したところ，表 5 に示す出演者を追加した場合に対象番組の予測視聴割合が上昇するという推定結果が得られた．ただし，対象時刻に 7 放送局が放送した番組の視聴率の総和に，予測視聴割合を乗じた値を予測視聴率とする．

表 5: 対象番組 1 の予測視聴割合を増加させる追加出演者上位 5 名

出演者	予測視聴割合	増加視聴率
長谷川初範	12.73%	+0.08%
鈴木翼	12.73%	+0.08%
深浦加奈子	12.73%	+0.08%
白石隼也	12.73%	+0.08%
市川勇	12.73%	+0.08%
追加なし	12.14%	-

対象番組 1 の予測視聴割合を増加させる出演者 (表 5) には，同じヒーローものである「ウルトラマン 80」で主人公を演じた「長谷川初範」や,「仮面ライダーウィザード」で主人公を演じた「白石隼也」が現れた．このことから，提案モデルは出演者と番組トピックの相性を考慮できていると考えられる．

一方，対象番組 1 を同放送局の他番組と置き換えたところ，表 6 に示す番組で予測視聴割合が上昇する結果となった．予測視聴割合を上昇させた上位 5 つの番組の代表的なトピックを表 7，裏番組とそれらの代表的なトピックを表 8 に示す．

表 6: 対象番組 1 の予測視聴割合を増加させる入れ替え番組上位 5 件

番組	予測視聴割合	増加視聴率
「報道ステーション」	29.23%	+3.85%
「くりぃむクイズミラクル 9」	28.06%	+3.70%
「相棒」	27.80%	+3.66%
「路線バスで寄り道の旅」	27.22%	+3.59%
「帰れまサンデー」	27.21%	+3.59%

表 7: 対象番組 1 の入れ替え番組に含まれる上位 5 所属トピック

番組名	「報道ステーション」
トピック 1	バラエティ(情報)
トピック 2	政治
トピック 3	ニュース (社会)
トピック 4	犯罪・サスペンス
トピック 5	ニュース (総合)
番組名	「くりぃむクイズミラクル 9」
トピック 1	バラエティー (クイズ)
トピック 2	犯罪・サスペンス
トピック 3	ニュース (社会)
トピック 4	ニュース (総合)
トピック 5	バラエティー (お笑い)
番組名	「相棒」
トピック 1	犯罪・サスペンス
トピック 2	母親向け
トピック 3	散歩
トピック 4	教育
トピック 5	挑戦・オリンピック
番組名	「路線バスで寄り道の旅」
トピック 1	国内観光
トピック 2	レジャー
トピック 3	散歩
トピック 4	教育
トピック 5	バラエティー (クイズ)
番組名	「帰れまサンデー」
トピック 1	国内観光
トピック 2	犯罪・サスペンス
トピック 3	バラエティー (クイズ)
トピック 4	散歩
トピック 5	バラエティー (ドキュメンタリー)

表 8: 対象番組 1 の裏番組とそれらに含まれる上位 5 トピック

放送局	日本テレビ	TBS
番組名	「シューイチ」	取得不可
トピック 1	バラエティー (お笑い)	-
トピック 2	バラエティー (クイズ)	-
トピック 3	挑戦・オリンピック	-
トピック 4	国内観光	-
トピック 5	小学生向け	-
放送局	フジテレビ	テレビ東京
番組名	「新報道２００１」	「ディズニー・サンデーアバローのプリンセスエレナ」
トピック 1	政治	生物
トピック 2	挑戦・オリンピック	挑戦・オリンピック
トピック 3	犯罪・サスペンス	犯罪・サスペンス
トピック 4	自然	医療
トピック 5	ニュース (社会)	芸術
放送局	NHK 総合	NHK E テレ
番組名	「ニュース・気象情報」	みいつけた!さん
トピック 1	-	小学生向け
トピック 2	-	乳幼児向け
トピック 3	-	バラエティー (クイズ)
トピック 4	-	バラエティー (情報)
トピック 5	-	医療

対象番組 1 の予測視聴割合を増加させる入れ替え番組 (表 6) には，国内観光，母親向け，バラエティー (クイズ)，レジャー，政治といったトピックが含まれている．また，裏番組 (表 8) には，バラエティー (クイズ)，小学生向け，挑戦・オリンピック，犯罪サスペンスといったトピックが含まれている．そのため，入れ替え番組と裏番組に共に含まれているトピックであるバラエティー (クイズ) は対象時間帯において人気なトピックであると考えられる．一方，入れ替え番組に含まれているものの，裏番組に含まれていないトピックである国内観光，母親向け，レジャー，政治は視聴者の潜在的なニーズを捉えた新たな可能性を持つトピックであると考えられる．

次に，対象番組 2「とんねるずのみなさんのおかげでした」に関する分析を行う．

[対象番組 2「とんねるずのみなさんのおかげでした」の分析]

対象番組 2 における出演者を表 9 に，上位 5 つの所属トイックを表 10 に示す．

表 9: 出演者一覧

出演者
とんねるず
カミナリ
マッコイ斉藤
小倉優子
小木博明

表 10: 対象番組 2 の上位 5 所属トピック

順位	トピック
1	挑戦・オリンピック
2	世界観光
3	バラエティー（ドキュメント）
4	バラエティー（お笑い）
5	道徳・24 時間テレビ

学習後の FNN を用いて，対象番組 2 に出演者を 1 人追加した際のインパクトを評価したところ，表 11 に示す出演者を追加した場合に対象番組の予測視聴割合が上昇するという推定結果が得られた．

表 11: 対象番組の予測視聴割合を増加させる追加出演者上位 5 名

出演者	予測視聴割合	増加視聴率
国分太一	18.01%	0.06%
渡部建	17.94%	0.05%
阿部渉	17.93%	0.05%
船越英一郎	17.92%	0.04%
森富美	17.88%	0.04%
追加なし	17.69%	-

予測視聴割合を増加させる追加出演者（表 11）には，対象番組のようなバラエティー番組に出演している「国分太一」や「渡部建」といったタレントが含まれており，先の事例に対す

る分析と同様に，提案モデルは出演者と番組トピックの相性を考慮できていると考えられる．

一方，対象番組を同放送局の他番組と置き換えたところ，表 12 に示す番組で予測視聴割合が上昇する結果となった．予測視聴割合を上昇させた上位 5 番組の代表的なトピックを表 13，裏番組とそれらの代表的なトピックを表 14 に示す．

表 12: 対象番組 2 の予測視聴割合を増加させる入れ替え番組上位 5 件

番組	予測視聴割合	増加視聴率
「村上信五とスポーツの神様たち」	28.50%	2.07%
「ROAD TO EDEN」	28.02%	1.97%
「めちゃ× 2 イケてるッ！記録より記憶に残る名作ベスト１０」	26.72%	1.73%
「ワイドナショー」	26.61%	1.70%
「文書改ざんキーマン佐川前長官を証人喚問みんなのニュース SP」	26.11%	1.61%

表 13: 対象番組 2 の入れ替え番組に含まれる上位 5 所属トピック

番組名	「村上信五とスポーツの神様たち」
トピック 1	時代劇
トピック 2	バラエティー (クイズ)
トピック 3	国内観光
トピック 4	芸術
トピック 5	挑戦・オリンピック
番組名	「ROAD TO EDEN」
トピック 1	時代劇
トピック 2	犯罪・サスペンス
トピック 3	バラエティー (クイズ)
トピック 4	料理
トピック 5	医療
番組名	「めちゃ× 2 イケてるッ！記録より記憶に残る名作ベスト１０」(2017-03-31 放送)
トピック 1	バラエティー (お笑い)
トピック 2	バラエティー (クイズ)
トピック 3	自然
トピック 4	ニュース (天気)
トピック 5	バラエティー (情報)
番組名	「ワイドナショー」
トピック 1	ニュース (天気)
トピック 2	犯罪・サスペンス
トピック 3	挑戦・オリンピック
トピック 4	バラエティー (クイズ)
トピック 5	ニュース (総合)
番組名	「文書改ざんキーマン佐川前長官を証人喚問みんなのニュース SP」
トピック 1	自然
トピック 2	小学生向け
トピック 3	国内観光
トピック 4	医療
トピック 5	ニュース (総合)

表 14: 対象番組 2 の裏番組とそれらに含まれる上位 5 トピック

放送局	日本テレビ	TBS
番組名	「秘密のケンミンＳＨＯＷ」	「ニンゲン観察バラエティモニタリング」
トピック 1	国内観光	挑戦・オリンピック
トピック 2	バラエティー (お笑い)	バラエティー (お笑い)
トピック 3	バラエティー (クイズ)	小学生向け
トピック 4	アイドル・女性タレント	母親向け
トピック 5	バラエティー (ドキュメンタリー)	道徳・24 時間テレビ
放送局	テレビ朝日	テレビ東京
番組名	「木曜ドラマ・緊急取調室」	「和風総本家」
トピック 1	犯罪・サスペンス	料理
トピック 2	挑戦・オリンピック	国内観光
トピック 3	散歩	散歩
トピック 4	自然	挑戦・オリンピック
トピック 5	道徳・24 時間テレビ	ニュース (社会)
放送局	NHK 総合	NHK E テレ
番組名	「ニュースウオッチ９」	-
トピック 1	バラエティー (情報)	-
トピック 2	犯罪・サスペンス	-
トピック 3	母親向け	-
トピック 4	ニュース (天気)	-
トピック 5	ニュース (社会)	-

対象番組 2 の視聴割合を増加させる入れ替え番組（表 12）には，バラエティー (クイズ)，バラエティー (お笑い)，挑戦・オリンピック，犯罪・サスペンスといったように，裏番組に現れるトピック (表 14) が含まれている．一方，時代劇，芸術，医療，料理といった，裏番組に現れないトピックが視聴割合を増加させる番組に含まれている．このように，入れ替え番組のトピックには，裏番組に含まれているトピックと裏番組に含まれていないトピックが混在している．裏番組の内容との相性や出演者の制約を考慮し，制作現場のノウハウと合わせて，様々な可能性を検討することができる．提案モデルは，対象時間帯において視聴者に支持されているトピックや，新しい可能性を持つトピックの発見に活用できると考えられる．

[対象番組 1 と 2 の分析結果まとめ]

提案モデルを活用して，対象番組に対し，出演者の追加と番組の入れ替えのシミュレーションを行った．これにより，出演者と番組との相性や，入れ替え番組と裏番組との相性の分析が可能になり，対象番組 1 と 2 それぞれに対し番組の魅力度を増加させる施策を考案することができた．さらに，裏番組と入れ替え番組の関係を分析することで，対象時間帯での人気・不人気トピックを把握し，対象番組の魅力度を向上させるようなトピックの把握，及び番組編成の施策を考案した．

このように，提案モデルを活用することで様々な視点からテレビ番組の魅力度を向上させるための施策を検討可能である．以上のように，提案モデルは，テレビ番組の編成や改善を検討するための分析モデルとして有効である．

4. まとめと今後の課題

本研究では，出演者情報を SAE で，番組内容のテキストデータを LDA で圧縮して低次元表現し，それらを用いて裏番組を考慮した視聴割合を予測する FNN モデルを提案した．また，提案モデルを用いて，実際に 2 つの番組に対し，出演者の追加や番組入れ替えを行なった際の効果を分析した．これにより，各番組に対し，出演者の追加，及び裏番組を考慮した上で視聴率を増加させる放送番組の選択など，魅力的な番組制作に繋がるような施策を考案することができた．さらに，出演者の入れ替えや削減，トピックベクトルの変化，裏番組の入れ替えなどを行なった分析も行えるため，様々な観点から魅力的な番組制作を行うための施策を考案することが可能であると考えられる．

一方，提案モデルの実応用を考えた場合，本研究で考案した施策の効果を実際に検証する必要がある．しかし，本研究の分析結果より，追加出演者や入れ替え番組に，番組の内容と相性が良い人気タレントや，人気ジャンルが含まれており，直感的な解釈とのずれは小さいと考えられる．つまり，提案モデルは視聴率とその影響要因の関係性を上手く捉えており，魅力的な番組制作に活用できると考えられる．

今後の課題として，別条件での視聴割合の変動分析，視聴割合を最大化させる出演者ベクトルとトピックベクトルの組み合わせの探索，流行要因の取り入れ，対象放送局数の追加，ハイパーパラメータの適切な調整などが挙げられる．

参考文献

[Hinton 06] Hinton, G., Salakhutdinov, R.: Reducing the dimensionality of data with neural networks, *Science*, vol. 313, no. 5786, pp. 504 - 507 (2006)

[Blei 03] Blei, D., Ng, A., Jordan, M.: Latent Dirichlet Allocation, *The Journal of Machine Learning Research*, vol.3, pp.993-1022 (2003)

[Rumelhart 86] Rumelhart, D., Hinton, G., Williams, R.: Learning internal representations by error propagation, *Parallel Distributed Processing*, vol.1, ch.8, pp.318-362 (1986)

[Liberman 91] Liberman, M.: The Trend towards Statistical Models in Natural Language Processing, Natural Language and Speech, *ESPRIT Basic Research Series*, pp. 1-7 (1991)

[Kingma 14] Kingma, D.P., Ba, J.: Adam: A Method for Stochastic Optimization, arXiv:1412.6980 [cs.LG] (2014)

[Agarap 18] Agarap, A.F.: Deep Learning using Rectified Linear Units(ReLU), arXiv:1803.08375 [cs.NE] (2018)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

高級焼肉店における時系列注文データ分析による顧客分類

Customer Classification Through Time Series Order Data Analysis in High-end Barbecue Beef Restaurants

辛　郷孝[*1]　瞿 雪吟[*1]　菅　愛子[*1]　山下　泰央[*1]　高橋　大志[*1]

Kiyotaka Shin　Xueyin Qu　Aiko Suge　Yasuo Yamashita　Hiroshi Takahashi

[*1] 慶應義塾大学 大学院経営管理研究科

Graduate School of Business Administration, Keio University

Abstract: The purpose of this research aimed at the improvement of management skills using POS data of restaurant service industry, focusing on customer configuration which is the most important factor in restaurant management. In addition to customer configuration, this analysis takes the time series order data into account which leads to the possibility of better classification. By obtaining more sophisticated knowledge of customer configuration, more value-added services and more efficient management will be expected.

1. はじめに

日本における外食産業の市場規模は、1 人当たりの外食支出額の増加、訪日外国人の増加、法人交際費の増加傾向などにより、2017 年時点で約 25 兆円、労働者人口約 480 万人となっており、2 年連続で微増している巨大な市場である。しかし、日本の外食産業は、労働生産性が低い上、慢性的な人手不足で人材確保に苦労している[星野智洋 18][原田奈弥 16]。昨今は、食材や人件費の高騰で、売上が微増であっても利益は下がるという傾向も見える。一方で、数か月先まで予約が埋まっており、社員教育にも熱心で、顧客の支持を得て利益を上げている飲食店も存在する。本研究では、顧客の支持を得て利益を上げている飲食店の一例として、これまで明らかにされてこなかった高級飲食店での注文データを分析し、そこに集まる顧客はどのような特徴があるのかを分析した。

本研究では飲食店経営において最も大切な要素である顧客構成に焦点を当て分析を行う[石垣司 11]。顧客構成に関する、より精緻な知見を得ることで、より付加価値の高いサービスの提供、より効率的な経営の遂行などの効果が期待される。

次節において目的について触れたのち、データ、分析方法について説明する。5.は分析結果、6.はまとめである。

2. 目的

本研究では、高級焼肉店における注文データから顧客の特徴を明らかにすることを目的とする。 労働生産性向上のためには、1テーブルごとの客単価向上が有効と考えられるが、顧客の特徴の把握は、生産性向上に貢献すると期待される。

分析においては高級焼肉店の POS データを用いた。高級焼肉店を利用する顧客が、入店後どのような購買行動を行っているのか、時系列での注文データ分析を通じ、注文パターンを明らかにすることで、顧客の分類を試みる[星野綾子 18]。飲食店における従来の顧客分類としては、来店人数や、男女別の比率等を用いる方法が挙げられる。本分析は、それらの分類に加え、新たに、注文データを考慮に加えよりきめ細かい分類の可能性を探索するものである。

高級焼肉店における注文データを用い顧客分類を行うことで、レコメンドによる客単価向上や注文パターンの時系列トレンドのモニタリングを行える可能性がある[神嶌敏弘 07]。更に、高価格単価の購買行動を分析することで、外食産業の付加価値向上への貢献も期待される。本研究は、飲食店産業における新たな分析手法の一つを提示するものである。

3. データ

POS データについては該当飲食店の共同研究の了承の元、SoftTheater 社から取得した。本研究は、2017 年 8 月 1 日-2018 年 7 月 31 日までの 361 日間において、高級焼肉店 1 店舗の POS データから 1 会計ごとの注文データを抽出し分析を行った。**表 1** は上記 361 日のデータである。17,855 件の会計ごとのデータであり、160,125 件の注文データである。

商品数は、520 商品であり、中分類として 62 分類に分かれている。POS データは、11 時から 23 時までの 12 時間のデータであるが、今回は、ディナー時間の 17 時から 23 時までの 12 時間を対象とした。

表 1：POS データ件数

会計件数（1 テーブルごと）	17, 855 件
注文件数（1 注文ごと）	160, 125 件

連絡先：慶應義塾大学 大学院経営管理研究科
〒223-8526 横浜市港北区日吉 4-1-1
E-mail: k-shin@keio.jp

4. 分析方法

17 時以降の顧客数 2 人組の注文を対象に、注文開始時間から 10 分ごとの注文データ分析を行った。顧客の購買行動を商品中分類(62 分類)の時系列注文データで階層クラスター分析を行い、注文パターンを分類した。**表 2** は、7つのクラスターのデータ件数である。

表 2:7 つのクラスターのデータ数

クラスター	データ数	男 1 女1	女 2	男 2
1	37	25	9	3
2	313	191	75	47
3	1,796	1,346	216	234
4	239	167	44	28
5	80	59	15	6
6	34	25	7	2
7	27	19	6	2
合計	2,526	1,832	372	322

5. 分析結果

17 時以降の 2 人組の顧客を分析対象とし、入店から 10 分単位の注文パターンを分析した。階層クラスター分析を行った結果、7つの注文パターンに分けられた。**図1、図2** は、その結果の一部である。7つの顧客分類のうち 2 つを示した。

図 1 のクラスター3 は、入店からビールの注文割合が多い。**図 2** のクラスター2 は、最初はビールの注文が多いが、2 杯目は、チューハイ、ハイボール、梅酒、焼酎に分かれる。これらの7つの顧客分類により、どのような注文パターンに分けられるのか可視化することができた。

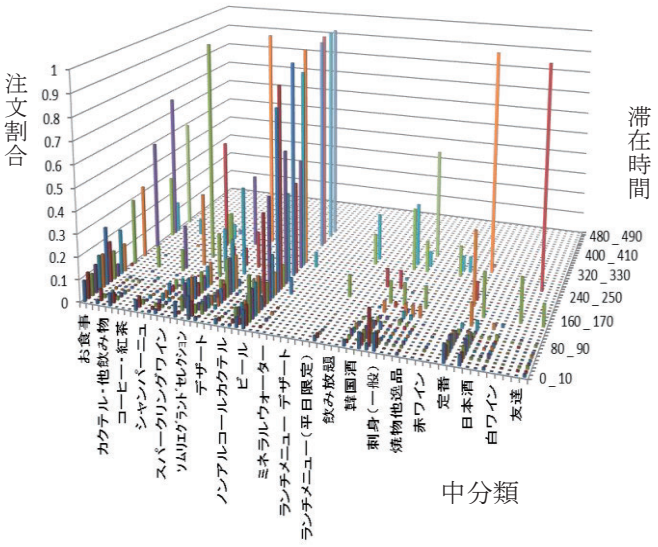


図 1:クラスター分析による注文パターン可視化 1
(クラスター3)

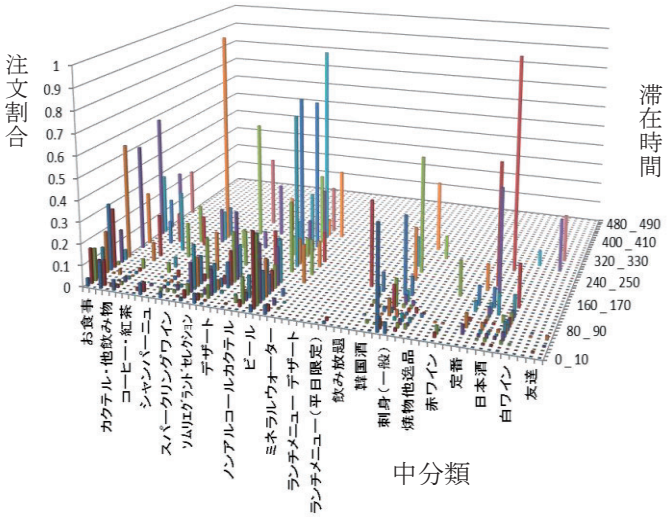


図 2:クラスター分析による注文パターン可視化 2
(クラスター2)

6.まとめ

本研究では、高級焼肉店の POS データから顧客の注文データを分析し、時系列注文データ分析を通じた顧客分類を試みた。従来の顧客分類としては、来店人数や、男女別の比率等が挙げらるが、本分析は、注文パターンによる分析を通じ、従来の手法よりも、より詳細な顧客分類ができる可能性を示した。これらの結果は、データ分析を通じより効率的な飲食店経営に貢献できることを示唆する結果である。本研究では、基本的な手法を通じた分析であり、より詳細な分析は今後の課題に挙げられる。また、本研究は、顧客数 2 人組に焦点を当て分析を行ったが、2 人組以外の顧客構成の分析も今後の課題として挙げられる。更に、POS、発注データ分析を通じた日次経営指標の作成を通じた経営の効率化手法の提案、およびキャッシュレスなどのフィンテック領域における応用との連携手法の提案などは、今後の課題として挙げられる。

参考文献

[星野智洋 2018]谷﨑隆士,新村猛,竹中毅:機械学習を用いた飲食店運営の効率化へのアプローチ,人工知能学会 32 回,JSAI2018,2018

[原田奈弥 2016]山下和也,本村陽一:ID 付 POS データによる購買行動の季節変化の分析,SIG-SAI,27(7),1-7,2016-1

[石垣司 2011]竹中毅, 本村陽一:日常購買行動に関する大規模データの融合による顧客行動予測システム, 人工知能学会論文誌, 26(6)D,2011

[星野綾子 2018]細見格:句構造解析とクラスタリングを用いた会話履歴の要約,人工知能学会 32 回, JSAI2018,2018

[神嶌敏弘 2007]推薦システムのアルゴリズム,人工知能学会誌 22(6),2007

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

販売履歴データに基づく中古ファッションアイテムの出品価格推定モデルの提案

An Estimation Model of Exhibits Price for Second-hand Fashion Items Based on Sales History Data

桑田　和 *1　杉崎　智哉 *1　三川　健太 *2　後藤　正幸 *1
Izumi Kuwata　Tomoya Sugisaki　Kenta Mikawa　Masayuki Goto

*1早稲田大学 Waseda University　*2湘南工科大学 Shonan Institute of Technology

In this study, we focus on the second-hand fashion EC site. In this site, the trade-in price is determined according to the exhibition price so that the decision of the appropriate exhibition price is strongly important. However, it is difficult to determine the best exhibition price because there are two types of items such as the items purchased with no discount and that purchased with discount. Therefore, we proposed a method to estimate the maximum exhibition price without discount for each item. In our proposed method, at first, we construct a binary classifier which classifies the item which is purchased with a discount price or not. In addition, we estimate the best price with changing the exhibition price of each item little by little. The effectiveness of our proposed method is clarified using real purchasing history data of this site.

1. 研究背景・目的

本研究では，ユーザからアイテムを買い取り，中古品として再販売する事業を展開する某ファッション EC サイト (以下，サイト A) における出品価格の決定問題を対象とする．出品価格とはアイテムを EC サイト上で出品する際の価格であり，これと連動して買取価格も決まるため，その最適化はビジネス上大変重要な課題の 1 つとなっている．

サイト A では，アイテムの売れ残りを防ぐため，出品から一定期間経過したアイテムの価格を自動的に値下げする仕組みを採用している．収益性の観点からは，可能な限り値下げをせずに販売することが望ましいが，購入の意思決定はユーザ側にあるため，ブランドや季節性といった多様性の高いファッションアイテムは実際に出品するまで購入結果が予想できない場合も多い．一方，サイト A では過去に出品したアイテムの出品価格や購入価格といった販売履歴データが膨大に蓄積されており，それらのデータの分析が各アイテムに対する最適な出品価格の決定につながると考えられる．

しかし，サイト A に蓄積されている販売履歴データには，出品後間もなく出品価格のまま購入されたアイテムと，出品から購入されるまでの期間 (以下，販売期間) が長くなったために，出品価格から値下げされて購入されたアイテムの 2 通りの販売結果が混在している．前者は出品価格を高く設定しても出品価格のまま購入された可能性が，後者は出品価格を低く設定することで出品価格のまま購入された可能性がある．そのため，購入された時点での販売価格がアイテムに対する最適な価格とは限らない．

そこで本研究では，アイテムの出品価格のみを変化させた場合の販売結果を予測し，その結果からアイテムの値下がりが起こらない出品価格の最大値を推定する手法を提案する．提案手法ではまず，過去の販売履歴データによる機械学習モデルを用いて，アイテムの出品価格をもとに，出品価格で購入されるか，値下げされて購入されるかの 2 通りの販売結果を判別する分類器を構築する．次に，推定された分類器を用い，アイテムの出品価格のみを変化させて結果の差異を分析する．そして，元の販売結果とは異なる結果が得られる変化点の価格を求める．この方法により，値下がりが起こらない範囲での出品価格の最大値を推定することができ，実際の価格決定の基準値となると期待できる．本研究では，サイト A の販売履歴データに提案手法を適用し，分析結果に対する考察を行う．

連絡先: 桑田　和，早稲田大学，東京都新宿区 169-8555，ikdsk14243150@toki.waseda.jp

2. 問題設定

サイト A では，アイテムの出品価格を高価格にすると，それに比例して購入時の価格も高価格になり，売上は増加する [1]．しかし，ユーザに購入されにくくなるため，販売期間が長くなり，在庫費の増加や売れ残り，サイト上に同一アイテムを長期間掲載することによるサイトの魅力度低下といった問題が発生する．一方，アイテムを低価格で出品した場合，多くのアイテムはすぐにユーザに購入される反面，より高価格で購入される機会を失う．そのため，販売期間と売上の双方を考慮した出品価格の推定が望まれる．

過去に出品され，購入されたアイテムには，前述のように 2 通りの販売結果が存在する．出品価格のまま購入されたアイテムは，より高い出品価格であってもユーザの購買意欲やアイテムの価値により，その価格で購入され，販売期間に大きな変化が生じなかった可能性がある．一方，値下げされたアイテムは，より低い出品価格であればアイテムに対してユーザが感じる価値より価格が下回り，より早く購入され，販売期間が短縮された可能性がある．このように，サイト A で扱われるアイテムは出品価格によって販売結果が異なるため，販売結果を予測するモデルを構築するだけでは適切な出品価格を推定することはできない．したがって，アイテムの販売結果の差異を考慮に入れて，適切な出品価格を推定する方法を考える必要がある．

そこで本研究では，まず，出品価格からの値下がり率 (以下，オフ率) と販売期間を用い，出品価格を設定したアイテムが出品価格で購入されるか，値下げされるかを判別する分類モデルを構築する．次に予測される販売結果を基に，値下がりしない出品価格の最大値を推定する方法を示す．これにより，個々のアイテムに対する値下げを可能な限り回避しつつ，収益性の高い出品価格を見積もることが可能となる．

3. 事前分析

本章では，前述の 2 通りの販売結果の境界を考えるため，出品価格の決定に大きく依存している要因の 1 つであるブランドに着目して，出品価格で購入されたアイテムと値下げされたアイテムの特徴について分析を行う．ここでは，前者をオフ率 0%かつ販売期間 8 日未満で購入されたもの，後者をオフ率 0%以外かつ販売期間 8 日以降で購入されたものとする．サイト A では，ブランドを 8 つのクラスタ (以下，ブランドクラスタ) に分けられている．各販売結果において，各クラスタでの出品価格の平均値を表 1 に示す．

表 1: 各販売結のブランドクラスタにおける平均出品価格 [円]

ブランド クラスタ	出品価格で購入された アイテム (件数)	値下げされた アイテム (件数)
1	**6,703** (10,879)	6,124 (13,724)
2	14,519 (4,946)	**17,160** (3,310)
3	10,051 (15,877)	**11,389** (15,767)
4	7,235 (43,552)	**8,210** (50,692)
5	4,975 (123,973)	**5,407** (257,398)
6	3,907 (128,266)	**4,026** (473,083)
7	3,327 (2,976)	**3,463** (39,693)
8	3,878 (55,021)	**4,068** (43,112)

※太字は 2 つのアイテム群を比較して大きい値

表 1 より，ほとんどのクラスタにおいて，その平均出品価格は，出品価格で購入されたアイテムの方が低い．このことから，同じような価格帯のアイテムでも，出品価格で購入されたアイテムの出品価格は値下がりしない出品価格の最大値よりも低く，値下げされたアイテムの出品価格は高く設定されている可能性がある．そこで，値下がりしない最大出品価格は，前者の出品価格をより高く，後者の出品価格をより低くすることで得られると考えられる．

4. 提案手法

4.1 概要

サイト A で扱われるアイテムは，出品価格によって 2 通りの販売結果が得られる．出品価格で購入されたアイテムは出品価格を上げると，ある価格を境に出品価格のまま購入されなくなり，値下げに結び付くと考えられる．一方，値下げされたアイテムは出品価格を下げると，ある価格を境に出品価格で購入されるようになると考えられる．

そこで本研究では，出品価格で購入されるアイテムに対しては，出品価格を上げ，値下げされる直前の価格を見つける．一方，値下げされるアイテムに対しては，出品価格を下げ出品価格で購入される際の価格を見つける．

提案手法ではまず，過去に購入されたアイテムの販売履歴データにおける，オフ率と販売期間を分類基準として学習することで，2 通りの販売結果を判別する分類規則を構築する．そして出品価格を設定した新規アイテムに分類規則を適用し，販売結果を予測する．次に，アイテムの値下がりしない出品価格の最大値を推定する．出品価格で購入されると予測されるアイテムに対しては，出品価格を段階的に上げながらオフ率の分類規則を適用し，値下げされると予測される出品価格を値下がりしない出品価格の最大値と推定する．一方，値下げされると予測されるアイテムに対しては，出品価格を段階的に下げながらオフ率の分類規則を適用し，出品価格で購入されると予測される出品価格を値下がりしない出品価格の最大値と推定する．

4.2 提案手法のアルゴリズム

N 個の学習データのうち，n 番目のアイテムの出品価格を p_n，出品価格以外の特徴量を $\boldsymbol{x}_n \in \mathbb{R}^D$, オフ率に関する分類ラベルを表す離散変数を $o_n \in \{0, 1\}$, 販売期間に関する分類ラベルを表す離散変数を $d_n \in \{0, 1\}$ と定義する．ただし，o_n は n 番目のアイテムのオフ率が 0%ならば 0，0%より高ければ 1 をとる変数であり，d_n は n 番目のアイテムの販売期間が k 日未満ならば 0，k 日以降ならば 1 をとる変数とする．また，オフ率が 0%と 0%より高いクラスを識別する関数を $f(\cdot, \cdot)$, 販売期間が k 日未満と k 日以降を識別する関数を $g(\cdot, \cdot)$ とする．

このとき，$f(\cdot, \cdot)$, $g(\cdot, \cdot)$ の学習アルゴリズムと，新たに出品する新規アイテム $\tilde{\boldsymbol{x}}$ の販売結果を予測し，値下がりしない出品価格の最大値を推定するアルゴリズムを以下に示す．ここでは，新規アイテムのうち，オフ率が 0%かつ販売期間が k 日未満と予測されるアイテムを出品価格で購入されるアイテム ($I_0 \in \mathcal{I}$)，オフ率が 0%より高くかつ販売期間が k 日以降と予測されるアイテムを値下げされるアイテム ($I_1 \in \mathcal{I}$) と定義する．ただし，どちらにも含まれないアイテムについては値下がりしない出品価格の最大値は求めない．また，新規アイテム $\tilde{\boldsymbol{x}}$ の暫定出品価格を $\tilde{p}$，出品価格の値上げ幅 s，値下げ幅 t，さらに，出品価格を無限に変化させないための上限値と下限値をそれぞれ予め設定しておく．

Step1) 販売結果の予測

Step1-1) $f(\cdot, \cdot)$ は，入力アイテムのオフ率が 0%ならば 0, 0%より高ければ 1 となるように $\{p_n,\ \boldsymbol{x}_n,\ o_n\}_{n=1}^N$ を学習データとして学習する．

Step1-2) $g(\cdot, \cdot)$ は，入力アイテムの販売期間が k 日未満ならば 0，k 日以降ならば 1 となるように $\{p_n,\ \boldsymbol{x}_n,\ d_n\}_{n=1}^N$ を学習データとして学習する．

Step1-3) 新規アイテム $\tilde{\boldsymbol{x}}$ に対し，$f(\tilde{p},\ \tilde{\boldsymbol{x}}) = 0$ かつ $g(\tilde{p},\ \tilde{\boldsymbol{x}}) = 0$ のとき I_0 へ分類し，Step2 へ．$f(\tilde{p},\ \tilde{\boldsymbol{x}}) = 1$ かつ $g(\tilde{p},\ \tilde{\boldsymbol{x}}) = 1$ のとき，I_1 へ分類し，Step3 へ．

Step2) 出品価格で購入されるアイテム ($\{\tilde{p},\ \tilde{\boldsymbol{x}}\} \in I_0$) の値下がりしない出品価格の最大値の推定

Step2-1) $j = 0$, $\tilde{p}^{(0)} = \tilde{p}$ とする．

Step2-2) $\tilde{p}^{(j+1)} = \tilde{p}^{(j)} + \tilde{p}^{(j)} \times\ s$ とする．$\tilde{p}^{(j+1)}$ が上限値以上の場合，上限値を最大出品価格として終了．

Step2-3) $f(\tilde{p}^{(j+1)},\ \tilde{\boldsymbol{x}}) = 1$ ならば，$\tilde{p}^{(j)}$ を最大出品価格として終了．$f(\tilde{p}^{(j+1)},\ \tilde{\boldsymbol{x}}) = 0$ ならば，$j = j + 1$ とし，Step2-2 に戻る．

Step3) 値下げされるアイテム ($\{\tilde{p},\ \tilde{\boldsymbol{x}}\} \in I_1$) の値下がりしない出品価格の最大値の推定

Step3-1) $j = 0$, $\tilde{p}^{(0)} = \tilde{p}$ とする．

Step3-2) $\tilde{p}^{(j+1)} = \tilde{p}^{(j)} - \tilde{p}^{(j)} \times\ t$ とする．$\tilde{p}^{(j+1)}$ が下限値以下の場合，下限値を最大出品価格として終了．

Step3-3) $f(\tilde{p}^{(j+1)},\ \tilde{\boldsymbol{x}}) = 0$ ならば，$\tilde{p}^{(j+1)}$ を最大出品価格として終了．$f(\tilde{p}^{(j+1)},\ \tilde{\boldsymbol{x}}) = 1$ ならば，$j = j + 1$ とし，Step3-2 に戻る．

5. 実データ分析

サイト A の販売履歴データに提案手法を適用し，2 通りの販売結果に判別するための分類規則の学習を行う．そして，分類規則を用いて，新規アイテムの販売結果を予測し，値下がりせずに購入される出品価格の最大値を推定する．得られた結果から，各アイテムと推定出品価格との関係分析を行う．

5.1 分析条件

提案手法を，サイト A における 2017 年 1 月 1 日から 12 月 31 日の販売履歴データに適用する．データ件数は 284,112 件 (分類器を構築する際の学習データ：255,700 件，新規アイテムとして使うテストデータ：28,412 件) であり，アイテムの特徴量として，出品価格に加えて，定価，20 種類のアイテムカテゴリ，51 種類の補助変数を用いる ($D = 72$)．また，分類の評価指標として正解率を用いる．

本研究では，事前分析を通じ，販売期間の分類基準を $k = 8$ とし，出品価格の値上げ幅 $s = 0.01$，値下げ幅 $t = 0.01$ と設定した．また，オフ率の分類器 $f(\cdot,\cdot)$ と販売期間の分類器 $g(\cdot,\cdot)$ には Random Forests (RF) [2] を用いる．ここで，分類器 $f(\cdot,\cdot)$, $g(\cdot,\cdot)$ における木の数はそれぞれ 200, 700 とし，木の深さの最大値はどちらも 100 とした．さらに，各ノードの分割基準にはジニ係数を用いるものとした．出品価格を変化させる際の制約条件として，出品価格の上限値を各アイテムの定価，出品価格の下限値を各アイテムの定価の 10%と設定した．

5.2 2 通りの販売結果への分類精度

2 通りの販売結果への分類において，オフ率と販売期間の分類器の正解率を表 2 に，テストデータの各販売結果における正解率を表 3 に示す．

表 2：各分類器による正解率

	オフ率 $f(\cdot,\cdot)$	販売期間 $g(\cdot,\cdot)$
学習データ	0.999	0.999
テストデータ	0.693	0.703

表 3：テストデータの各販売結果における正解率

	出品価格で購入される アイテム	値下げされる アイテム
正解率	0.486	0.756

表 2 より，オフ率と販売期間の分類器はテストデータに対して約 7 割の正解率が得られていることが分かる．また表 3 より，出品価格で購入されるアイテムへの分類は約 49%，値下げされるアイテムへの分類は約 76%の精度が得られていることが分かる．以上より，オフ率と販売期間を用いることで，新規アイテムの販売結果をある程度予測できることが示された．

さらに，RF を用いた各分類器においてどの特徴量が分類に影響しているのかを調べるため，各特徴量の重要度を分析した．表 4，5 にオフ率と販売期間の分類器において重要であった特徴量の上位 10 個を示す．

表 4：重要特徴量 ($f(\cdot,\cdot)$)

特徴量	説明	重要度
前回販売期間	買い取ったアイテムが販売されていた際の販売期間	0.183
在庫日数	アイテムの下取り日から出品日までの日数	0.163
定価	アイテムが未使用の際の出品価格	0.155
出品価格	サイト A でアイテムを出品する際の価格	0.132
コンディション_C	アイテムの状態	0.0190
コンディション_B	アイテムの状態	0.0177
画像使用_有	サイト A に掲載する際に画像使用	0.0175
セールランク_C	セールされている度合	0.0170
新品	買い取ったアイテムが新品で購入されたもの	0.0152
カテゴリ_カットソー	アイテムのカテゴリ	0.0122

表 5：重要特徴量 ($g(\cdot,\cdot)$)

特徴量	説明	重要度
前回販売期間	買い取ったアイテムが販売されていた際の販売期間	0.175
在庫日数	アイテムの下取り日から出品日までの日数	0.158
定価	アイテムが未使用の際の出品価格	0.158
出品価格	サイト A でアイテムを出品する際の価格	0.140
コンディション_C	アイテムの状態	0.0215
セールランク_C	セールされている度合	0.0191
コンディション_B	アイテムの状態	0.0190
画像使用_有	サイト A に掲載する際に画像使用	0.0173
新品	買い取ったアイテムが新品で購入されたもの	0.0133
カテゴリ_カットソー	アイテムのカテゴリ	0.0111

表 4，5 より，2 つの分類器において重要な特徴量にほとんど違いはなく，前回販売期間，在庫日数，定価，出品価格が特に重要な特徴量であることが分かる．これらの特徴量はすべて量的変数であり，質的変数に比べて多様性が高く，それによりこのような結果になったと考えられる．

5.3 値下がりしない出品価格の最大値についての分析

(1) カテゴリに着目した分析

出品価格で購入されると予測されたアイテムのうち，出品価格が，上限値に到達しなかったアイテムと上限値に到達したアイテム，値下げされると予測されたアイテムのうち，出品価格が，下限値に到達しなかったアイテムと下限値に到達したアイテムのカテゴリについてそれぞれ分析する．分析結果を表 6 に示す．ただし，全データを分析した際に，20 種類のカテゴリのうち，アイテムの所属割合が 3%未満であったカテゴリはデータ数が非常に少なく，分析する上で偏った特徴が見られると考えたため，今回は分析対象外とした．

表 6：カテゴリ別の各グループの割合 [%]

	出品価格で購入される アイテム		値下げされる アイテム	
カテゴリ (割合)	上限値未達	上限値到達	下限値未達	下限値到達
全体 (100.00)	5.71	16.82	43.56	33.90
カットソー (15.49)	6.42	12.19	47.06	**34.33**
コート (3.59)	3.43	**41.37**	29.31	25.89
シャツ (10.86)	**7.90**	17.72	45.65	28.73
シューズ (10.42)	2.45	8.04	38.07	**51.44**
スカート (7.24)	6.81	13.55	**50.16**	29.49
デニム (4.41)	**8.68**	17.05	49.07	25.21
ニット (13.25)	3.61	15.07	34.00	**47.32**
バッグ・ケース類 (10.04)	5.31	**24.80**	40.55	29.34
パンツ (13.52)	**8.00**	11.91	**50.44**	29.66
ワンピース (11.16)	5.93	**17.82**	**49.37**	26.89

※太字は割合が大きい上位 3 つのカテゴリ

表 6 より，全アイテムの所属割合を比較すると，上限値に到達しなかったアイテムには，シャツ，デニム，パンツが多く含まれ，それらは出品価格を上げてもオフ率 0%を達成できるアイテムと考えられる．また，上限値に到達したアイテムにはコート，シャツ，バッグ・ケース類が多く含まれ，それらは定価のままでもオフ率 0%を達成できるアイテムであり，他のアイテムに比べて売上増加を見込めると考えられる．

一方，下限値に到達しなかったアイテムには，スカート，パンツ，ワンピースが多く含まれる．これらは出品価格を下げることでオフ率 0%を達成できると考えられ，販売期間の短縮が見込める．また，下限値に到達したアイテムにはカットソー，シューズ，ニットが多く含まれ，これらは出品価格を大きく下げてもオフ率 0%を達成できないアイテムが多く，アイテムの買取自体を検討する必要があると考えられる．

次に，上限に到達しなかったアイテムのカテゴリにおいて，最も割合が大きくなったデニムに対し，提案手法で算出した出品価格とその値上がりした割合 (以下，値上げ度) を式 (1) のように定義し，得られた度数分布を図 1 に示す．また，下限に到達しなかったアイテムのカテゴリにおいて，最も割合が大きくなったパンツに対し，提案手法で算出した出品価格とその値下がりした割合 (以下，値下げ度) を (2) のように定義し，得られた度数分布を図 2 に示す．ただし，図中の%表示は，q% 以上 $q + 10$%未満の値上げ度・値下げ度となったアイテムを

q%と表記した．また，アイテムが所属しない値上げ度・値下げ度は省略している．

$$\text{値上げ度} = \left(\frac{\text{最終出品価格} - \text{元の出品価格}}{\text{元の出品価格}}\right) \times 100 \quad (1)$$

$$\text{値下げ度} = \left(\frac{\text{元の出品価格} - \text{最終出品価格}}{\text{元の出品価格}}\right) \times 100 \quad (2)$$

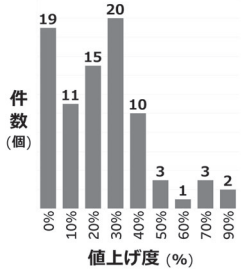


図 1：値上げ度の分布 (デニム)

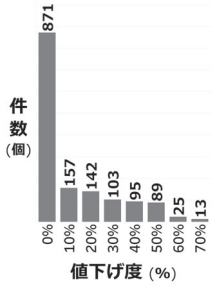


図 2：値下げ度の分布 (パンツ)

図 1 より，値上げ度の分布が 0%から 9%, 30%から 39%に多く分布していることから，上限値に到達しなかったデニムの多くは出品価格を 0%から 9%または 30%から 39%値上げしたとしても出品価格で購入されると考えられ，売上増加が見込める．また図 2 より，値下げ度の分布が 0%から 9%に多く分布していることから，下限値に到達しなかったパンツの多くは出品価格を 0%から 9%値下げすることで出品価格で購入されると考えられ，販売期間短縮が見込める．

(2) ブランドに着目した分析

予測したアイテムの販売結果に対し，出品価格を変化させて推定した結果をブランドクラスタに着目して分析を行う．分析結果を表 7 に示す．

表 7：ブランドクラスタ別の各グループの割合 [%]

	出品価格で購入されるアイテム		値下げされるアイテム	
ブランドクラスタ (割合)	上限値未達	上限値到達	下限値未達	下限値到達
全体 (100.00)	5.71	16.82	43.56	33.90
1 (2.01)	1.81	19.92	34.21	**44.06**
2 (0.56)	0.72	**52.90**	28.26	18.12
3 (2.27)	2.66	40.32	29.48	27.53
4 (7.43)	4.57	30.67	35.51	29.26
5 (29.25)	5.44	20.47	43.60	30.49
6 (47.42)	5.83	10.89	46.40	36.88
7 (3.40)	3.92	4.16	**49.29**	42.64
8 (7.66)	**10.23**	21.45	38.75	29.57

※太字は割合が最も大きいブランドクラスタ

表 7 より，クラスタ 8 は他のブランドクラスタに比べて上限値未達の割合が大きい．このことから，クラスタ 8 に所属するアイテムの多くは出品価格を上げてもオフ率 0%を達成できるアイテムと考えられる．また，クラスタ 2 は他のクラスタに比べて上限値到達の割合が大きい．このことから，クラスタ 2 に所属するアイテムの多くは定価のままでもオフ率 0%を達成できるアイテムであり，他のアイテムに比べて売上増加を見込めると考えられる．

一方，クラスタ 7 は他のクラスタに比べて下限値未達の割合が大きい．このことから，クラスタ 7 に所属するアイテムの多くは出品価格を下げることでオフ率 0%を達成できると考えられ，販売期間の短縮が見込める．また，クラスタ 1 は他のクラスタに比べて下限値到達の割合が大きい．このことから，クラスタ 1 に所属するアイテムの多くは出品価格を大きく下げてもオフ率 0%を達成できないアイテムが多く，アイテムの買取自体を検討する必要があると考えられる．

次に，上限値未達の割合が最も大きかったクラスタ 8 に所属するアイテムに対し，式 (1) により値上げ度を求め，その度数分布を図 3 に示す．また，下限値未達の割合が最も大きかったクラスタ 7 に所属するアイテムに対し，式 (2) により値下げ度を求め，その度数分布を図 4 に示す．

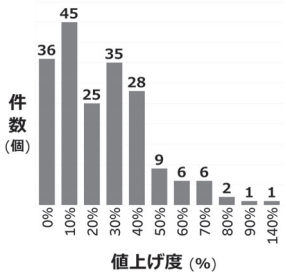


図 3：値上げ度の分布 (ブランドクラスタ 8)

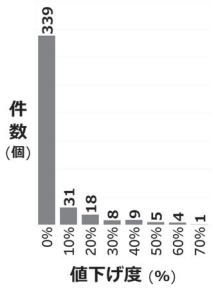


図 4：値下げ度の分布 (ブランドクラスタ 7)

図 3 より，値上げ度の分布が 10%から 19%に多く分布していることから，上限値に到達しなかっクラスタ 8 の多くは出品価格を 10%から 19%値上げしたとしても出品価格で購入されると考えられ，売上増加が見込める．また図 4 より，値下げ度の分布は 0%から 9%に多く分布していることから，下限値に到達しなかったクラスタ 7 の多くは出品価格を 0%から 9%値下げすることで出品価格で購入されると考えられ，販売期間短縮が見込める．

6. まとめと今後の課題

本研究ではサイト A におけるアイテムの出品価格決定問題を対象とし，新たに出品するアイテムの値下がりせずに購入される出品価格の最大値を推定することを目的とし，アイテムの販売結果を予測することで，値下がりしない出品価格の最大値を推定する手法を提案した．これを実際にサイト A の販売履歴データに適用し出品価格を推定することで，提案手法の有効性を示した．これにより，サイト A において，各アイテムが値下がりせずに購入される出品価格の最大値の推定を可能とした．この推定出品価格はサイト A における出品価格決定の際の新たな基準値となることが期待できる．

今後の課題としては，アイテムの販売結果の予測手法の検討が挙げられる．本研究では分類精度と計算コストを考慮したため RF を用いたが，他の 2 値分類の手法として，Support Vector Machine [3] やニューラルネットワーク [4] といった手法により，予測精度が向上する可能性もある．また，本研究では，新規アイテムの出品価格を推定する際，オフ率が 0%以下かつ販売期間が k 日以降と予測されたアイテムと，オフ率が 0%より高くかつ販売期間が k 日未満と予測されたアイテムは，推定対象外のアイテムとした．そのため，それらのアイテムを考慮した出品価格の推定モデルも必要である．

参考文献

[1] 仁ノ平 将人，三川 健太，後藤 正幸，“販売履歴データに基づく中 古ファッションアイテムの販売価格予測モデルに関する一考察，”情報処理学会論文誌, Vol. 60, No. 4, (掲載決定)

[2] L. Breiman, “Random Forests,” *Machine Learning*, Vol. 45, pp. 5–32, 2001.

[3] J. A. Suykens and J. Vandewalle, “Least Squares Support Vector Machine Clasifiers,” *Neural processing letters*, Vol. 9, No. 3, pp. 293–300, 1999.

[4] 麻生英樹, “ニューラルネットワーク情報処理,” 産業 図書, 1998.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

良品率予測と装置組合せ最適化による生産性向上

Productivity Improvement through Yield Prediction and Machine Combination Optimization

鈴木 慶昭 *1 Yoshiaki Suzuki　加納 学 *1 Manabu Kano　曽我 朗 *2 Akira Soga　柳町 武志 *2 Takeshi Yanagimachi　村尾 了 *2 Ryo Murao　高木 雅哉 *2 Masaya Takaki

*1京都大学 Kyoto University　*2東芝 Toshiba Corp.

In a multi-process production system, the yield rate of the final products depends not only on the goodness of each machine but also on that of machine combinations at different stages. To maximize the productivity, it is crucial to use good machine combinations by priority. In the present work, we proposed a modeling method that can estimate the yield rates of unused machine combinations and a production scheduling method that can optimize machine combinations by taking account of the yield rates. The proposed modeling method uses field-aware factorization machines (FFM). A case study demonstrated that FFM can estimate the yield rates with great accuracy even when yield rates are available in only 20% of all machine combinations and also that the proposed scheduling method improved the productivity by more than 10%.

1. はじめに

製品が複数工程を経て製造される場合，装置組合せの良し悪し，つまり装置の相性が重要な役割を果たすことがある．不良品の発生をできるだけ抑えたい場合，性能 (製品の良品率) の低い装置を用いるべきでないことは当然だが，複数の装置を同時に利用することで生じる交互作用も考慮すべきである．例えば，工程 1 の装置 3 と工程 2 の装置 1 を用いて製品を製造すると不良品が発生しやすいといった場合である．製造現場では，装置の組合せが歩留まりに与える影響を経験的に考慮してきたものの，システマティックには取り扱ってこなかった．しかし，さらなる生産性向上を実現するために，多工程生産設備における装置組合せの最適化が必要である．

大規模な生産設備の場合，装置組合せの数が膨大であるため，全装置組合せについて最終製品の良品率に関する実績データを取得することはほぼ不可能である．したがって，実績のない装置組合せについての良品率を推定しなければならない．さらに，生産性を向上させるためには，良品率の向上とメイクスパンの短縮を同時にできる生産スケジューリングが必要になる．ところが，装置組合せに依存する良品率を考慮したスケジューリングの研究例はない．そこで本研究では，装置組合せ最適化によって生産性を最大化することを目的として，装置組合せに依存する良品率の推定方法と良品率を考慮した生産スケジューリング方法を提案する．

2. 装置組合せに依存する良品率の推定

良品率の実績データが存在する装置組合せとその良品率との関係を表現するモデルを構築することで，実績データのない装置組合せの良品率を推定したい．個々の装置の良し悪しに加えて装置組合せの良し悪し，つまり入力変数間の交互作用を表現する必要があるため，また，少ない実績データから使用実績のない装置組合せの良品率を推定する必要があるため，Field-aware Factorization Machines (FFM)[?] を用いる．

連絡先: 加納学，manabu@human.sys.i.kyoto-u.ac.jp

2.1 Field-aware Factorization Machines

Factorization Machines (FM)[?] は，入力変数間の関係を潜在ベクトルによって表現することで，モデル中のパラメータ数を減らし，効率的に学習する非線形回帰手法である．入力変数を x_i $(i = 1, 2, \cdots, I)$，$\hat{y}$ を出力変数の予測値とすると，二次までの交互作用を考慮する FM の予測式は

$$\hat{y} = \omega_0 + \sum_{i=1}^{I} \omega_i x_i + \sum_{i=1}^{I} \sum_{j=i+1}^{I} w_{i,j} x_i x_j \qquad (1)$$

となる．ここで，ω_0 は切片項，$\boldsymbol{\omega}$ は係数ベクトルである．

FM では，入力変数が属するカテゴリーごとに交互作用を調整することができず，存在しない交互作用もモデル化することになり，予測性能が低下することがある．この問題を解決するために，FFM では，入力変数をいくつかのフィールド (field) に分割，つまりグループ化することで，潜在ベクトルをフィールドごとに用意する．

本研究で対象とする多工程生産設備における良品率推定の場合，工程ごとに装置数を要素数とするワンホットベクトルを用意する．工程をフィールドとみなすことにより，同じ工程内の装置間の交互作用係数 $w_{i,j}$ を 0 としてモデル化できる．さらに，係数 $w_{i,j}$ が交互作用の大きさを表すことから，その絶対値が大きいほど対応する装置組合せが良品率に与える影響が大きく，符号が正であれば良品率が高くなると判断できる．

2.2 ケーススタディ

工程数を 4，各工程の装置数を 5 とする．装置組合せの良品率は，その組合せにおける個々の装置の性能と，特定の 2 台の装置組合せの良し悪しにより定まるとする．全装置組合せに対して使用実績 (良品率データ) のない装置組合せの割合を μ% として，実績のある装置組合せについての観測データを用いて良品率推定モデルを構築した結果を Figs. **??**に示す．なお，モデル構築には，FM と FFM に加えて，サポートベクトル回帰 (SVR)，ガウス過程回帰 (GPR)，ランダムフォレスト (RF) を用いた．$\mu = 80$% では FFM の推定性能の低下幅が顕著に小さく，FFM の推定性能が最も高いことがわかる．

次に，交互作用係数 $w_{i,j}$ の絶対値を指標に用いて，重要な装置組合せを特定した結果 (10 回の試行の平均) を Fig. **??**に

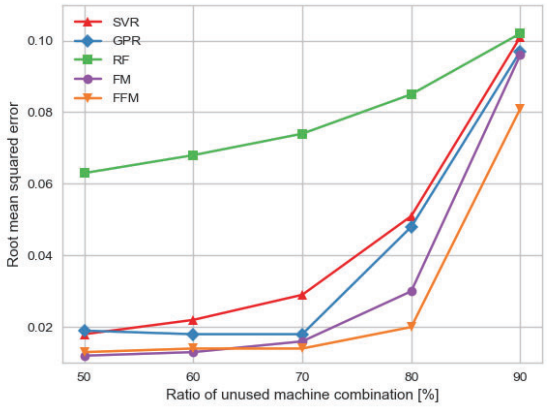


図 1: Estimation result of yield rate: RMSE

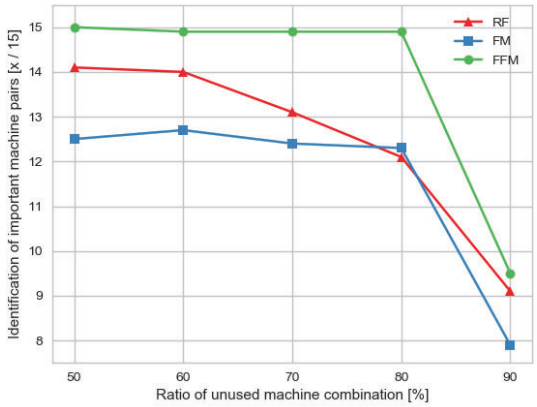


図 2: Identification results of 15 good/bad machine combinations using RF, FM, and FFM

示す．縦軸は各手法が正しく特定した装置組合せの数であり，合計 15 個のうち何個を特定できたかを表す．この結果から，$\mu = 80\%$ を超えるとどの方法でも特定性能が悪くなるが，80% 以下では FFM がほぼ完全に特別な装置組合せの特定に成功したことがわかる．

3. 良品率を考慮した生産スケジューリング

一部の装置組合せについて使用実績がなく，良品率が未知であるとして，メイクスパンと良品率を同時に考慮して，装置へのジョブの割り当てを最適化するハイブリッド・フローショップ・スケジューリング問題を解く．なお，多目的遺伝的アルゴリズムの一種である NSGA-II を用いる．

3.1 ディスパッチングルール

生産スケジューリング問題を遺伝的アルゴリズムで解く場合，第 1 工程のジョブ割当てのみを最適化変数とし，第 2 工程以降はディスパッチングルールを使うことで計算負荷を低減することが多い．標準的なディスパッチングルールは First-In First-Out (FIFO) と呼ばれ，対象となる工程に早く到着したジョブから順に処理可能な装置に割り当てる．FIFO はメイクスパン最小化が目的である場合には優れた手法であるが，良品率を考慮していないため，本研究で対象とする問題には適さない．そこで，新たに 3 種類のディスパッチングルールを提案する．Highest Expected Yield Rate (HEYR) では，ジョブを期待良品率が最も高くなる装置に割り当てる．Throughput Multiple Insertion (TMI) では，全ジョブを処理可能時刻が早い順に並べ，工程ごとにスループットが最大となるようにジョブの処理装置と処理順序を決定する．Hybrid は HEYR と TMI を組み合わせたディスパッチングルールである．

表 1: Results of production scheduling

Method	NHV	$C_{\max}$	Q_{all}	Throughput
FIFO	0.256	59.2	0. 868	284.1
HEYR	0.592	62.8	0.917	274.1
TMI	0.801	66.0	0.962	278.8
Hybrid	0.760	62.8	0.946	282.7
GA	-	60.0	0.798	253.6

3.2 ケーススタディ

工程数，装置数，良品率に関する設定は**??**節と同一であり，30 個のジョブを処理する．使用実績のある装置組合せは全体の 50%とし，使用実績のない装置組合せの良品率を FFM によって推定した．良品率の実績値と推定値を利用し，NSGA-II を用いて多目的スケジューリング問題のパレート最適解を求めた．パレート最適解の良さを定量的に評価するために算出した Normalized Hypervolume (NHV) を Table **??**に示す．この結果から，ディスパッチングルールとして TMI を採用した場合のパレート最適解集合が最も優れていることがわかる．

Table **??**には，メイクスパン $C_{\max}$ の最小値，良品率 Q_{all} の最大値，およびスループットの最大値を求めた結果も示している．スループットは単位時間あたりの良品数であり，生産性の指標として重要である．GA は遺伝的アルゴリズムであり，メイクスパンのみを目的関数として最適化した結果を示した．メイクスパン最小化では FIFO が最も良く，GA と同等の結果が得られた．良品率最大化では TMI が最も良く，良品率を考慮したディスパッチングルールの有用性が確認できた．従来型ディスパッチングルールの FIFO でも GA と比べて 35%の良品率向上がみられた．また，スループット最大化では FIFO と Hybrid の結果が良く，GA と比べてそれぞれ 12%および 11%の向上がみられた．

4. おわりに

本研究では，多工程生産設備の生産性向上を目指して，装置組合せに依存する良品率の推定方法と良品率を考慮した生産スケジューリング方法を提案した．良品率推定には FFM が極めて有効であり，良品率を高精度で推定できることに加えて，良品率に影響する特別な装置組合せを正確に特定できた．さらに，メイクスパン最小化と良品率最大化を同時に考慮した多目的生産スケジューリング問題を，NSGA-II と新しいディスパッチングルールを組み合わせて解くことで，従来法に比べて単位時間あたりの良品数を 10%以上向上できた．

参考文献

[Juan 16] Y. Juan, Y. Zhuang, W. S. Chin, and C. J. Lin, Field-aware Factorization Machines for CTR Prediction, *Proc. ACM Conf. on Recommender Systems*, 43/50 (2016)

[Rendle 10] S. Rendle, Factorization machines, *Proc. IEEE Int'l Conf. on Data Mining*, 995/1000 (2010)

General Session | General Session | [GS] J-2 Machine learning

[2H3-J-2] Machine learning: selective preprocess

Chair:Yoji Kiyota Reviewer:Satoshi Oyama

Wed. Jun 5, 2019 1:20 PM - 3:00 PM Room H (303+304 Small meeting rooms)

[2H3-J-2-01] Surround Inhibition Mechanism by Deep Learning

○Mamoru Sugamoto[1], Naoaki Fujimoto[2], Muneharu Onoue[3], Tsukasa Yumibayashi[4], Akio Sugamoto[5] （1. apprhythm inc., 2. Tama Art U., 3. Geelive, Inc, 4. Otsuma Women’s U., 5. Ochanomizu U. and OUJ）

1:20 PM - 1:40 PM

[2H3-J-2-02] Adaptive Learning Rate Adjustment with Short-Term Pre-Training in Data-Parallel Deep Learning

○Kazuki Yamada[1], Haruki Mori[1], Tetsuya Youkawa[1], Yuki Miyauchi[1], Shintaro Izumi[1], Masahiko Yoshimoto[1], Hiroshi Kawaguchi[1] （1. Kobe University）

1:40 PM - 2:00 PM

[2H3-J-2-03] Adaptability of Cognitive Satisficing Algorithm in Nonstationary Environments

○Yuto Hanayasu[1], Kenshi Saito[2], Yuki Yoshii[1], Yu Kono[1], Tatsuji Takahashi[1] （1. School of Science and Engineering, Tokyo Denki University, 2. Graduate School of Tokyo Denki University）

2:00 PM - 2:20 PM

[2H3-J-2-04] A proposal of a new variable selection method utilizing gene's distribution information and solutions search progress rate of Real-coded genetic algorithms

○Takahiro OBATA[1], Setsuya KURAHASHI[1] （1. University of Tsukuba）

2:20 PM - 2:40 PM

[2H3-J-2-05] Feature Oriented Attention to Extract Attribution for Multivariate Time-Series Data

○Shuhei Asano[1], Keisuke Kiritoshi[1], Tomonori Izumitani[1] （1. NTT Communications Corporation）

2:40 PM - 3:00 PM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

Surround Inhibition Mechanism by Deep Learning

Naoaki Fujimoto[*1] Muneharu Onoue[*2] Akio Sugamoto[*3] Mamoru Sugamoto[*4]
Tsukasa Yumibayashi[*5]

[*1]Tama Art U. [*2]Geelive, Inc. [*3]Ochanomizu U. and OUJ [*4]Apprhythm Co.
[*5]Otsuma Women's U.

In the sensation of tones, visions and other stimuli, the "surround inhibition mechanism" (or "lateral inhibition mechanism") is crucial. The mechanism enhances the signals of the strongest tone, color and other stimuli, by reducing and inhibiting the surrounding signals, since the latter signals are less important. This surround inhibition mechanism is well studied in the physiology of sensor systems.

The neural network with two hidden layers in addition to input and output layers is constructed; having 60 neurons (units) in each of the four layers. The label (correct answer) is prepared from an input signal by applying seven times operations of the "Hartline mechanism", that is, by sending inhibitory signals from the neighboring neurons and amplifying all the signals afterwards. The implication obtained by the deep learning of this neural network is compared with the standard physiological understanding of the surround inhibition mechanism.

1. Introduction

The inhibitory influence between different sensory receptors is found in the eye of Limulus (the horseshoe crab). Limulus has a pair of compound eyes. Each compound eye consists of 1000 ommatidia each of which is connected to a single nerve. Therefore, Limulus is the best creature to study the interactions between different light censors.

Hartline and his collaborators [1], [2] found by experiment that different ommatidia (light sensors) are interacted, giving mutual inhibition, that is, the excitation signal e_A of a sensor A is inhibited from the neighboring sensor B, following the following linear equation:

$$r_A = e_A - K_{AB} \times (r_B - r_B^0)\ \theta(r_B - r_B^0), \tag{1}$$

$$r_B = e_B - K_{BA} \times (r_A - r_A^0)\ \theta(r_A - r_A^0). \tag{2}$$

Here, $e_{A,B}$ is the excitation at A and B, induced when only A or B is stimulated. The $r_{A,B}$ is the response of the sensory nerve, when they are stimulated at the same time. The $r_{A,B}^0$ gives thresholds, by a step function $\theta(r-r^0)$ $(=1$ if $r - r^0 > 0$, but else 0). The strength of signal from a sensory nerve, is identified to the number of discharge of nerve impulses per unit time.

The inhibition (kinetic) coefficient K_{AB} gives the rate of inhibition to the sensor A from B. If A and B are the equal type, the reciprocal law $K_{AB} = K_{BA}$ holds. Its value depends on the pair of sensors, but is roughly $0.1 - 0.3$ by experiment. In the later analysis, we use 0.25 for this inhibition coefficient.

Suppose that the sensors, labeled by i, are lined laterally, while the layer is labeled by ℓ to which the sensors are concentrated. Then, Eq. (1) becomes

$$r_i(\ell+1) = \sum_j r_i(\ell) - K_{ij}\dot{(}r - r^0)_j(\ell)\ \theta(r_j - r_j^0)(\ell), \tag{3}$$

where we consider the response $r_j(\ell)$ be the input signal to a receptor j located at layer ℓ, and $r_i(\ell+1)$ is the output signal transferred to the receptor i located at the next layer $\ell+1$. The 0-th layer can be the input layer, receiving the outside stimulus, $r_i(0) = e_i$.

The same inhibition mechanism works for hearing. In this case, signals are transferred from the cochlea where the voice sensor are placed, to cochlear nuclei, super olivary complex, inferior colliculus, lateral geniculate body (LGB), before arriving at the auditory cortex. This means there exist at least four layers between the input and output, in which neurons are concentrated.

If we use the "rectified linear unit (ReLU)" function defined by $y = f(x) = \mathrm{ReLU}(x) = x \times \theta(x - x^0)$, then we have

$$x_i(\ell+1) = x_i(\ell) - \sum_j K_{ij} \times f\left((x - x^0)_j(\ell)\right). \tag{4}$$

This is identical to the neural network used by the deep learning (DL). In DL the adjustable parameters are weights W_{ij}, which is identical to the (kinetic) coefficients K_{ij} of Hartline *et al.*, [1]. For the human hearing, the neural network having several layers are used.

Now, we are ready to investigate by deep learning (DL) [3] how the sharpness of the contrast in brightness, color, or sound tone can be achieved.

2. Implication by Deep Learning (DL)

We implement a neural network having two hidden layers, and the number of neurons (units) in four layers of input, hidden1, hidden2 and output is all 60. The 1000 training data and the 1000 test data are prepared by random separation from 2000 data. Each datum and its label (a correct answer to be attained from a datum by DL) are prepared by the Harline's observation. Given a one dimensional data of a certain signal (brightness or color of light, frequency of

Contact: Mamoru Sugamoto, Research and Development Division, Apprhythm Co., Honmachi, Chuo-ku, Osaka, 541-0053 Japan, mamoru.sugamoto@gmail.com

sound, or else), as a sum of sin functions:

$$X(x) = \left(\sum_{n=1}^{5} a_n \sin nx \right)^2 , \tag{5}$$

where coefficients $0 \leq \{a_1, \cdots, a_5\} \leq 1$ are randomly generated, and x is the discretized position of neurons, having 60 points $\{x_i = \frac{2\pi i}{60} | i = 0, \cdots, 59\}$. The "Hartline operation" $X' = \hat{H}X$ is defined by

$$X'(i) = \lambda \cdot \mathrm{ReLU}\{X_i - \kappa(X_{i+1} + X_{i-1})\}. \tag{6}$$

The label Y for a datum X is given by $Y = (\hat{H})^7 X$ with $\kappa (= \text{Hartline}'\text{s } K) = 0.25$, and $\lambda = 2$.

The running of DL for 100,000 epochs, using sigmoid as the activation function and the full Stochastic Gradient Descent method, yields the following epoch dependence of the loss function defined as the squared error, $L(X_{\text{out}}, Y) = \frac{1}{2N} \sum_{n=0}^{N-1} \sum_{i=0}^{59} (X_{\text{out}} - Y)^2$, where $N = 1000$ is the total number of test data.

See (Figure 1) which shows the decrease of loss function by epochs, as well as the intermediate epochs of DL training, corresponding to the Hartline mechanism.

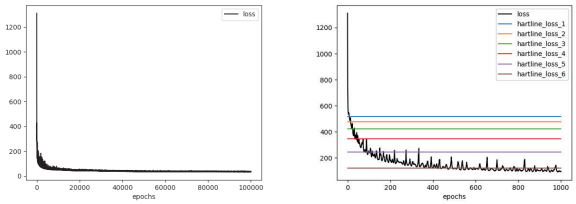


Figure 1: (Left): Loss as a function of epoch $<$ 100,000; (Right): Horizontal lines show the n-th Hartline loss $L(X_H^{(n)}, Y) + 34.55$ for epochs $<$ 1,000.

The left figure in (Figure 1) shows that the loss function decreases rapidly in the first 100 epochs, and it takes finally 34.55 at epoch 100,000 as the averaged value over the last 100 epochs.

It is important to compare the "Hartline's mechanism" of the surround inhibition in physiology [1], [2], with the implication obtained by DL of the neural network. We choose six intermediate outputs, $\{X^{(1)}, X^{(2)}, \cdots, X^{(6)}\}$ during the training of DL. The input datum is $X^{(0)}$ and the output datum is $X_{\text{out}} = X^{(7)}$. As for the Hartline mechanism, it gives the six intermediate outputs by $\{X_H^{(1)}, X_H^{(2)}, \cdots, X_H^{(6)}\}$, where $X_H^{(n)} = (\hat{H})^n X^{(0)}$, and $X_H^{(7)} = Y$ is the label. Therefore, it is reasonable to select six intermediate epochs of the DL training so that $L(X^{(n)}, Y) = L(X_H^{(n)}, Y) + L(X_{\text{out}}, Y)$ holds for $n = 1, 2, \cdots, 6$, where the last term in the r.h.s fills a gap 34.55 existing between the loss functions of Hartline and DL, even at 100,000 epochs' running. From the the training data, we select the 6 intermediate epochs. See the right figure in (Figure 1).

The loss functions between $X^{(n)}$ and $X_H^{(n)}$, $(n = 1, 2, \cdots, 6)$ is a measure to understand the difference between two mechanisms, Hartline's physiological one and DL's one. The data shows intermediate epochs of DL which corresponds to the Hartline's $X_H^{(n)}$ are 8, 24, 34-37, 84-88, 398-400, for $n = 1, 2, 3, 4, 5, 6$, respectively. The mean squared errors $L(X^{(n)}, X_H^{(n)})$ for $n = 1, 2, \cdots, 6$ are 30004.77, 2782.63, 2298.65, 2321.01, 2402.69, 711.76, respectively. They are not small. This suggests that the Hartline's mechanism and the DL's mechanism are not identical but they may differ.

The performance can be seen visually from the following two samples among 1,000 test data at 100,000 epoch, where the input, the label and the output signals are depicted by black, red and blue colors, respectively. See (Figure 2).

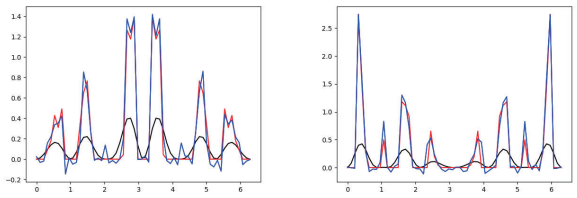


Figure 2: Input (black), label (red) and output (blue) signals of two sample data among 1,000 test data at 100,000 epoch.

From the samples, we can see DL acquires an ability of making the sharp contrast to the input datum, resulting the output datum in which the bumps are enhanced and strengthened.

3. Conclusion

The surround inhibition mechanism of sensory nerve system is studied by deep learning of a neural network. The deep learning mechanism by this neural network is not necessary equal to the standard one in physiology. More detailed comparison between DL and the real sensory system is necessary, using the real data of the creature.

References

[1] (Vision): H. K. Hartline, H. G. Wagner, and F. Ratliff, J. Gen. Physiol. **39** (1956) 651; H. K. Hartline and F. Ratliff, *i.b.d.* (1957) 357; *i.b.d.* **41** (1958) 1049; D. H. Hubel and T. N. Wiesel, J. Physiol. **148** (1959) 574; (Audition): E. G. Wever, M. Lawrence, and G. von Békésy, Proc. N. A. S. **40** (1954) 508, H. Helmholtz, "On the Sensations of Tones" Dover Pub. (1885); G. von Békésy and E. G. Wever, "Experiments in Hearing", New York MacGraw-Hill Pub. (1960).

[2] M. Takagi, "Sensonary Physiology-Illustrated", Shokabo Publishing (1989); A. Ogata, "Musical Temperamant and Scale" revised version (2018).

[3] Y. LeCun, Y. Bengino and G. Hinton, Nature **521** 436 (2015); K. Saitoh, 'Deep Learning-theory and implementation by Python-', O'Reilly Japan (2016); Y. Sugumori, "Deep Learning-time series date processing by TensorFlow and Keras-", Mynavi Publisher (2017).

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

データ並列深層学習における
短期事前学習を用いた適応的学習係数調節手法

Adaptive Learning Rate Adjustment with Short-Term Pre-Training in Data-Parallel Deep Learning

山田 和樹, 森 陽紀, 陽川 哲也, 宮内 勇貴, 和泉 慎太郎, 吉本 雅彦, 川口 博
Kazuki Yamada, Haruki Mori, Tetsuya Youkawa,Yuki Miyauchi, Shintaro Izumi, Masahiko Yoshimoto, Hiroshi Kawaguchi

神戸大学
Kobe University

Abstract: This paper describes short-term pre-training (STPT) algorism to adaptively select an optimum learning rate (LR). The proposed STPT algorism is beneficial for quick model prototyping in data-parallel deep learning. It adaptively finds an appropriate LR from multiple LR sets by STPT, which means the multiple LRs are evaluated within the beginning few iterations in an epoch. The STPT short cuts the tuning process of LRs that is requested in conventional training procedure as hyper-parameter tuning, even if the unknown models are considered. Therefore, the proposed STPT reduces computational time and increases throughput to find the best LR for network training. This algorism reduces the computational time by 87.5% than the conventional method when the eight-LR sets are evaluated using eight-parallel workers. We verified the accuracy improvement by 4.8 % compared with the conventional one with a reference LR of 0.1; there are no accuracy deterioration is observed. In this algorism, better training convergence is shown and expresses the advantage in terms of training time especially for the unknown models than other cases such as fixed LR.

1. はじめに

畳み込みニューラルネットワーク(CNN)をはじめとした深層学習は，画像認識分野において圧倒的な認識精度を示している [1]. より高精度な認識性能獲得のためには，より深くより大規模なネットワークが期待される. このようなネットワーク学習を考慮した場合，学習に係る計算機の占有は長時間に及び，現在の深層学習実用化にとって大きな障壁となっている. これまで，深層学習を高速化する手法として，データ並列及びモデル並列という 2 つの概念をベースとした多数の並列手法が研究されてきた [2]. さらなる学習時間の短縮のためには，ニューラルネットワークによって自動的に決定されない，ハイパーパラメータの設計がその学習速度に大きな影響を及ぼす.

これまで，LR がその最終精度に与える影響が大きいことは報告されているが，多くの場合で実験的または経験的に LR が設計されていた [3]. また，未知のネットワークに対して，単一プロセスのみの学習で適切な LR パラメータを設計し十分な精度を達成することは困難であった. つまり，ハイパーパラメータの決定のために，複数回の学習を繰り返し試行する必要があった. これに対し，適応的な LR を決定するためのアルゴリズムが多数提案されている. 特に，Adam [4], AdaGrad [5], AdaDelta [3]等は，蓄積した過去の勾配の変化量を基準として LR を適応的に変化させることで勾配降下法の収束速度を改善している. 一方で，これらの適応的手法ではむしろハイパーパラメータが増える傾向にある. また，解くべき問題やネットワークに対してそれぞれ，向き不向きがあり，問題やネットワークに依存しない最適な方法は見つかっていない. 従って，未知のネットワークを考慮した際には，プロセス毎に様々な試行を施し，実験結果に基づいた最適点を選択する必要がある.

本稿では，通常の誤差逆伝搬で計算された勾配を用いた学習手法において，その更新量を調節する学習係数（LR）を対象とし，短時間の事前学習だけで未知のネットワーク構造に適した LR を選択する，短期事前学習（Short-Term Pre-Training: STPT）を用いたアルゴリズムを提案する. また，本手法を用いることで，未知のネットワークの性能を素早く評価できる.

連絡先：山田和樹，神戸大学大学院 システム情報学研究科 情報科学専攻 アーキテクチャ研究室，yamada.kazuki@cs28.cs.kobe-u.ac.jp

2. 短期事前学習（STPT）による適応的 LR 調節

2.1 アルゴリズム概要

提案アルゴリズムの概要図を図 1 に示す. 提案アルゴリズムの主な特徴は，複数の LR 候補を用いて学習を行う点と，1エポック以内の僅かなミニバッチの反復回数（イタレーション）のみで各 LR 候補の評価を行う，短期事前学習（STPT）を用いる点である. 提案アルゴリズムでは，1 つのエポックを Pre-train と Main-train の2つのフェーズに分けて学習を行う.

最初に，第 1 フェーズである Pre-train を行う. Pre-train では n 台のワーカにそれぞれ異なる LR 候補を分配し，各ワーカの LR と LR 初期値をそれぞれ掛け合わせた値を，実行的 LR として，学習を行う. これにより LR 初期値に対してある一定の幅を持たせた m 種類の実行的 LR を評価することができる. Pre-train 開始時の各ワーカの初期値は，LR 候補以外すべて同じである. また，m ($\leq$ n)個の LR の評価を想定し，各ワーカでそれぞれ独立した学習を行う. ここで最も重要な点は，Pre-train では α イタレーションのみ学習を行う点である. 尚，学習全体のイタレーション数を $\alpha + \beta = 1$ エポックとなるように設定する. この時，α は Pre-train のイタレーション数，β は Main-train のイタレーション数を意味する. 各ワーカはそれぞれ異なる LR を用いて，α イタレーションの学習を行い，その時点の精度を出力する. 次に，各実行的 LR の精度を比較し，最も精度が高かった実行的 LR を bestLR として選択する.

第2フェーズでは，Main-train を行う. Main-train では Pre-train において bestLR で学習したモデルを，n 台のワーカに分配し，実行的 LR に bestLR を用いた n 並列のデータ並列学習を β イタレーション行う.

以上が提案アルゴリズムにおける1エポック(α + βイタレーション)の学習フローである. Main-train 終了後のモデルを次のエポックの Pre-train の初期値として用いる. また実行的 LR は, 前のエポックの bestLR に各 LR 候補を掛け合わせた物を用いて, それぞれ学習を行う. 以上を繰り返すことで, 学習を進めていく.

2.2 例

用いる LR 候補群(LR set)を 3.0, 1.0, 0.5 として, 学習を行った場合の学習時の精度推移のグラフを図 2 に示す. 各エポックの初期段階にある3本の短い線は, Pre-train における各 LR 候補を用いた場合の精度を示し, 黒い線は bestLR を用いた, Main-train の精度推移を示している. 精度推移に注目すると, 各エポックの初期段階では精度が大きく上下するが, すぐに安定していることが分かる. これより, エポックの初期段階のみで実行的 LR の評価が可能と考え, STPT 終了後に実行的 LR の評価を行っている. これを用いることで, 複数の LR 候補の評価に必要なイタレーション数を削減することが可能である. 例として, 8つの LR 候補と8台のワーカを用いた実験において, 各 LR 候補を1エポック学習した場合と, 提案アルゴリズムの αを 200 とした場合を比較した図を図 3 に示す. この場合, 提案アルゴリズムでは 87.5%のイタレーション数を削減することができる.

3. 実験と結果

本実験では, 提案アルゴリズムの性能を評価するために画像認識を用いた実験を行った.

3.1 実装

本実験ではデータセットに ImageNet の ILSVRC2012 [6]で使用されたデータセットを使用した. このデータセットはサイズの違う 1000 カテゴリの一般物体の RGB 画像を, 学習データ 128 万枚, 検証データ 5 万枚, テストデータ 10 万枚を用意したものである. 本稿では画像のサイズを 256×256 に統一し, 実験を行う. またネットワークには ResNet50 [7]を用いた. ResNet は残差と共に学習を行い, 勾配消失問題を回避できる. そのため, ネットワークの層を増やすことが可能である. また, 最適化関数には Momentum SGD [8]を用いており, LR 候補はエポックごとに掛け合わせている. さらに, 提案アルゴリズムにおいては, 学習の初期段階に比較的小さい値の LR で学習を行う, Warmup [9]と呼ばれる手法を用いる. リファレンスとして ResNet の論文 [7]に従い, LR の初期値を 0.1 に設定し, 精度が飽和すると LR を 10 分の 1 にする手法を用いる. また, この場合に Warmup を用いると精度の劣化が見られたので, リファレンスに対して Warmup は用いない.

表 1 に実験で使用したパラメータを示す. 本実験では8並列, 1ノードの同期型データ並列を用いてソフトウエシミュレーションを行う. 提案アルゴリズムの疑似コードをアルゴリズム 1 に示す. また, アルゴリズム 1 に示している通り, Pre-train については, データ並列を使用してシミュレーションを行った. また, 実装のフレームワークとしては Chainer [10]を用いた.

3.2 Pre-train における αイタレーションの決定方法

本節では, Pre-train の実行イタレーション数である, αの決定方法について述べる. この実験ではバッチサイズを 512(=64 バッチ/ワーカ*8 ワーカ)に設定しているため, 128 万枚の学習データを全て学習するのに, 2,500 イタレーション必要である.

表 1 各パラメータ

Network	ResNet50
Number of workers	8
Batch size (per worker)	512 (64)
Training max epoch	40
Pre-train (α) iterations	200, 600, 1,250, 2,500
Weight initializations	He's initialization [11]
Momentum cofficient	0.9
Initial LR	0.1
LR set	表 2, 表 3
Warmup epoch	4
Warmup LR	0.005

従って αの最大値は2,500となる. また, 実装上の理由から αの最小値を200とする. よって αは 200～2,500 の範囲で決定することとする. ここで, αが小さいほど, 演算量は削減されるが, 学習が十分にできていない段階での LR の評価は, 学習の最終精度を悪化させる可能性がある. 逆に, αが大きいほど, 最終精度への悪影響は小さくなるが, 演算量が増えてしまう. そこで, 本実験では αの値が最終精度にどのように影響するかを調査する. 実験では αを 200, 625, 1,250, 2,500 の 4 つの値でシミュレーションを行い, 評価する. また, 本実験で用いた LR set を表 2 に示す.

図 4 は各 αを用いたときの最大精度を示している. αが 200 の時, 最も高い精度である, 0.639 を示した. 625, 1,250, 2,500 はそれぞれ 0.628, 0.622, 0.628 と, 比較的低い精度となった. また, αによる精度の変化幅は, 最大で 1.6%である. これは Pre-train におけるイタレーション数は最終精度に大きな影響を与えないことを示している. 従って本稿では αの値を 200 とした.

表 2 αを決定の際に用いる LR set

LR set	#1	#2	#3	#4	#5	#6	#7	#8
LRs	10.0	5.0	3.0	1.5	1.0	0.9	0.5	0.4

3.3 LR set の決定方法

提案アルゴリズムにおいて, 使用する LR 群である LR set の選択は重要である. この節では, LR set の決定方法について述べる. 表 3 に示す, LR 候補間の間隔の違う3種類の LR set, (a) Narrow set, (b) Middle set, そして (c) Wide set を用意し, 精度の収束性を比較する. 各 LR set の最大値と最小値をそれぞれ定め, その他の値は 1.0 を中心に等間隔になるように設定した. 他のパラメータは表 1 と同様である. 図 5 及び図 6 は(a),(b),および(c)を用いて, 40 エポック学習を行った際の精度及び LR の推移を示したグラフである. これによると,

(a) Narrow set: 最終精度は 65%. 最終精度は最も高いが, 25 エポック以降精度の減衰が見られる. 図 5 によると, 25 エポック以降は推移にばらつきがあることが分かる. これは LR 候補間の差が小さくなると, 精度の差が GPGPU の演算時に生じるノイズに負けてしまうためであると考えられる. 結果的にこのばらつきが精度に悪影響を与えてしまっている.

(b) Middle set: 最終精度は 63.4%. 最終精度は 2 番目だが, 学習が途中で止まっている.

(c) Wide set: 最終精度は 61.4%. 最終精度は最も悪く, 学習速度も遅いが, 40 エポック時点でも学習が進んでいる. 理由として, LR が小さくなりすぎているためである. しかし, LR 候補間の差が大きく, LR の評価を正しく行えるため, 学習後期でも学習が進んでいると考えられる.

以上の結果を基に，表 4 に示すスケジュールで LR set を組み合わせた．これを Mix と呼ぶ． Mix のシミュレーション結果の精度及び LR の推移を図 7，図 8 に示す．結果として，Mix は，最も高い精度であった(a)と比べて，1.2%向上した．(a)では 25 エポック以降に精度の減衰が見られたが，Mix ではこれを回避することができた．本スケジュールの様に LR set を組み合わせることで，各 LR set の欠点を補うことができる．また，Mix はリファレンスと比較して精度が 4.8%向上している．

以上より，STPT を用いた適応的学習係数調整手法では，従来手法と比較して，87.5%の演算量を削減し，4.8%の精度向上を達成した．

表 3 LR sets

Values	(a) Narrow set	(b) Middle set	(c) Wide set
#1	1.25	2.50	5.00
#2	1.17	2.00	3.67
#3	1.08	1.50	2.33
#4	1.00	1.00	1.00
#5	0.95	0.85	0.80
#6	0.90	0.70	0.60
#7	0.85	0.55	0.40
#8	0.80	0.40	0.20

表 4 Mix: LR set 変更スケジュール

Epoch	1–4	5–19	20–29	30–40
LR set	Warmup	(a) Narrow	(b) Middle	(c) Wide

4. 今後の研究

今後の研究では，提案アルゴリズムに Adam や AdaGrad 等他の手法を組み合わせる．また，LARS [9]に適応することで，巨大なバッチサイズの並列学習を行えると考える．

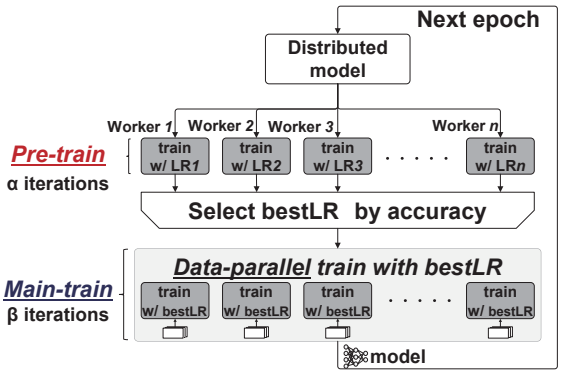


図 1　提案アルゴリズムの概要図

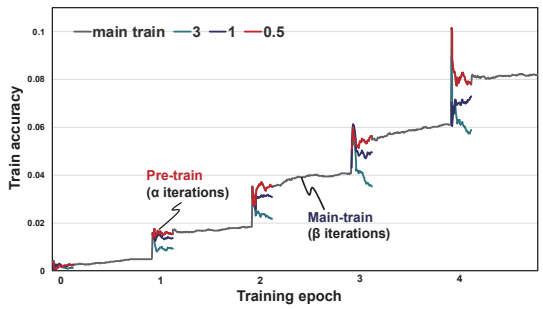


図 2　提案アルゴリズムを実行した際のコンセプト図

謝辞

この成果は、国立研究開発法人新エネルギー・産業技術総合開発機構（NEDO）の委託業務の結果得られたものです。

参考文献

[1] A. Krizhevsky, I. Sutskerver and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," Neural Information Processing Systems Conference, 2012.

[2] H. Mori, "A LAYER-BLOCK-WISE PIPELINE FOR MEMORY AND BANDWIDTH REDUCTION IN DISTRIBUTED DEEP LEARNING," MLSP, 2017.

[3] M. D.Zeoler, “AdaDelta: An Adaptive Learning Rate Method,” 2012.

[4] D. Kingma , J. Ba, “Adam A Method for Stochastic Optimization,” 2014.

[5] J. Duchi, E. Hazan , Y. Singer, “Adaptive Subgradient Methods for Online Learning and Stochastic Optimization,” 2011.

[6] "IMAGENET," [Online]. Available: http://www.image-net.org/.

[7] K. He, X. Zhang, S. Ren and J. Sun, "Deep Residual Learning for Image recognition," Microsoft Research, 2015.

[8] N. Qian, "On the momentum term in gradient descent learning algorithms," *Neural Networks : The Official Journal of the International Neural Network Society,* vol. 12, no. 1, p. 145–151, 1999.

[9] P. Goyal, P. Dollar, R. Girshick , P. Noordhuis, “Accurate, Large Minibatch SGD: Training ImageNet in 1 Hour,” 2017.

[10] P. Networks, "Chainer," [Online]. Available: https://chainer.org/.

[11] K. He, X. Zhang, S. Ren , J. Sun, “Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification,” arXiv, 2015.

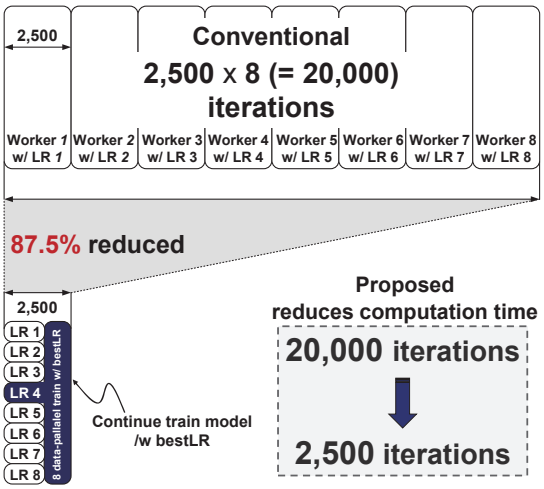


図 3　提案アルゴリズムと従来手法の比較

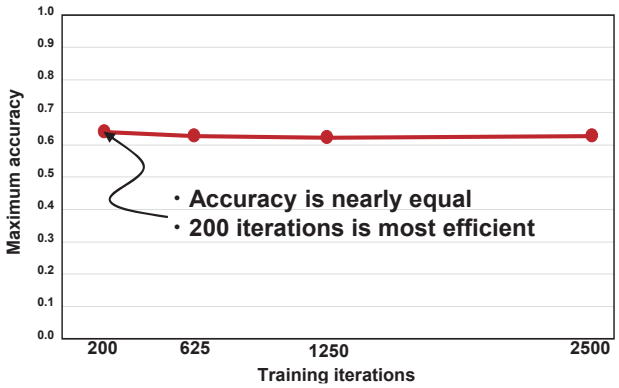


図 4　α が 200，625，1250，2500 の時の最大精度

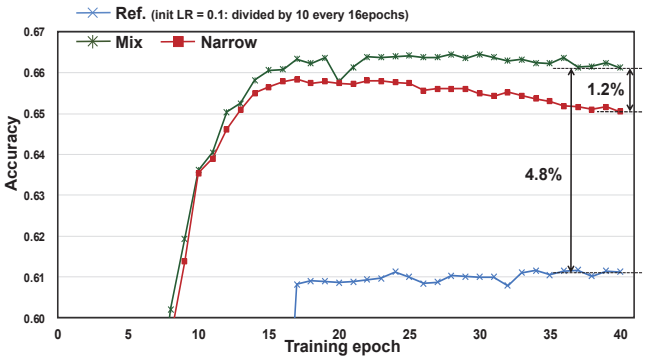


図 7　Mix，(a)Narrow set，Ref.の精度推移

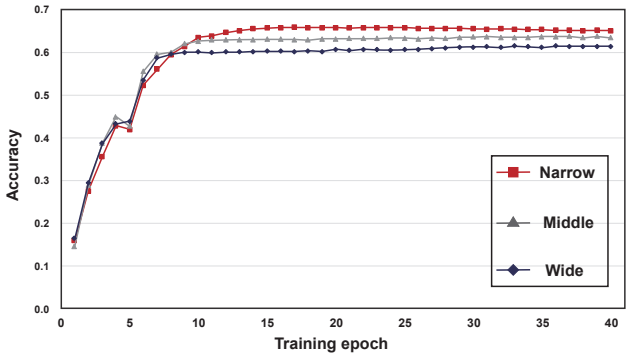


図 5　(a),(b),(c)を用いた際の LR 推移

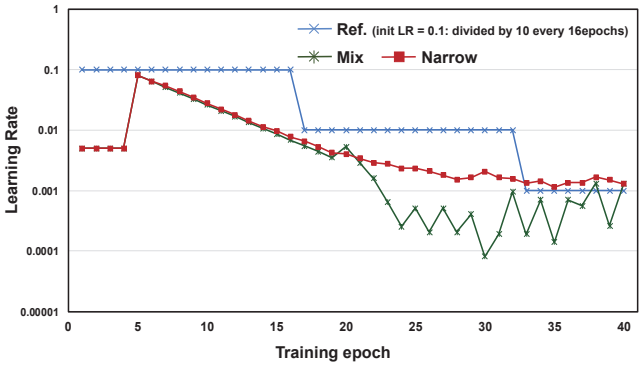


図 8　Mix，(a)Narrow，Ref.の LR 推移

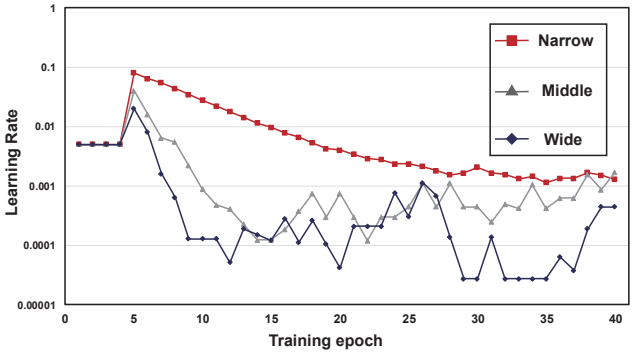


図 6　(a),(b),(c)を用いた際の LR 推移

アルゴリズム 1：提案アルゴリズムの実装

```
for epoch in range(max_epoch + warmup_epoch)
  if epoch < warmup_epoch
      run warmup train with warmup_LR using data parallel
  else
      #initialization
      best_accuracy = 0.0
      bestLR = 0.0
##-------------------------Pre-train-------------------------##
      for LR_index in range( len( LR_set ) )
          new_accuracy = run pre_train with
LR_set[ LR_index ] using data parallel
          if new_accuracy > best_accuracy
              bestLR = LR_set[ LR_index ]
```

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

非定常環境における認知的満足化価値関数の適応性能

Adaptability of Cognitive Satisficing Algorithm in Nonstationary Environments

花安 勇人 *1 Yuto Hanayasu　齋藤 建志 *2 Kenshi Saito　吉井 佑輝 *1 Yuki Yoshii　甲野 佑 *1 Yu Kono　高橋 達二 *1 Tatsuji Takahashi

*1東京電機大学理工学部 School of Science and Engineering, Tokyo Denki University

*2東京電機大学大学院 Graduate School of Tokyo Denki University

The environments where an agent performs trial-and-error learning is generally nonstationary because of unobservable information and various kinds of fluctuations. In order to make effective decisions in such an environment, the agent has to gradually or abruptly discard old information and put more weight on newer information, because some of the elements in the environment may have changed. As a result, there is a necessity of choosing a better option with smaller amount of information. We focus on the risk-sensitive satisficing (RS) algorithm which models the decision-making strategy of human beings and animals. We compare its performance in stationary and nonstationary bandit problems with other representative algorithms. We propose variants of RS combined with existing ideas for adaptation for nonstationary bandits such as meta-bandit and discounted update.

1. はじめに

近年，深層学習の目覚しい発展により，画像認識をはじめ現実での応用事例が増えてきている．深層学習は試行錯誤によって, 自律的に行動手順を学習するある種の万能性を有する強化学習 [Sutton 98] とも結びつき，従来困難だった人間レベルのビデオゲームのプレイを可能にした [Mnih 15]．しかしながら，強化学習の主要な問題である活用と探索のバランシングに関して，深層学習は直接的な解決策を与えていない．現在最適だと見積もられている行動を通して利益を追求する活用と，利益を捨ててでも真に最適な行動を探し出そうとする探索は同時に行うことができない．このような主体的な活用と探索が必要となる最も単純な課題の一つに多腕バンディット問題が存在する．多腕バンディット問題に対して探索と活用のバランシングを考慮し，適した試行錯誤を与える意思決定アルゴリズムは複数存在するが，基本的に環境が変化しない固定された定常環境を前提にしたものである．しかしながら, 往々にして現実の問題は非定常な環境である．そこで, 我々は実際に非定常な環境下で生きる人間の意思決定傾向を有する認知的満足化価値関数 (Risk Sensitive Satisficing Value Function: RS) を用いた選択アルゴリズム (RS アルゴリズム)[高橋 16] に着目した．本研究では非定常環境でのバンディット問題において RS アルゴリズムのバリエーションと既存のアルゴリズムを比較し，人間の意思決定傾向である満足化を利用することでの高い柔軟性を示す．

2. 多腕バンディット問題と非定常な環境

多腕バンディット問題ではエージェントが, 未知の報酬確率 $\{p_1, p_2, \ldots, p_k\}$ が割り当てられた行動 $\{a_1, a_2, \ldots, a_k\}$ の中から毎回一つ選択し，試行錯誤しながら得られる報酬を最大化することを目的とした最も単純な強化学習課題である．与えられる報酬が 1 か 0 のベルヌーイ試行からなるものをベルヌーイバンディットと呼び，本研究ではこれを扱う．現実には選んだ広告 (行動) がクリック (報酬) されるか否かという広告配信などの応用例と対応づけられる．多腕バンディット問題では最適な手段を知るために，現状は非最適な行動をあえて探索的に試行する必要がある．しかし前述の通り，高い累積報酬を得る (活用) ためにはどこかで探索を打ち切らなければならないという速さと正確さのトレードオフを端的に表した課題であり，探索と活用のバランシングが問題となる．バンディット問題において，このバランシングの良し悪しは，最適な行動を最初から知っていた場合に得られる報酬の累積の期待値との差分からなる regret で評価される．この regret が小さいほど，無駄なく報酬を最大化できたことを意味し，多くのバンディット問題のアルゴリズム (バンディットアルゴリズム) はこれの最小化を目指す．

$$\text{regret} = p^* N - \sum_{t=0}^{N} p_t \tag{1}$$

ここで変数 N は総試行回数，p^* は最も高い報酬確率であり，p_t は開始から t 回目に選択した選択肢の報酬確率である．Upper Confidence Bound (UCB) 系のアルゴリズム (UCB1-tuned[Wang 05], KL-UCB) や Thompson Sampling [Agrawal 12] など regret をなるべく小さくするバンディット問題に適したアルゴリズムが存在するが，これらは定常環境を前提としている (以下では UCB1-tuned を UCB1T，Thompson Sampling を TS とそれぞれ記載する)．しかし，現実的には対応すべき環境は非定常であり，既に最善の行動を見つけていても, 環境の変化によって探索を再開する必要がある場合を考慮しなければならない．これに対して複雑な準備をせず，迅速に対応するのは難しい．

3. RS アルゴリズム

人間の意思決定ではある基準を定め，基準を超える価値を持った選択肢を探索し続け，発見した場合は探索をやめて満足するという傾向がある．この意思決定における傾向を満足化と呼ぶ．満足化は，最も高い価値の選択肢を探索する最適化に比べ，基準の設定によって探索の打ち切りを早めることができるという利点がある．そのような基準の達成を目的に，観測された報酬期待値と思考回数から定義される認知的な価値関

連絡先: 高橋達二，東京電機大学理工学部，350-0394 埼玉県比企郡鳩山町大字石坂，049-296-1642, tatsujit@mail.dendai.ac.jp

数として，満足化価値関数 (Risk Sensitive Satisficing Value Function: RS) が考案されている [高橋 16].

$$RS_i = n_i\delta_i = n_i(E_i - \aleph) \tag{2}$$

ここで，n_i は行動 a_i を試行した回数, E_i は行動 a_i によって得た報酬の平均, $\aleph$ は満足化基準値である．そして, 常に最大の RS_i を持つ行動 a_i を選択する意思決定アルゴリズムを RS アルゴリズム (以下，断りがなければ RS はアルゴリズムのことを示す) と呼ぶ．RS は非満足状態 ($E_i < \aleph$) であれば楽観的探索を行う．すなわち試行回数 n_i が少ない方が価値が高く，過小評価しないようになっている．一方，満足状態 ($\aleph < E_i$) は悲観的利益追求を行う．これは試行回数 n_i が大きいほど価値を高く評価し，満足状態の確実性を試行回数で保証している．また，$\aleph$ を最大の報酬確率 p_{first} とその次に大きい報酬確率 p_{second} の間に設定することで満足化は最適化となる．そのため，満足化基準値 $\aleph$ が以下のように設定された場合，最適切基準 $\aleph_{\text{opt}}$ と呼び，$\aleph_{\text{opt}}$ を用いた RS アルゴリズムを RS-OPT アルゴリズムと呼ぶ.

$$\aleph_{\text{opt}} = \frac{p_{\text{first}} + p_{\text{second}}}{2} \tag{3}$$

しかし，$\aleph_{\text{opt}}$ は報酬確率が既知のものとしているため活用は困難である．そこで，以下のように初期値 $\aleph_0$ から基準値を更新することで条件 (5) を目指す.

$$\aleph = \aleph + \alpha(E_i - \aleph) \tag{4}$$

$$P_{\text{first}} > \aleph > P_{\text{second}} \tag{5}$$

式 (4) によって求められる基準値 $\aleph$ は $a_{\text{select}} = a_{\text{first}}$ であるならば P_{second} を超えて条件式 (5) を満たすことができる．しかし， 式 (4) が条件式 (5) を満たす保証はないことに注意しなければならない.

4. 非定常環境に対処するアルゴリズム

環境が変異したという直接的な情報をエージェントが得られない場合，それはエージェントにとって非定常な環境であると言える．前述の UCB1T や TS は定常環境を前提として regret を最小化するアルゴリズムであり，一般に非定常環境には対応できない．そこで環境から得られる間接的な情報である報酬から環境の変化を察知したり，過去の情報の廃棄 (忘却) を用いて非定常環境に対応するアルゴリズムが考案されている.

4.1 メタバンディットアルゴリズム

非定常な多腕バンディット問題に対しては, 一般的にメタバンディットアルゴリズムが用いられる [Hartland 06]．メタバンディットは環境の変化の検出と，検出後の処理の組み合わせからなる．環境の変化は下記の Page-Hinkley 統計量 PH_T より, 最も高い価値をもつ選択肢を選び続けた結果, 得られた報酬の獲得割合の変化から検出する (PH_T が閾値 λ を超えると環境が変化したと判断する).

$$\overline{r_t} = \frac{1}{t}\sum_{l=1}^{t} r_l \tag{6}$$

$$m_T = \sum_{t=1}^{T}(r_t - \overline{r_t} + \delta) \tag{7}$$

$$M_T = \max\{m_t, t = 1 \ldots T\} \tag{8}$$

$$PH_T = M_T - m_T \tag{9}$$

$$\text{Change alarm} = \begin{cases} \text{true} & (PH_T > \lambda) \\ \text{false} & (\text{otherwise}) \end{cases} \tag{10}$$

そして変化が検出されると “従来の観測情報を記憶している旧エージェント” を保持したまま “観測情報を初期 step の状態に戻した新規エージェント” を生成する．また，新旧どちらのエージェントで意思決定を行うかを選ぶ上位エージェントを生成する．その後 L step の間，上位エージェントは旧エージェントと新規エージェントのどちらで意思決定を行うかを選び，選ばれたエージェントはこの環境に対して意思決定を行う．この L step の間をメタバンディット期間と呼ぶ．そしてメタバンディット期間終了後，旧エージェントと新規エージェントで高い報酬を得られていた方を残し，一方のエージェントと上位エージェントを破棄する．そして環境の変化の検出を再開する．メタバンディット期間に実際の環境に対して選択肢を試行して得られた報酬情報は新旧エージェントの両方に共有される．両者の違いはそれ以前の観測情報を持っているか否かである．また，上位エージェントには, 新旧どちらのエージェントが意思決定を担い，報酬を得ることができたかを記憶していく．本研究では UCB1T と TS, RS, RS-OPT アルゴリズムにメタバンディットアルゴリズムを適用して意思決定を行う (Meta UCB1T，Meta TS， Meta RS， Meta RS-OPT).

4.2 忘却率付き RS アルゴリズム

RS アルゴリズムは最適切基準を設定することで定常環境下において理論的保証と高い性能をもつアルゴリズムである．しかし，RS 値は試行回数 n_i の増加によって ∞ もしくは $-\infty$ に発散してしまう．そのため，報酬確率が非定常な場合に満足できる腕への切り替えが遅くなる場合がある．さらに，満足化価値関数 RS が，人間の満足化を目指す意思決定傾向から考案されたことから考えると，信頼度として RS に用いられている試行回数 n_i は発散するが, 人間の満足度合いが際限なく増加することは考えにくい．そこで，n_i の更新に忘却率 γ を導入して過去の情報を忘却しつつ, RS 値の発散を抑えるために各ステップごとに全ての w_i, l_i を以下のように更新する [甲野 13].

$$w_i = \begin{cases} \gamma w_i + 1 & (a_i = a_{\text{select}} \wedge e) \\ \gamma w_i & (\text{otherwise}) \end{cases} \tag{11}$$

$$l_i = \begin{cases} \gamma l_i + 1 & (a_i = a_{\text{select}} \wedge \neg e) \\ \gamma l_i & (\text{otherwise}) \end{cases} \tag{12}$$

ここで，a_{select} はそのステップで選択した行動で, e は行動 a_i をして報酬を獲得できたことを意味する．満足化価値関数 RS の更新において，式 (11)，(12) で更新された信頼度 $n_i = w_i + l_1$ を用いた満足化価値関数に対して最大の選択肢を選ぶアルゴリズムを RSγ アルゴリズムと呼ぶ．また，同様に期待値 E_i に関しても忘却率を伴った更新 w_i, l_i によって更新された $E_i = w_i/(w_i + l_1)$ を用いて計算する．そして，RSγ との比較のためにこの忘却率を用いて減衰した w_i, l_i を用いてベータ分布のハイパーパラメータを更新する Thompson Sampling を新たに TSγ として定義する．この時，全ての行動の集合を $\mathbf{A}$ とすると k ステップ目での全体の和 N_k は以下のようになる.

$$N_k := \sum_{i \in \{i | a_i \in \mathbf{A}\}} (w_i + l_i) \tag{13}$$

$$\begin{aligned} N_{k+1} &= \gamma w_1 + \gamma l_1 + \gamma w_2 + \gamma l_2 + \cdots + \gamma w_{|\mathbf{A}|} + \gamma l_{|\mathbf{A}|} + 1 \\ &= \gamma N_k + 1 \end{aligned} \tag{14}$$

忘却率 γ が条件 $-1<\gamma<1$ を満たすならば以下が成り立つ．

$$\lim_{k\to\infty} N_k = \frac{1}{1-\gamma} \tag{15}$$

したがって，式 (11)，(12) による更新を行うことで RS 値が ∞ もしくは $-\infty$ に発散することを防ぐことが可能である．本研究では参考文献 [甲野 13] を参考に，忘却率 $\gamma = 0.999$ とした．

5. バンディットシミュレーション

以降, 式 (4) で算出される基準値を使用する満足化価値関数 RS を RS，RS を用いたメタバンディットアルゴリズムを Meta RS と表す．パラメータは $\lambda = 30$, $\delta = 0$, $\gamma = 0.999$, $\alpha = 0.001$, $\aleph_0 = 1.0$ と設定し, UCB1T, TS, RS, RS-OPT, TS γ, RS γ, RS-OPT γ, Meta UCB1T(L=500), Meta TS(L=30), Meta RS(L=30), Meta RS-OPT(L=30) を以下の多腕バンディットシミュレーションで比較する．性能の指標としては，最も高い行動の報酬確率と選んだ行動の真の報酬確率の差である regret を用いる．

5.1 定常環境でのシミュレーション

環境が変化しない多腕バンディット問題で各種アルゴリズムを比較する．選択アルゴリズムに従い, 選択を総 step 数として 100,000 steps 行い，その 1,000 シミュレーション回分を平均して regret を算出した．選択肢は 20 通りあり，全ての選択肢の真の報酬生起確率は，シミュレーション開始時に一様分布から独立に決定されて以降 100,000steps の間は変化しない．1,000 シミュレーションのあいだ毎回，全ての選択肢の真の報酬生起確率はサンプリングし直される．

5.1.1 定常環境でのシミュレーションの結果と考察

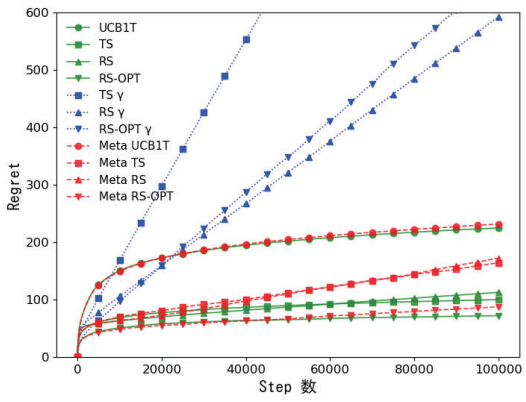


図 1: 定常環境 20 本腕バンディット問題での regret の推移

図 1 は定常環境での regret の推移を示している．忘却率 γ 用いていないアルゴリズムは regret が 250 以下に収まっているのに対し，忘却率 γ を用いたアルゴリズムは 500 以上まで伸びてしまっている． このことから忘却率 γ が定常環境での TS, RS, RS(OPT) の性能を低下させていることが分かる．一方で，Meta UCB1T, Meta TS, Meta RS, Meta RS-OPT は環境の変化の検出がなければ， それぞれ UCB1T, TS, RS, RS-OPT と同じ振る舞いをするが， 今回のシミュレーションでは環境の変化の誤検出を行ってしまい，regret が増えてしまっている．また, Chernoff Bound を背景に持ち，比較的優れている TS よりも最適切基準値を有する RS-OPT の方が優っている [Tamatsukuri 18]．Meta TS，Meta RS-OPT のシミュレーション結果も見ると，RS-OPT のこのような達成したい基準というただ一つのパラメータを与えるだけで優れた成績を示すのはメタバンディットアルゴリズムに用いた場合も変わらないことが示された．また, RS-OPT のシミュレーション結果より, RS の動的基準値更新を改善し, 今よりもう少し最適に近い基準を設定することができれば, 定常環境において TS を上回ることが期待できる．

5.2 非定常環境でのシミュレーション

環境が不定期的に変化する多腕バンディット問題で各種アルゴリズムを比較する．選択アルゴリズムに従い, 選択を総 step 数として 100,000 steps 行い，そのシミュレーション 1,000 回分を平均して regret を算出した．選択肢は 20 通りあり，全ての選択肢の真の報酬生起確率は，シミュレーション開始時に一様分布から独立に決定される．定常環境シミュレーションとの違いは，シミュレーション開始から，step 毎に 1/10000 の変異確率で各選択肢の真の報酬生起確率が一様分布から独立に再設定されることである．選択肢ごとの変異が独立で非同期なため, 各エージェントは選択肢の変化を直接的に観測することはできず，また，そのタイミングを学習することができない．

5.2.1 非定常環境でのシミュレーション結果と考察

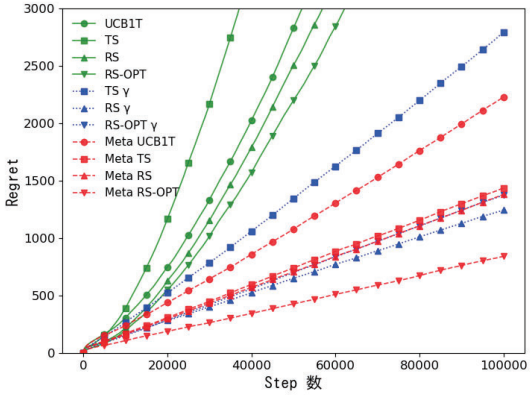


図 2: 非定常環境 20 本腕バンディット問題での regret の推移

図 2 は非定常環境での regret の推移を示している．UCB1T, TS, RS, RS-OPT は環境の変化に適応できず, regret が 6000 以上に跳ね上がってしまっている．また, Meta UCB1T と TS γ も regret が 2000 以上まで増えていて, 優秀とは言えない．一方で, RS γ, RS-OPT γ, Meta TS, Meta RS, Meta RS-OPT は regret が 1500 を下回っている．定常環境では, regret が多かった RS γ だったが, 非定常環境では, 最適切基準値を与えないアルゴリズムの中で最高の成績を残している．また，定常環境では, Meta RS は Meta TS より regret が多かったが, 非定常環境では, その関係が逆転している．さらに Meta RS-OPT と Meta TS の違いは定常環境と同じく，ただ一つの達成したい基準値パラメータ (最適切基準値) を与えるのみだが，非定常環境でも優れた成績を示せた．

5.3 定常環境と非定常環境での成績の総合考察

図 3，表 1 は各アルゴリズムの定常環境，非定常環境の 100,000 step 時点での regret の比較を示している．

図 3 では左下に近いほど，当該のアルゴリズムが定常，非定常環境の両方で優れていることを示す．Meta TS と Meta

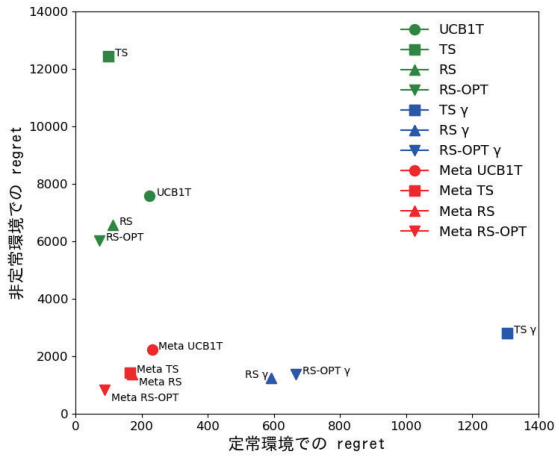


図 3: 100,000 step 時点での定常環境 (横軸)・非定常環境 (縦軸) regret 比較図

表 1: 100,000 step 時点での regret

	定常環境	非定常環境
UCB1T	224.6	7576.7
TS	100.0	12436.1
RS	112.5	6574.8
RS-OPT	71.9	6016.6
TS γ	1306.1	2793.5
RS γ	592.4	1246.0
RS-OPT γ	665.5	1375.7
Meta UCB1T	231.7	2228.9
Meta TS	164.2	1436.7
Meta RS	172.0	1381.7
Meta RS-OPT	87.6	842.7

RS がほぼ互角の水準であり，Meta RS-OPT がさらにそれに優れた性質を有している．これはメタバンディットアルゴリズムの定常環境のときは定常を考慮したアルゴリズムとして振る舞い， 非定常環境のときは非定常を考慮したアルゴリズムとして振る舞う柔軟性を示している．一方で, RS γ，および RS-OPT γ は常に忘却するという定常環境では不利なアルゴリズムではあるが，TS γ に対しては 定常環境，非定常環境での成績を比較的両立していると言える．これは人間の意思決定傾向を背景に持つ RS の柔軟性を示しており，メタバンディットアルゴリズムと比較して, 忘却率付き更新の容易さから，この点も RS の利点だと言える．

6. おわりに

以上の結果より，RS アルゴリズムが定常，非定常環境において有用であることが分かった．最適切基準値を与えないアルゴリズムの中で, 定常環境では TS ，非定常環境では RS γ が最も優秀な結果を残したが， Meta RS, Meta TS は一組のパラメータで定常，非定常問わず，優秀な結果を残した．現実の問題では環境が非定常であることが多く，環境の変化のタイミングや頻度を予測できない場合も多くあるため, この二つのアルゴリズムは現実の問題に対しても有用であると言える．また, 達成したい基準値パラメータ (最適切基準値) が与えられていれば, 定常・非定常問わず, 最も優秀な成績を残した Meta RS-OPT は最適切基準値をある程度予測できる場合には現実の問題にも有用であり, 動的に満足化基準値を設定する Meta RS や RS の潜在能力を示していると言える．

参考文献

[Agrawal 12] Agrawal, S., Navin Goyal, N.: Analysis of thompson sampling for the multi-armed bandit problem. In: *Proceedings of the 25th Annual Conference on Learning Theory* (COLT). (2012)

[Hartland 06] C. Hartland, S. Gelly, N. Baskiotis, O. Teytaud, and M. Sebag, Multi-armed bandit, dynamic environments and meta-bandits, In: *Advances in Neural Information Processing Systems(NIPS-2006) Workshop, Online Trading Exploration Exploitation*. (2006)

[Mnih 15] Mnih, V., Kavukcuoglu, K., Silver, D., Hassabis, D., et al.: Human-level control through deep reinforcement learning. *Nature*, 518(7540), 529-533. (2015)

[Sutton 98] Sutton, R. and Barto, A.: *Reinforcement Learning: an Introduction*, MIT Press. (1998)

[Tamatsukuri 18] Tamatsukuri, A. and Takahashi, T: Guaranteed satisficing and finite regret: Analysis of a cognitive satisficing value function, arXiv:1812.05795. (2018; manuscript under revision)

[Wang 05] S. Gelly, Y. Wang., R. Munos. and O. Teytaud.: Modification of UCT with Patterns in Monte-Carlo Go, *INRIA Technical Report*, No.6062. (2005)

[甲野 13] 甲野佑, 高橋達二, 価値推論ヒューリスティクスとしての規準学習と忘却, In: *Proceedings of 30 th Japanese Congnitive Science Society (JCSS)*, 74–79. (2013)

[高橋 16] 高橋達二, 甲野佑, 浦上大輔, 認知的満足化 限定合理性の強化学習における効用, 人工知能学会論文誌, 31(6), AI30-M_1–11. (2016)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

実数値遺伝的アルゴリズムの遺伝子分布情報と解探索進捗率を活用した変数選択手法の提案

A proposal of a new variable selection method utilizing gene's distribution information and solutions search progress rate of Real-coded genetic algorithms

小畑崇弘　　倉橋節也
Takahiro Obata　　Setsuya Kurahashi

*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 variable selection and parameter optimization are getting more and more important. Regarding parameter optimization, much attention has been paid to Real-coded Genetic Algorithms (RCGA) because of their good searching ability and high flexibility. As for variable selection, traditionally Akaike Information Criterion (AIC) or Bayesian Information Criterion (BIC) are used quite often as selection criteria. These criteria estimate the relative quality of analysis models for a given set of data, but do not evaluate the importance of the variables themselves. This paper proposes a new variable selection method applying RCGA. This new variable selection method consists of 2 main components. The one is a new variable selection criterion utilizing the variances of genes in RCGA and the other is an estimation method of how far is in progress of RCGA optimization. The effectiveness of this new variable selection method is confirmed through application to a multiple linear regression model.

1. はじめに

近年，計算機システムや計測・測定技術の発展により，様々な分野で大量かつ複雑なデータの獲得と蓄積が進み，それに伴い，多数の分析データから重要なものを選ぶ変数選択手法の重要性が高まっている．また，分析モデルの複雑化も進んでおり，モデル内のパラメータ推定の難易度が高まっている．これらの問題に対し，本稿では実数値遺伝的アルゴリズム（RCGA）の同一世代内における遺伝子の分散を活用した変数選択指標とRCGA による解探索進捗率の推計値を用いた変数選択手法を提案する．当手法を用いることで，遺伝的アルゴリズム（GA）の枠組みの中でパラメータ推定と変数選択の両方に対応できる可能性を示す．

本稿の構成は次の通りである．2 章で，関連研究として GA および変数選択について概略する．3 章では新たな変数選択指標として，遺伝子の分散を活用した I 値について説明する．4 章では，変数選択のタイミングを判定するために GA による解探索の進捗率という考えを導入し，その推計方法について説明する．5 章は I 値と進捗率を用いた変数選択手法の実行結果についてで，6 章はまとめである．

2. 関連研究

2.1 実数値遺伝的アルゴリズム

遺伝的アルゴリズムは進化計算の一種で，環境に適応した生物が生き残り，適応できなかった生物が死滅する自然淘汰の考え方が取り入れられており [goldberg 89]，(1) 目的関数の微分可能性を仮定する必要がない，(2) 大域的探索が可能，といった特徴を持つ．

GA では遺伝子型として古くから 0 と 1 によるビットコーディングが使われてきたが，実数値パラメータを扱う最適化問題を解く場合，遺伝子型空間の位相構造は表現型空間である実数空間の位相構造とは異なっており，表現型空間において互いに近い二つの親個体から生成された子個体が，遺伝子型空間では親個体の近傍にあっても表現型空間上で親個体の近傍に生成されるとは限らない．従って GA による探索の後半で有望な領域を重点的に探索したい場合に探索範囲が大きく移動してしまう恐れがあり，探索に無駄が生じる可能性が指摘されてきた．

こうした指摘に対応したのが，遺伝子型として実数値ベクトルを扱う RCGA である [wright 91]．RCGA は，子個体生成（これを交叉と呼ぶ）の際に実数値ベクトルを直接操作するので，表現型空間における親個体群の近傍に子個体群を生成することが出来る．そのため，従来のバイナリコーディングに較べて実数値を扱う問題では解の探索効率が格段に向上する．

RCGA の解の探索能力は，交叉モデルと世代交代モデルにどのような手法を組み合わせるかによって決まる．本稿では RCGA の世代交代モデルとして Just Generation Gap (JGG) を，交叉モデルとして AREX を用いた [秋本 07][秋本 09-1][秋本 09-2]．JGG と AREX の組み合わせは解の探索能力に優れた代表的な組み合わせである．簡単に各モデルを紹介すると，JGG は多親交叉に適したモデルで，生存選択の対象は子個体に限定され交叉に参加した親固体は全て淘汰される．AREX は多親交叉の一般的枠組みである REX[小林 09] に初期収束を回避するための仕組みを取り入れた手法である．その一つは交叉の拡張率を適応的に調節する仕組みで，集団が重心移動中に交叉による子個体生成領域を広げるようにコントロールすることで局所解への初期収束を回避する．もう一つは交叉中心降下というもので，子個体の生成分布の中心を親個体群の重心から最適解のあると思われる方向にシフトさせる仕組みであり，この概念を導入したことにより，最適解が初期化領域外にある場合でも解に到達する能力が向上している．

2.2 変数選択

複数のモデルの中からデータをうまく説明するモデルを選択することをモデル選択という．モデル選択の中でも，多数の説明変数の中から目的変数の変動を説明するのに適した変数を取捨選択する問題を，特に変数選択という．

変数選択を行う際にはモデルを比較する順番を決める変数選択アルゴリズムと，モデルの優劣を判断する選択基準の二つが重要である．

連絡先: 氏名，所属，住所，電話番号，Fax 番号，電子メールアドレスなど

2.2.1 変数選択アルゴリズム

変数選択アルゴリズムの中で最も確実な方法は，可能な変数の組み合わせを全て比較する総当たり法である．しかし説明変数の数を p とすると組み合わせの総数は $2^p - 1$ となり，説明変数が 10 個の場合は組み合わせ数は 1,023，説明変数が 20 個になると 1,048,575 といった具合に説明変数の増加によって計算コストが爆発的に増大してしまう．そこで準最適な方法として，変数増加法，変数減少法，変数増減法などが用いられている．

2.2.2 変数選択基準

変数選択の基準は様々なものが用いられてきた．古くは残差平方和が利用されてきたが，説明変数の数が増えれば残差平方和は必ず小さくなるため残差平方和をそのまま用いるのではなく，残差平方和に修正を加えた自由度調整済み決定係数や Mallows の提案した C_p が利用されるようになった．その後，真の分布に対する予測分布の良さという視点から赤池情報量規準（AIC）が提唱され，広く活用されるている．さらにベイズ情報量規準（BIC）や最小記述長（MDL）原理などの基準も提案され，状況に応じて各基準が用いられている．

情報量基準による変数選択の場合，変数の重要性に関する情報が陽には示されず，最終的に選ばれたモデルの変数を受け入れるしかない．特に，非連続・非線形なモデルの場合は，変数の重要性をどのように評価するかが課題となる．

2.2.3 変数選択に GA を応用した事例

変数選択に GA を応用した既存研究としては [Broadhursta 97][栗田 94] などがある．これらの研究では GA を変数選択アルゴリズムの替わりに用いており，本稿で目指すものとは軸を異にしている．

3. RCGA の遺伝子の分散を活用した変数選択指標

3.1 遺伝子の分散と標準誤差

分析モデル内のあるパラメータの変化がモデルの評価値に与える影響の大きさはパラメータによって異なり，その相違が RCGA でパラメータ推定をする際の遺伝子の分散の大小に反映されていると考えられる．[小畑 18] はこの点を検証するため，(1) 式のような線形回帰モデルを用いて実験を行った．

$$y = a_0 + a_1 \cdot x_1 + \cdots + a_p \cdot x_p \tag{1}$$

(1) 式の y は目的変数，x_1〜x_p は説明変数，a_0 は定数項，a_1〜a_p は回帰係数，p は説明変数の数である．この式の定数項および回帰係数を RCGA によって推定し，その際の遺伝子の分散について分析した．2 章で説明した通り，利用した RCGA の交叉モデルは AREX，子個体生成モデルは Just Generation Gap (JGG) である．世代内の個体数や子個体生成数は [秋本 09-1] の推奨値を採用した．すなわち，個体数は問題の次元数の 10 倍，子個体生成数は次元数の 4 倍である．

各個体は定数項および各回帰係数に対応する遺伝子を持つ．遺伝子の分散についてはパラメータ毎に各個体の対応する遺伝子のみを取り出し，その遺伝子群ごとに分散を計算した．以後，遺伝子の分散を Vg と表す．例えば回帰係数 a_1 に対応する遺伝子の分散は Vg_{a1} と表す．

実験結果の分析から，RCGA によるパラメータ推定が収束した状態では，あるパラメータに対応する Vg の値と重回帰分析による当パラメータの標準誤差がほぼ比例するという関係を見出した．この関係は (2) 式のように表せる．

$$\frac{Vg_a}{STD_a} \simeq \frac{Vg_{a1}}{STD_{a1}} \simeq \cdots \simeq \frac{Vg_{ap}}{STD_{ap}} \simeq K \tag{2}$$

ここで STD_i はパラメータ i の標準誤差を表し，K はある定数を表す．

3.2 I 値の導入と変数選択

ここで，(3) 式で定義する I 値という新しい指標を導入する．

$$I_i = \frac{\nu_i^2}{V_{gi}} \tag{3}$$

I_i はパラメータ a_i に対する I 値である．ν_i はパラメータ a_i の推定値，V_{gi} は同一世代内の個体のパラメータ a_i に対応する遺伝子の分散を表す．

線形回帰モデルにおいて T 値が回帰係数÷標準誤差で表されることをを考慮すると，I 値が T 値の 2 乗（つまり F 値）と比例関係にあると期待できる．実際の分析結果でも I 値と F 値との比例関係が確認できている．T 値は説明変数の係数の有意水準の判定に用いられる．この T 値の 2 乗と比例関係にあるのであれば，I 値も係数の有意水準が反映されていると考えらえ，I 値の大小は変数選択指標として活用できる可能性がある．[小畑 18] では I 値を変数選択基準として用いた変数選択を実行し、AIC を選択基準としたステップワイズ変数選択と似た結果が得られたと報告している．

4. 最適解探索進捗率の推計

3 章で遺伝子の分散を活用した変数選択指標を導入した．しかし，どういったタイミングで変数選択を行えばいいのかは未検討であった．そこで，この章ではソフトウェア信頼度成長モデル（SRGM）の手法を応用して RCGA の最適解探索の進捗率を推計し，その進捗率に基づいて変数選択を実施することを検討する．

4.1 SRGM を応用した RCGA の最適解探索進捗率の推計

SRGM とは，ソフトウェア開発において生じる累積バグ数を推定する手法の一つで，テスト工程で検出されるバグの累積値の傾向から残存バグ数を推定する方法である．これまで様々な SRGM が論じられているが，多くが指数型や S 字型などの各モデル固有の典型的な特性を持った曲線をもとにしたものであり，あるモデルを固定的に使用すると，対象データの特性によっては残存バグ数の推定精度が低くなることが指摘されている．こうした問題を解決するひとつの手段として代表的なモデルを包含する統合モデルが提案され，特に [古山 96] は統合モデルを表す微分方程式の対数をとることにより，得られたデータ系列から対数誤差の二乗和を最小にする方法で解析的にパラメータを推定することができることを示した．統合モデルは次の微分方程式で表される．

$$\frac{d(y+\delta)}{dt} \cdot (y+\delta)^{\gamma-1} = \alpha \cdot \mathrm{e}^{-\beta t} \tag{4}$$

ここで y は時刻 t における累積バグ数である． 式 (4) は $\delta = 0$ のとき次式のように表せる．y' は時刻 t で発見されたバグ数である。

$$y' \cdot y^{\gamma-1} = \alpha \cdot \mathrm{e}^{-\beta t} \tag{5}$$

(5) 式の両辺の対数を取ると, 次のようになる.

$$\ln y' + (\gamma - 1)\ln y = \ln \alpha - \beta t \tag{6}$$

式 (6) から対数誤差の二乗和を最小にする方法で α，β，γ を推定し，そこから累積バグ数を算出するのが [古山 96] の手法であり，これを RCGA による解探索の進捗率推定に応用する．そのため，y' および y を次のように置き換える．

y ': t-1 世代の個体の評価値の平均値 − t 世代の個体の評価値の平均値（つまり評価値の平均値の改善幅）

y: y ' の累計

RCGA の解探索が順調に進めば，世代交代が進むにつれて評価値の改善幅は逓減していき，やがてゼロになることが期待できる．これはソフトウェア開発のテスト工程が進むにつれて時点ごとのバグ発見数が逓減していくのと類似している．SRGM では t 時点における最終累積バグ数予測と実際の累積バグ数の比をとることでテスト工程の進捗状況を管理するが，それと同様に t 世代における最終累計評価値改善幅の予測と実際の改善幅累計の比をとることで RCGA による解探索状況の進捗率の推計が可能になると考えられる．

前述のように，SRGM では様々な曲線をもとにしたモデルがあり，指数型，ゴンペルツ曲線，超指数型の 3 タイプを試したところ，ゴンペルツ曲線と超指数型では進捗率の推定が不安定だったことから本稿では以後，指数型モデルを用いて進捗率を推計する．指数型モデルは (7) 式で表される．N は最終累積バグ数の予測値である．RCGA の解探索の文脈では，N は評価値の平均値の改善幅の最終累計値となる．

$$y = N(1 - \mathrm{e}^{-bt}) \tag{7}$$
$$\alpha = Nb, \beta = b, \gamma = 1$$

5. I 値と最適解探索進捗率を用いた変数選択

5 章では，3 章で検討した変数選択指標，および 4 章で説明した解探索進捗率を用いた変数選択手法の実験結果について報告する．

分析に用いたデータセットはワイン品質（0〜10 までの 11 段階スコア）とワイン品質に影響する 11 項目の数値（実数値）からなる．データはカリフォルニア大学アーバイン校が提供している機械学習用データセット集から取得した．このデータセットを用いた重回帰モデルに対して提案手法による変数選択を実行した．

ワイン品質データによる重回帰分析，およびステップワイズによる変数選択結果を表 1 に示した．ステップワイズの結果，T 値の絶対値の小さい変数が変数削除されていることが分かる．

次に，同じ重回帰モデルの回帰係数を RCGA により推定し，探索が収束した段階で I 値の最も低い変数を削除することを繰り返す変数選択法を実行した．5 回の試行の結果，表 1 の変数 no でみて，9 → 2 → 5 → 4 → 7 → 10 の変数削除順は 5 回の試行全てで共通となり，その後は 6 → 8 → 11 → 3 → 1 の順が 2 回，8 → 6 → 11 → 3 → 1 が 2 回，8 → 6 → 11 → 3 → 1 が 1 回となった．この変数削除の順番は重回帰分析の T 値の絶対値の小さい順，もしくは P 値の大きい順に概ね一致しており，変数削除を 4 変数で止めた場合は AIC によるステップワイズで変数削除されたものと完全に一致する．

表 1: ワイン品質データに関する回帰分析結果

変数 no	変数名	重回帰分析 回帰係数	T 値	P 値	ステップワイズ 回帰係数	T 値	P 値
1	(Intercept)	22.0	1.04	0.300	4.43	11.00	< 0.001
2	fixed.acidity	0.0250	0.96	0.336	–		–
3	volatile.acidity	-1.08	-8.95	< 0.001	-1.01	-10.04	< 0.001
4	citric.acid	-0.183	-1.24	0.215	–		–
5	residual.sugar	0.0163	1.09	0.277	–		–
6	chlorides	-1.87	-4.47	< 0.001	-2.02	-5.08	< 0.001
7	free.sulfur	0.00436	2.01	0.0447	0.00508	2.39	0.017
8	total.sulfur	-0.00327	-4.48	< 0.001	-0.00348	-5.07	< 0.001
9	density	-17.9	-0.83	0.409	–		–
10	pH	-0.414	-2.16	0.0310	-0.483	-4.11	< 0.001
11	sulphates	0.916	8.01	< 0.001	0.883	8.03	< 0.001
12	alcohol	0.276	10.43	< 0.001	0.289	17.23	< 0.001

*灰色部分はステップワイズで削除された変数

表 2: ワイン品質データについての変数選択結果

変数 no	進捗率の閾値 0.999 試行 NO 1	2	3	4	5	進捗率の閾値 0.9999 試行 NO 1	2	3	4	5	進捗率の閾値 0.99999 試行 NO 1	2	3	4	5
1					3				1						
2				2	2		3	3	2	3	3				
3															
4															
5	2	2	2	3	1	3		1		1		1	1	1	1
6			1												
7	4	4					1				1				
8	1	1				1									
9	3	3	3	1		2	2	2		2	2	2	2	2	2
10															
11															
12															

*灰色部分はステップワイズで削除された変数

さらに，進捗率が閾値に達した段階で変数削除する変数選択法を，閾値を様々に変えて試した．このとき，GA の解探索終了条件として（1）評価値の改善幅がゼロになる，(2）進捗率が 1 に達する，(3）残った変数の数が 1 になる，のどれかに該当した場合に RCGA を終了するようにした．その結果，閾値を 0.9999999 以上に設定した場合は前述の解探索が収束した段階で変数削除する変数選択法と当初の 2〜3 変数までは変数削除順が同様だった．但し，その後は先に述べた RCGA 探索終了条件 (1) に該当して RCGA の処理が終了した．さらに進捗率の閾値を 10 倍ずつ変化させて変数選択を試したところ，0.99999 以上の閾値では変数削除順は，若干異なるケースがあるものの，概ね T 値の絶対値の小さい変数を先に削除する傾向がみられたが，進捗率の閾値を 0.9999 以下に設定すると変数削除順が不安定になった．

なお，進捗率 0.99999 に達するのは 200 世代目前後であり，一方で解探索が収束するのは 650 世代前後である．計算コストの面では進捗率の閾値を出来るだけ低い水準に設定するのが望ましいと言えるが，一方で閾値が低すぎると重要な変数を削除してしまう可能性が高まる．このトレードオフの関係に対して適当な水準を見出す方法が求められるがその点は今後の課題としたい．

6. まとめ

本稿では，RCGA の枠組みで変数選択を行う手法を提案し，各分野の分析で広く用いられている AIC による変数選択と類似の結果が得られることを示した．この変数選択手法のために次の 2 つの仕組みを導入した．

（1）RCGA の遺伝子の分散の大きさを活用した I 値という変数選択指標.

（2）SRGM を応用した，RCGA の解探索の進捗率推計法.

一方，本稿の今後の課題も多い．一つ目は変数選択を実行する進捗率の閾値の設定方法である．進捗率の進み具合やその水準と解探索状況の関係は分析に用いるモデルによって異なると考えられ，閾値の設定水準を検討する作業負担は小さくない．この閾値の設定方法に関する基準や計算方法を見出すことが今後の大きな課題と考えている．また，評価値改善幅累計の形状が異なった場合にその形状に適した進捗率計算モデルを選択できるようにすることも課題の一つである．

これらの点を改善することで，非線形や非連続などのより複雑なモデルでも変数選択を実行できるようにすることが今後の大きな目標である．

参考文献

[Broadhursta 97] Broadhursta, Goodacrea, Jonesa, Rowlandb, Kell, : Genetic algorithms as a method for variable selection in multiple linear regression and partial least squares regression, with applications to pyrolysis mass spectrometry : Analytica Chimica Acta Vol. 348, 1-3, pp. 71-86, (1997)

[栗田 94] 栗田 : 遺伝的アルゴリズムによる線形回帰分析における説明変数の選択の試み，情報処理学会 全国大会講演論文集　第 48 回平成 6 年前期 (2) pp.253-254（1994）

[goldberg 89] Goldberg :Genetic Algorithms in Search, Optimization and Machine Learning, Addison Wesley Longman Publishing Co. Inc., (1989)

[wright 91] Wright : Genetic Algorithms for Real Parmter Optimization, Foundations of Genetic Algorithms, pp. 205-218 (1991)

[秋本 07] 秋本，羽佐田，佐久間，小野，小林 : 多親を用いた実数値 GA のための世代交代モデル〜 Just Generation Gap (JGG) の提案と評価〜，SICE 第 19 回自律分散システムシンポジウム資料，pp. 341-346 (2007)

[秋本 09-1] 秋本，永田，佐久間，小野，小林 : 適応的実数値交叉 AREX の提案と評価，人工知能学会誌 24(6), pp. 446–458,（2009）

[秋本 09-2] Akimoto, Sakuma, Ono, and Kobayashi : Adaptation of expansion rate for real-coded crossovers, Proc. of the 11th Annual Conf. on Genetic and Evolutionary Computation (GECCO'09), pp. 739-746 (2009)

[小林 09] 小林 : 実数値 GA のフロンティア，人工知能学会誌 24(1) pp.128-143（2009）

[小畑 18] Obata and Kurahashi:A Study of Variable Selection within A Framework of Real-coded Genetic Algorithm, 2018 IEEE International Conference on Systems, Man, and Cybernetics (IEEE SMC 2018)

[古山 96] 古山 : ソフトウェア信頼度成長モデルに関する統合モデルの解析的パラメータ推定法 情報処理学会論文誌, Vol.37 No.12, pp. 2326-2333, (1996)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

特徴アテンションを用いた時系列データのアトリビューション抽出

Feature Oriented Attention to Extract Attribution for Multivariate Time-Series Data

浅野秀平 *1　切通恵介 *1　泉谷知範 *1
Shuhei Asano　Keisuke Kiritoshi　Tomonori Izumitani

*1NTT コミュニケーションズ株式会社
NTT Communications Corporation

In the application of neural networks to industries such as manufacturing, it is important to extract which features have an important role in model output from the viewpoint of model reliability and understanding the couse of event. Attention mechanisms in neural networks is generally used to handle dynamic dependencies between time series, such as in natural language processing. In this research, we apply attention as a weight of each feature and propose a method to extract attribution of each feature in model output. We also examined its effectiveness using real sensor data.

1. はじめに

近年，ニューラルネットは画像，音声，自然言語といった幅広い分野で研究がなされている．しかし，ニューラルネットの産業への応用には，学習したモデルがブラックボックスであるという大きな課題が存在する．入出力の過程が自明でないニューラルネットでは，線形モデルのように出力に対する入力の要因を特定することが難しく，これはモデルに対する信頼性や，人が取るべき次の行動が分からないなど運用上の問題となる．

ニューラルネットの入出力間の依存関係 (アトリビューション) を抽出する研究は，画像や自然言語処理において広く提案されている [Selvaraju 17, Vaswani 17]．Attention は主に自然言語処理において再帰型ニューラルネットと組み合わせる形で研究がなされており，単語系列間の動的な依存関係を捉えることや，副次的な恩恵として単語系列毎のアトリビューションを可視化することに使われている．

本研究では，センサデータのような多変量時系列データを対象として，attention を特徴量方向に独立性を保ったまま適用する事で，各特徴量のアトリビューションを抽出する手法を提案する．また，実問題での有用性を評価する為に，人の運動を計測したセンサデータセットを使って実験を行なった．

2. 関連研究

ニューラルネットにおいて attention は主に自然言語処理で利用されており [Vaswani 17]，各入力単語系列の影響を時間減衰なく最終的な出力に与える手法として用いられている．また，各時刻における attention を可視化することで，最終的な出力に影響を与えた単語のアトリビューションを抽出することができる．

また，ニューラルネットの出力に対するアトリビューションを分析する研究は，可視化や解釈性という文脈で提案されている．その一つとして，Simonyan ら [Simonyan 13] は画像分類問題において出力に対する入力の偏微分値をネットワーク構造の逆伝播を用いて計算する手法を提案している．また，そのノイズを減らし時系列拡張を行った手法が提案されている [Kiritoshi 18]

連絡先: 浅野秀平，NTT Communications Corporation, shuhei.asano@ntt.com

これらの手法と比較して，本研究は画像分類や自然言語処理ではなく，センサなどの時系列データへの適用を目的としている点が異なる．また一般的なニューラルネットの attention は出力に寄与した時系列方向のアトリビューションを示す一方，本手法では特徴量毎のアトリビューションを抽出している点が異なる．また，Simonyan らの手法は入出力の偏微分値に注目しているが，本研究はネットワークの中間出力として，特徴量毎に計算された feature map と attention の積を与えることで，明示的に出力に寄与した特徴量が得られる点が異なる．

3. 提案手法

提案モデルの概要を図 1 に示す．提案モデルは，特徴量毎に独立した特徴抽出を行うネットワークと，特徴量毎の重み (attention) を変化させるネットワーク (以下 attention network)，およびそれらの出力を元にタスクに応じた最終的な出力を計算するネットワークから構成される．入力データ X に応じて変化するモデル内部の attention を観察することで，どの特徴量がタスクにおいて重要であったか推測する．

3.1 特徴 *attention* によるアトリビューション抽出

本手法はタスクに対する各特徴量の重要度を測る事を目的とする．よって attention はデータの時系列方向ではなく特徴量方向に適用する．入力するデータ X の系列長を T，特徴量の数を C とした時，出力する attention は長さ C のベクトル a となる．本研究ではこれを特徴 attension と呼ぶ．

特徴 attension を生成する attention netowrok は CNN などによって構成し，出力層の活性化関数に softmax 関数を使用する．このネットワークの役割は直接的にタスクの答えを求める事ではなく，入力データの全体の様相を捉え，どの特徴量にタスクを解く上で重要な情報があるかを出力する事にある．

次に attention を掛け合わせる対象である feature map $V \in \mathbb{R}^{F \times C}$ を $V = W_f X^{\mathrm{T}}$ によって得る．ここで $W_f \in \mathbb{R}^{F \times T}$ は学習した重みを表す．この処理は入力 X に対し，特徴量方向にカーネルサイズを 1 とした F 個の畳み込みを行なう操作と同一である．カーネルサイズを敢えて 1 に限定する事で，特徴量間で情報が混ざる事を防ぎ，後のアトリビューションの解釈を容易とする．

次に以下の式によって a と V から長さ F のベクトル m を

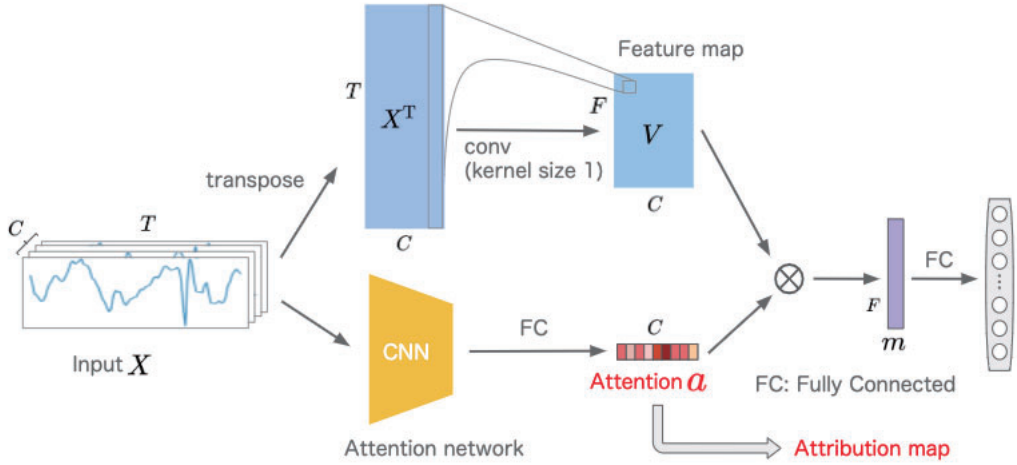


図 1: モデル全体

得る．V を $v = (v_1, v_2, ..., v_C)$ とした時，

$$m = \sum_{i=i}^{C} a_i v_i \tag{1}$$

得られた m は全結合層などを介してタスクに対する最終的な出力に使用される．Attention netwrok や W_f を含むネットワーク全体は，タスクに応じた損失の誤差逆伝播によって学習する．

最後に学習したモデルを使い，入力データ X に対する attention の平均を求める事で，各特徴量のアトリビューションを求める．

4. 実験

時系列センサデータからなる PAMAP2 Physical Activity Monitoring Data Set[Reiss 12] を使い，各センサに対するアトリビューション抽出を行なった．このデータセットは，9 人の被験者に歩行やサイクリングといった 18 種類の異なる行動を行わせ，複数のウェラブルセンサによってそれらの行動の磁気や加速度の時間変化を計測したものである．

今回は，データセットの中から少数の被験者でしか計測されていない watching TV などのデータは取り除き，手足の 34 次元のセンサデータから 12 種類の行動を分類する問題をタスクとして設定した．入力 X は 1 秒間 (100 点) のデータをランダムに切り出すことにより作成した．

上記のタスクを学習後，各行動における各特徴量のアトリビューションを表すために，複数の入力から計算された attention を平均したもの（以下アトリビューションマップと呼ぶ）を用いた．更に学習によるばらつきを抑える為に，異なる初期パラメータを使ってモデルを 30 回学習し，各モデルから得たアトリビューションマップを平均した結果を図 2 に示す．

データセットにおいて 17〜20 番，および 51 番〜54 番のセンサは無効なデータであることが説明されており，これらのセンサの中に高いアトリビューションを示すものは無かった事から，提案法は重要な特徴量の選別に有効である事が示唆される．

更に，より直接的に一部のセンサを被験者の行動と関係のないランダムなノイズに置き換え，同様の実験を行なった結果を図 3 に示す．対象のセンサでは，アトリビューションがゼロに近い値を示した事からも，本手法が入出力間の依存関係の抽出に置いて有効であると考えられる．

5. まとめ

本研究では attention を用いる事で時系列データの特徴量毎のアトリビューションを可視化する手法を提案し，実センサデータによる実験によってその有効性を示した．

次の課題として，回帰問題などの他のタスク条件下での実験や，偏微分値に基づくアトリビューション抽出の手法との比較を行う必要がある．

参考文献

[Kiritoshi 18] Kiritoshi, K., Ito, K., and Izumitani, T.: Capturing Time-Varying Influence Using an Attribution Map Method for Neural Networks, *Workshop on AI for Internet of Things* (2018)

[Reiss 12] Reiss, A. and Stricker, D.: Introducing a new benchmarked dataset for activity monitoring, in *Wearable Computers (ISWC), 2012 16th International Symposium on*, pp. 108–109IEEE (2012)

[Selvaraju 17] Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., and Batra, D.: Grad-CAM: Visual Explanations From Deep Networks via Gradient-Based Localization, in *The IEEE International Conference on Computer Vision (ICCV)* (2017)

[Simonyan 13] Simonyan, K., Vedaldi, A., and Zisserman, A.: Deep inside convolutional networks: Visualising image classification models and saliency maps, *arXiv preprint arXiv:1312.6034* (2013)

[Vaswani 17] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L. u., and Polosukhin, I.: Attention is All you Need, in Guyon, I., Luxburg, U. V., Bengio, S., Wallach, H., Fergus, R., Vishwanathan, S., and Garnett, R. eds., *Advances in Neural Information Processing Systems 30*, pp. 5998–6008, Curran Associates, Inc. (2017)

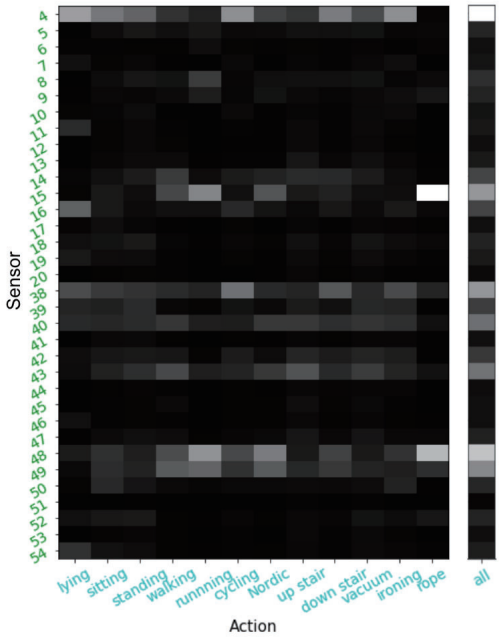


図 2: アトリビューションマップ　(縦軸がセンサの番号を表し，横軸が被験者の行動を表す．明度がアトリビューションの高さを表す．右端のグラフは全ての行動のアトリビューションを足しわせたもの．センサの番号は元のデータセット [Reiss 12] に合わせた)

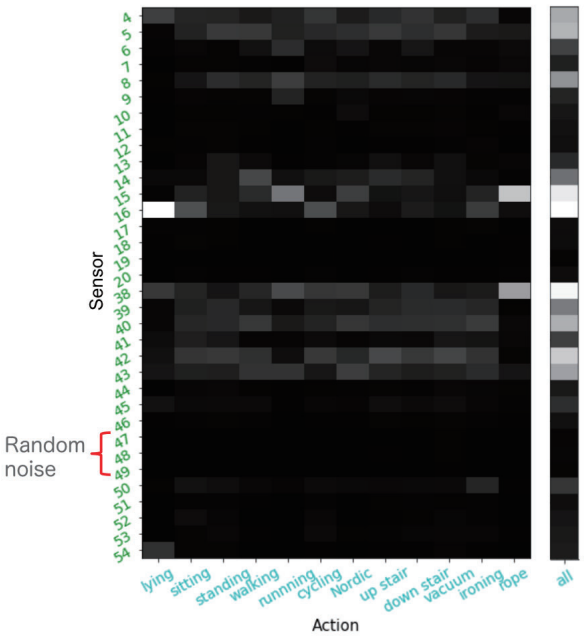


図 3: 一部センサをランダムなノイズに置き換えた条件下でのアトリビューションマップ

[2I5-J-9] Natural language processing, information retrieval: classification and evaluation

Chair:Hirotoshi Taira Reviewer:Kugatsu Sadamitsu

Wed. Jun 5, 2019 5:20 PM - 7:00 PM Room I (306+307 Small meeting rooms)

[2I5-J-9-01] Unsupervised Ensemble of Ranking Models for News Comments Using Pseudo Ranking Evaluation

○Soichiro Fujita[1], Hayato Kobayashi[2,3], Manabu Okumura[1] （1. Tokyo Institute of Technology, 2. Yahoo Japan Corporation, 3. RIKEN AIP）

5:20 PM - 5:40 PM

[2I5-J-9-02] A Discussion of the Relation between Assembly Member's Utterance and Next Election Outcome

○Yasutomo Kimura[1], Akihiko Kawaura[2], Yuzu Uchida[3] （1. Otaru University of Commerce, 2. Doshisha University, 3. Hokkai-Gakuen University）

5:40 PM - 6:00 PM

[2I5-J-9-03] A Study of Patent Publications Classification Using Machine Translation and Rough Set Theory

○Masaki Kurematsu[1] （1. Iwate Prefectural University）

6:00 PM - 6:20 PM

[2I5-J-9-04] The Simplest Document Classifier

○Yoshitaka Shirai[1], Yutaka Hirata[1] （1. Chubu Univercity）

6:20 PM - 6:40 PM

[2I5-J-9-05] Automatic Scoring and Scoring Support System using LSTM and Attention

○Kohei Takai[1], Kengo Taketani[1], Junpei Hayakawa[2], Yasukuni Mori[3], Hiroki Suyari[3] （1. Department of Applied and Cognitive Informatics, Graduate School of Science and Engineering, Chiba University, 2. Department of Informatics and Imaging Systems, Faculty of Engineering, Chiba University, 3. Graduate School of Engineering, Chiba University）

6:40 PM - 7:00 PM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

疑似順位付け評価を用いたニュースコメント順位付けモデルの教師なしアンサンブル

Unsupervised Ensemble of Ranking Models for News Comments Using Pseudo Ranking Evaluation

藤田 綜一郎 *1 Soichiro Fujita　小林 隼人 *2*3 Hayato Kobayashi　奥村 学 *1 Manabu Okumura

*1東京工業大学 Tokyo Institute of Technology　*2ヤフー株式会社 Yahoo Japan Corporation　*3理研 AIP RIKEN AIP

In this paper, we propose a simple unsupervised ensemble method that determines the importance of each model by comparison of multiple models like majority vote. Experimental results on a news comment ranking task show that our proposed method outperforms current ensemble methods including the supervised one.

1. はじめに

オンラインニュースサイトには，ニュース記事毎に読者の議論の場としてコメント欄が設けられているものがある．それらのサイトの多くは，肯定的な読者評価が多く寄せられた順にコメントをランキング（順位付け）し，読者に良いコメントを優先的に提示している．しかし，読者評価の数は単調増加するため，単純に早期に投稿されたコメントほど多くの評価を得やすく，コメントの良さが平等に評価されているとは言い難い．そのため，藤田ら [藤田 18] はコメントの建設的度合いに注目し，良いコメントを直接ランキングする事に取り組んだが，分類器の精度が高くないことが課題として残されていた．

一方で，分類器のアンサンブルは機械学習モデルの精度を向上させる手法として広く知られている．最近では，Kobayashi [Kobayashi 18] が要約タスクにおいて，モデルの出力間のコサイン類似度を用いてモデルの多数決をとることで高速に動作し，かつ高い精度が得られたという報告がある．我々は，藤田らが作成したデータセットが読者が建設的かどうかの多数決によりラベル付けされていることから，コメントのランキングにも Kobayashi の類似度を用いた多数決によるアンサンブルモデルが適していると考えた．

そこで，本研究では，ランキングの評価指標 NDCG@k を用いて，記事毎に対応したモデルの重みを求める，多数決ベースの教師なしアンサンブル手法を提案する．具体的には，学習した複数のモデルの出力の平均によるランキングを擬似正解とみなし，各モデルの NDCG@k を求める．NDCG@k の値を記事に対するモデルの重要度とみなし，重み付けやモデル選択を行う．

ニュースコメントの建設的度合いをランキングするタスクの実験を行い，結果として，モデルの出力を NDCG@k の値で重み付けすることで既存手法を上回る精度を達成した．また，NDCG@k が高いモデルだけを選択してアンサンブルすることで，さらなる精度向上が見られた．

2. 提案手法

2.1 LSTM ランキングモデル

本研究では，Burges ら [Burges 05] の RankNet をベースにし，記事のタイトル $q \in Q$ とコメント $c \in C$ の二つを入力とし，記事 q におけるコメント c のランキングスコアを出力とする，LSTM ランキングモデルを使用する．

記事のタイトルとコメントの入力単語系列をそれぞれ $X_q = [x_1^q, ..., x_{|q|}^q]$, $X_c = [x_1^c, ..., x_{|c|}^c]$ とおく．まず，記事タイトルとコメントの単語系列を符号化する．符号化器の隠れ状態 $\boldsymbol{h}$ は次式で計算される:

$$\boldsymbol{h_i^q} = encoder_{title}(\boldsymbol{h_{i-1}^q}, \boldsymbol{e_i^q}), \quad (1)$$

$$\boldsymbol{h_i^c} = encoder_{comment}(\boldsymbol{h_{i-1}^c}, \boldsymbol{e_i^c}). \quad (2)$$

ここで，e_i^q, e_i^c はそれぞれ記事タイトル中の単語 x_i^q とコメント中の単語 x_i^c の事前学習された単語分散表現である．また，$encoder_{title}$ と $encoder_{comment}$ はそれぞれ記事タイトルとコメントの単語系列の符号化器であり，本研究では一層の LSTM を用いた．このとき，コメント c のランキングスコア s^c は次のように表される:

$$s^c = \boldsymbol{W}([\boldsymbol{h}_{|q|}^q; \boldsymbol{h}_{|c|}^c]) + \boldsymbol{b}. \quad (3)$$

ここで，$\boldsymbol{W}$ は重みベクトル，$\boldsymbol{h}_{|q|}^q$ と $\boldsymbol{h}_{|c|}^c$ は符号化器の隠れ層の最終状態，$\boldsymbol{b}$ はバイアス項である．

学習の際にはスコアを直接学習するのではなく，2 つのコメント $\{c_A, c_B\} \in C$ の予測結果を比較し相対的に学習するペアワイズ学習を用いる．このとき，損失関数 $loss_{AB}$ は式 (4) の様に交差エントロピーを用いて計算される:

$$loss_{AB} = -\bar{P}_{AB} \log P_{AB} - (1 - \bar{P}_{AB}) \log(1 - P_{AB}) \quad (4)$$

$$P_{AB} = \frac{1}{1 + e^{-\sigma(s^{c_A} - s^{c_B})}}, \quad (5)$$

$$\bar{P}_{AB} = \frac{1}{2}(1 + S_{AB}). \quad (6)$$

ここで，$S_{AB} \in \{-1, 0, 1\}$ はコメント c_A と c_B の相対正解スコアであり，c_A の正解スコアが c_B の正解スコアより高い場合は 1，低い場合は -1，同一の場合は 0 となる．

2.2 Post-Eval アンサンブル

ここでは，記事ごとに多数決で代表モデルを選択する手法 `Post-Eval` について説明する．Kobayashi の研究では，要約タスクにおいてモデルの予測単語の系列同士をコサイン類似度で比較することでモデルの重要度を教師なしに導出している．`Post-Eval` ではモデルが予測したランキングを予測単語の系列と同等のベクトル系列とみなすことで，ランキングタスク

連絡先: *1{fujiso, oku}@lr.pi.titech.ac.jp
*2hakobaya@yahoo-corp.jp

に Kobayashi の手法を適用可能にする．学習された複数のモデル M の記事 q に対する予測ランキング（予測スコアのリスト）集合を R^q とする．この時，モデル $m_i \in M$ の予測ランキング $r_i \in R^q$ の重要度を式 (7) で定義する．

$$post_{r_i} = \frac{1}{|S|} \sum_{r_j \in R^q : r_j \neq r_i} f(r_j, r_i). \tag{7}$$

ここで，$f(x, x^*)$ は評価指標であり，通常 x にはモデルによる予測ランキング，x^* には正解ランキングを代入する．`Post-Eval` では，正解ランキングの代わりに，他のモデルの予測ランキングを用い，モデル間の類似度を計算する．アンサンブル後の最終ランキング $\bar{r}$ は，式 (8) に示す通り $post_{r_i}$ が最大値となる，言い換えるとランキングが最も密集しているところのモデルを選択する．

$$\bar{r} = \underset{r_i \in R^q}{\operatorname{argmax}}(post_{r_i}). \tag{8}$$

本研究では，評価指標 f として，Normalized Discounted Cumulative Gain (NDCG@k) [Burges 05] を用いる．NDCG@k はランキングの有効性の評価として，情報検索などのランキング問題で広く用いられている評価指標であり，ランキング結果上位 k 件において，正解のランキングとの近さを示している．NDCG@k は次式で表される:

$$\mathrm{NDCG@}k = Z_k \sum_{i=1}^{k} \frac{s_i}{\log(i+1)}. \tag{9}$$

ここで，s_i はモデルによって順位付けられた i 番目のコメントの正解スコアを示している．また，Z_k は正規化項であり，モデルの出力が正解と同じ順序で並べられているときに最大値 1 をとるように設定されている．

2.3 Weighted-Eval アンサンブル

2.2 節で評価指標によるモデルの取捨選択について述べたが，この手法ではモデルの重み付き平均をとるアンサンブル手法を上回る精度は達成できなかった (詳細は 3.3 節で述べる)．

そこで，モデルの取捨選択の代わりに，評価指標を用いて重み付き平均を行う `Weight-Eval` アンサンブル手法を提案する．`Weight-Eval` による最終ランキング $\bar{r}$ は，式 (10) で表される:

$$\bar{r} = \sum_{r_i \in R^q} f(r_i, t^q) \cdot r_i, \tag{10}$$

$$t^q = \frac{1}{|S|} \sum_{r_i \in R^q} \frac{r_i}{||r_i||}. \tag{11}$$

ここで，式 (11) の t^q は記事 q の擬似正解ランキングである．擬似正解ランキングは，各モデルのランク系列 r_i を L2 正則化したものの平均で表される．`Post-Eval` では重要度算出の際にモデル間の類似度を全て計算していたが，擬似正解ランキングにより一括で重要度を求めることで，ランキングの系列を高速に比較できる．

また，モデルの重み付き和を求める前に k 個のモデルを取捨選択する `Select@`k を導入することで，`Weight-Eval` の更なる精度向上を図る．具体的には，モデルの重要度 $f(r_i, t^q)$ が大きい順に選んだ k 個のモデルだけを対象に重み付き和を取ることで，`Weight-Eval` と `Post-Eval` 双方の利点を得ることを目指す．

3. 実験

3.1 実験設定

データセット: 我々は，データセットとして，藤田ら [藤田 18] が報告している Yahoo!ニュース記事のコメントの建設的コメントランキングデータセットを用いた．データセットは，(記事タイトル, コメント, 建設的スコア) の 3 つ組からなる．建設的スコアは，40 人に対して各コメントを提示し，コメントが建設的である/建設的でないの二択質問をした際に，建設的であると判別した人数で定義されており，0 ～ 40 の整数値をとる．このスコアは，出来るだけ多くの読者を十分に満足させることを目的としており，コメントが建設的であると考える潜在的な人数を模擬する尺度となっている．本研究では，データセットのうち 1,300 記事 130,000 コメントを学習データ，113 記事 11,300 コメントを開発データ，200 記事 42,436 コメントをテストデータとして用いた．学習データと開発データは各記事からランダムに抽出された 100 コメントにラベル付けがされており，テストデータは実際のサービスを想定して各記事の全てのコメントにラベル付けがされている．

前処理: データの前処理として，形態素解析器 MeCab[*1] [Kudo 04] を NEologd 辞書 [*2] [Toshinori 17] と共に用いて単語分割を行った．また，数字を特殊なトークンに置き換え，片仮名は平仮名にすることで文字種の統一をした．機能語はランキングの精度に良い影響を与えているため，ストップワードは除去しなかった．各データセットで出現回数が 3 回未満の単語は低頻度語として切り捨てた．

モデルの学習: 単語の分散表現は，word2vec [Mikolov 13] により約 150 万件のラベル無しコメントを事前学習したものを使用した．分散表現の次元数は 300 として窓幅 5 単語の Skip-gram モデルを学習した．ランキングモデルのパラメータの学習には Adam (学習率: 1.0×10^{-4}) を使用し，ミニバッチサイズは 10，イテレーション数は 1.0×10^4 とした．各ミニバッチは，同一記事からランダムに 10 ペアを選択することで作成した．記事タイトルとコメントのエンコーダの隠れ状態の次元数はどちらも 300 とした．実験では，アンサンブルのために，上記設定でモデルの初期状態をランダムに変化させた 100 モデルを学習した．

評価指標: 式 (9) で説明した NDCG@k に加えて，2 つ目の評価指標として Precision@k を用いる．これは推定された上位 k 件のコメントが、正解の上位 k 件のコメントに含まれている割合として定義されている．実験では $k \in \{1, 5, 10\}$ の場合の評価を行った．なお，数値関連度を用いたランキングの設定においては Precision@k よりも NDCG@k の方が優れた指標であると言われている．

3.2 比較手法

本研究では以下の手法について比較を行った．`RankSVM` と `LSTMRank` はそれぞれ既存手法と本研究で作成した単一モデルによるベースラインである．`ScoreAverage`，`RankAverage`，`Top-k-Average`，`Normalized` は一般的によく用いられる，教師なしで事後的にモデルを組み合わせるアンサンブルの手法である．`Supervised` は，教師ありデータによりモデルに重み付けをしてアンサンブルする手法である．

- `RankSVM`: 藤田らの研究 [藤田 18] で最も精度が高かった `RankSVM` モデル. 既存研究におけるベースラインである．

∗1 http://taku910.github.io/mecab/

∗2 https://github.com/neologd/mecab-ipadic-neologd

	NDCG			Precision		
	@1	@5	@10	@1	@5	@10
RankSVM	73.38	74.59	76.01	15.5	30.20	38.95
LSTMRank	76.35	77.97	79.52	15.0	33.20	42.99
ScoreAverage	76.91	79.11	80.48	16.08	33.67	44.32
RankAverage	79.19	80.53	81.81	13.57	36.18	46.08
Top-k-Average	78.38	80.52	81.57	14.07	35.38	46.08
Normalized	79.83	80.77	82.16	**17.08**	37.18	46.48
Supervised	78.64	80.33	81.94	16.28	35.47	46.58
Post-Eval	77.18	80.09	81.24	14.57	35.58	45.78
Weight-Eval	**79.87**	81.39	82.17	**17.08**	**37.88**	46.63
+ Select@50	**79.87**	**81.43**	**82.33**	**17.08**	37.39	**47.34**

表 1: 建設的コメントのランキング実験における NDCG@k と Precision@k の結果 ($k \in \{1, 5, 10\}$).
すべての値はパーセンテージで表されている.

- LSTMRank: 2.1 節のランキングモデルを 100 モデル学習した中で最も高い精度が得られたモデル．アンサンブルではなく，単一モデルで予測する．
- ScoreAverage: コメントごとにモデルの出力スコアを平均し，その値が高い順に並べる．
- RankAverage: モデルごとにコメントのランキングを行い，その順位をコメントのスコアとする．全てのモデルのスコアを平均し，その値が高い順に並べる．
- Top-k-Average: Cormack らの手法 [Cormack 09]. 各モデルのランキング上位 k 件のみコメントを対象に，モデルの出力スコアの総和を計算し，その値が高い順に並べる．
- Normalized: Burges らの研究 [Burges 11] に代表される，各モデルの出力を正規化してから平均をとる手法．正規化にはさまざな方法があるが，本研究では各モデルの出力のランク系列をベクトルとみなし，L2 ノルムによる正規化を行う．
- Supervised: 各モデルの開発データセットでの NDCG@k をモデルの重要度とみなし，スコアの重み付き和が高い順に並べる．この手法では，モデルの重要度は記事に関係なく一定である．

3.3 実験結果

実験結果を表 1 に示す．まず，単一モデル同士を比較すると本研究で用いた LSTMRank は藤田らのベースライン RankSVM を上回る精度を達成した．Precision@1 のみ RankSVM を下回っているが，これは LSTMRank が最もスコアの高いコメントを見つけられなかった一方で，スコアが高いものを多く推定できていることを意味している．

また，アンサンブルの結果，全ての手法において，単一モデルの結果を上回る精度を達成した．特に提案手法である Weight-Eval は最高精度を達成しており，Select@50 により 100 モデルから重要度が高い順に 50 モデルを選択して重み付け和をとることで，更に NDCG@k が向上した．

Kobayashi の手法をランキングタスクに適用させた Post-Eval は LSTMRank よりも高い精度を達成した．これにより，評価指標を用いてモデル間で類似度を計算し，それを元に記事ごとにモデルを事後的に選択する手法が有効であることが確認できた．しかし，一方で，Normalized などの一般的なモデルの平均によるアンサンブルよりも低い精度となった．これは元々ランキングが相対的な比較によってなされているため，Post-Eval による確信度が高いモデルを選択するよりも，モデルの多様性を保持する方が性能向上に有効だからだと考えられる．

教師なし手法である Weight-Eval は教師ありでモデルの重要度を学習する Supervised よりも高い精度を達成した．よって，事前にモデルの重要度を教師データを用いて学習するより，ランキング間の類似度から事後的にモデルの重要度を決める方が良いことが確認できた．

4. 関連研究

ニュースのコメント欄をはじめとするオンラインフォーラムのコメントの分析は，近年多くの研究がなされてきた．中でもコメントのランキングについては，読者による評価を予測しランク付けする研究 [Hsu 09, Das Sarma 10] や，説得力のあるコメント順にランク付けする研究 [Wei 16] など様々な観点からランキングをする試みがされている．本研究に最も関連する建設的なコメント順にランク付けする研究 [藤田 18] では，ランキング用データセットを作成し，精度向上のためにタスクに適したデータ作成の方法について考察されている．我々は，モデルの精度向上の方面から更なる精度向上を図っている．

ランキングタスクのアンサンブルでは，多数決選択のように事後的にモデルを教師なしで選択する手法として，モデルの出力を正規化してアンサンブルしている手法 [Burges 11] や上位のコメントだけをフィルタリングしてからモデルの平均をとる手法 [Cormack 09] がある．また，情報検索において，クエリ依存のアンサンブルの重みを半教師ありで学習する研究 [Hoi 08] がある．彼らの研究は，記事毎にモデルの重みを求める我々の手法と発想は類似しているが，情報検索がクエリに対する一致度で順位付けをするタスクであるのに対し，コメントのランキングは記事 (クエリ) に類似していることが前提の上に順位付けするため，我々の試みとは大きく異なる，

評価指標 NDCG@k を元に分類器の精度を向上させる試みとして，NDCG@k を損失関数に組み込み直接学習する LambdaRank [Burges 07] やそれに決定木を組み合わせた LambdaMART [Burges 10] が提案されている．しかし，これらは事前に教師ありの学習を行なっており，教師なしで事後的にモデルを組み合わせる提案手法とは本質的に異なるため，本研究では比較を行っていない．

5. おわりに

本研究では，評価指標を用いて教師なしで事後的にモデルをアンサンブルする手法を提案した．実験により，提案手法が最も高い精度を達成し，モデル間のランキングの近さを評価指標により求め，その値を重要度としてモデルの重み付けや取捨選択に使用することで精度が向上することを示した．
今後の展望として，同一の構造の分類器ではなく，様々な種類の分類器を組み合わせによるアンサンブルを行いたいと考えている．また，提案手法と教師ありのアンサンブル手法との精度面/速度面での性能比較を検討している．

参考文献

[Burges 05] Burges, C., Shaked, T., Renshaw, E., Lazier, A., Deeds, M., Hamilton, N., and Hullender, G.: Learning to rank using gradient descent, in *Proceedings of the 22nd international conference on Machine learning*, pp. 89–96ACM (2005)

[Burges 07] Burges, C. J., Ragno, R., and Le, Q. V.: Learning to rank with nonsmooth cost functions, in *Advances in neural information processing systems*, pp. 193–200 (2007)

[Burges 10] Burges, C. J.: From ranknet to lambdarank to lambdamart: An overview, *Learning*, Vol. 11, No. 23-581, p. 81 (2010)

[Burges 11] Burges, C., Svore, K., Bennett, P., Pastusiak, A., and Wu, Q.: Learning to rank using an ensemble of lambda-gradient models, in *Proceedings of the Learning to Rank Challenge*, pp. 25–35 (2011)

[Cormack 09] Cormack, G. V., Clarke, C. L., and Buettcher, S.: Reciprocal rank fusion outperforms condorcet and individual rank learning methods, in *Proceedings of the 32nd international ACM SIGIR conference on Research and development in information retrieval*, pp. 758–759ACM (2009)

[Das Sarma 10] Das Sarma, A., Das Sarma, A., Gollapudi, S., and Panigrahy, R.: Ranking Mechanisms in Twitter-like Forums, in *Proceedings of the Third ACM International Conference on Web Search and Data Mining (WSDM 2010)*, pp. 21–30, ACM (2010)

[Hoi 08] Hoi, S. C. and Jin, R.: Semi-supervised ensemble ranking (2008)

[Hsu 09] Hsu, C.-F., Khabiri, E., and Caverlee, J.: Ranking Comments on the Social Web, in *Proceedings of the 2009 International Conference on Computational Science and Engineering (CSE 2009)*, Vol. 4, pp. 90–97, IEEE (2009)

[Kobayashi 18] Kobayashi, H.: Frustratingly Easy Model Ensemble for Abstractive Summarization, in *Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing*, pp. 4165–4176 (2018)

[Kudo 04] Kudo, T., Yamamoto, K., and Matsumoto, Y.: Applying Conditional Random Fields to Japanese Morphological Analysis, in *Proceedings of the 2004 Conference on Empirical Methods in Natural Language Processing (EMNLP 2004)*, pp. 230–237, Association for Computational Linguistics (2004)

[Mikolov 13] Mikolov, T., Sutskever, I., Chen, K., Corrado, G. S., and Dean, J.: Distributed representations of words and phrases and their compositionality, in *Advances in neural information processing systems*, pp. 3111–3119 (2013)

[Toshinori 17] Toshinori, T. H., Sato and Okumura, M.: Implementation of a word segmentation dictionary called mecab-ipadic-NEologd and study on how to use it effectively for information retrieval (in Japanese), in *Proceedings of the Twenty-three Annual Meeting of the Association for Natural Language Processing*, pp. NLP2017–B6–1, The Association for Natural Language Processing (2017)

[Wei 16] Wei, Z., Liu, Y., and Li, Y.: Is This Post Persuasive? Ranking Argumentative Comments in Online Forum, in *Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (ACL 2016)*, pp. 195–200, Association for Computational Linguistics (2016)

[藤田 18] 藤田綜一郎, 小林隼人, 奥村学 F 建設的ニュースコメントの順位付けのためのデータセット構築, 研究報告自然言語処理 (NL), Vol. 2018, No. 14, pp. 1–7 (2018)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

都道府県議会を対象とした 議員の発言と選挙結果の関係性の一考察

A Discussion of the Relation between Assembly Member's Utterance and Next Election Outcome

木村泰知 *1 Yasutomo KIMURA
川浦昭彦 *2 Akihiko KAWAURA
内田ゆず *3 Yuzu UCHIDA

小樽商科大学 *1 Otaru University of Commerce
同志社大学 *2 Doshisha University
北海学園大学 *3 Hokkai-Gakuen University

We created the local assembly minutes corpus, which connected the politicians' profile, the results of elections and politicians' utterances. This corpus includes minutes of plenary assemblies in 47 prefectures of Japan from April 2011 to March 2015. This paper shows that a politicians' utterance in the assembly makes an effect for next election in order to predict next election results by Machine Learning. Therefor we tried to clarify characteristic words between the election winners and election losers in the assembly elections.

1. はじめに

近年，政治家は，インターネットを介して，政治理念，政策，政治活動，プロフィールなどを伝えている．このような政治家の情報は，どの程度，次回選挙に影響を与えるのだろうか．選挙結果に影響を与える要因には，当選回数，学歴，政党，年齢，性別，職歴などがある．他にも，政治家がどのようなマニフェストを書いたのか，どのような発言をしたのか，どのような内容の投稿をしたのかのように，発信している情報の内容も影響する．特に，2013 年に公職選挙法が改正されたことにより，インターネット選挙運動が解禁され，電子的なテキストを対象とした選挙に関する研究が盛んになっている [2]．インターネット選挙運動では，twitter が注目されており，2013 年参議院選挙におけるソーシャルメディアの分析として，つぶやきを対象とした分析の研究がある [3]．また，鳥海らによる 2017 年衆議院選挙における政党公式アカウントフォロワーを分析している研究がある [4]．このように，国政選挙におけるインターネット選挙運動を対象とした研究は進んでいるが，日本の地方議会選挙においては，地方議員の投稿量が少ないことから，国会議員の選挙と同じように分析することが困難である．

そこで，我々は，都道府県議会における発言を対象として，議会の発言と選挙結果との関係に焦点を当てて研究を行う．議会における議員の発言を分析するには，ウェブ上に公開されている議会会議録から，議員の発言を収集し，いつ，どこで，だれが，なにを発言したのかを整理するため，膨大な時間とコストがかかる．そのため，大規模なテキスト分析はほとんど行われていなかったが，最近，地方議会会議録コーパスが整備されつつあることから，川浦らが議会における「発言量」と選挙結果の関係について，計量経済学の観点から研究を進めている [1]．しかしながら，地方議会における議員の「発言内容」と選挙の結果についての研究は進められていない．そこで，本研究では，47 都道府県の地方議会会議録コーパスと選挙結果を結びつけることにより，都道府県議会における各議員の発言内容（発言単語）が，次回選挙において当選予測を行う場合に有効な素性となるのかについての調査を行う．我々は，以前から，都道府県議会の平成 23 年 4 月から平成 27 年 3 月までの会議録を対象として，発言者の表記ゆれを人手で対応づけたコーパスを作成しており，正確な分析を行うことができる．本研究では，議会における発言内容に含まれる単語の出現頻度から，当選者と落選者に特徴的な単語を明らかにする．また，特徴的な単語を用いて，機械学習による選挙予測がどの程度可能なのか試みる．

連絡先: 木村泰知，小樽商科大学，〒 047-8501 北海道小樽市緑 3 丁目 5 － 2 1，kimura@res.otaru-uc.ac.jp

2. データセットの構築

本章では，会議録，議員プロフィール，当選情報に含まれるデータから，発言内容と選挙結果（当落）を結びつけるデータセットの構築方法について述べる．

2.1 対象の会議録と選挙結果

対象の会議録は，47 都道府県の地方議会会議録の本会議とする．議会会会議録の対象期間は，第 18 回統一地方選挙（2015 年 4 月）を対象とするため，2011 年 4 月から 2015 年 3 月までの 1 任期 4 年とする．第 18 回統一地方選挙は，岩手県，宮城県，福島県，茨城県，東京都，沖縄県を除く 41 道府県議会において，2015 年（平成 27 年）4 月 12 日と 26 日の 2 回に分けて行われた．統一地方選挙は，議会の解散や自然災害の影響により，選挙時期がずれることがある．例えば，岩手県，宮城県，福島県は，東日本大震災の影響により，第 17 回の地方統選挙が通常よりも，遅れて実施された．そこで，本研究では，統一地方選挙の時期と異なる自治体を除き，41 道府県議会を対象とする．

2.2 対象の立候補者

本節では，分析対象者について述べる．分析対象者は，2015 年 4 月の統一地方選挙に立候補した議員とする．また，本研究では，議会の発言を利用することから，選挙前に議員であることが前提となり，全ての議員を対象とすることができない．さらに，対象の自治体の場合でも，議長および副議長の議員の発言は，発言内容が質問でなはく議事進行となることから対象外とする．そこで，分析対象の立候補者の選定条件を以下のように定める．

1. 2015 年 4 月の統一地方選挙に立候補した議員
2. 現職，新人，元職のうち，現職の議員
3. 議長，副議長を務めていない議員

表 1: 3 つのデータ構造と連結キー

番号	会議録コーパス	議員リスト	選挙結果
0	識別子	議員 ID	(異なる)ID
1	都道府県名	都道府県名	都道府県名
2	回	自治体名	選挙名
3	号	姓名	選挙区
4	年	ふりがな	当選フラグ
5	月	対象行政区	得票数
6	日	生年	姓名
7	開催期間	性別	ふりがな
8	表題	職名	党派
9	発言者名表層		新旧
10	議員 ID		無投票フラグ
11	発言者名		任期開始
12	発言者の役職		任期満了
13	発言文		備考
14	発言以外		自治体コード
15	原本 URL		選挙 ID
16	—		選挙区 ID

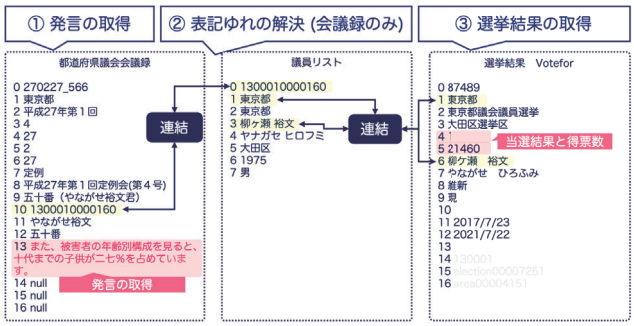


図 1: 会議録と議員リストと選挙情報を結びつける例

2.3 分析に用いる会議録および選挙情報

本節では，発言内容と選挙結果を結びつける方法について説明する．選挙結果は，政治山 [*1] を運営している Votefor から入手した．選挙結果のデータには 4,035 人の（落選者を含む）立候補者全員の情報が含まれている．一方，47 都道府県の地方議会会議録コーパスには，2,947 人の議員が含まれている [*2]．

データセット構築では，上記の 2 つのデータに加えて，地方議会会議録コーパスで利用している「議員リスト」を用いて「都道府県名」「姓名」が一致する場合に，データを結びつける．表 1 に 3 つのデータ構造と連結キー（下線が引いてあるフィールド名）を示す．また，図 1 に会議録と議員リストと選挙情報を結びつける例を示す．

表 2 に会議録コーパスと Votefor で管理している選挙結果情報に含まれる「都道府県名」および「姓名」の字面が完全に一致した立候補者の人数を示す．字面が完全に一致した立候補者を自動で連結した結果，2,172 人に対して「議会の発言」と「選挙結果」を結びつけることができた．

*1 https://seijiyama.jp/

*2 地方議会会議録コーパスに含まれる議員数は議員定数より多くなっている．その理由は，選挙時期がずれている自治体があり 2 期分の議員を含んでいるため，そして，補欠選挙により当選した議員が含まれているためである．

表 2: 結びつけることができた分析対象者

データ名	完全一致	不一致	合計
会議録コーパス・議員リスト	2,172	775	2,947
第 18 回統一地方選挙の結果	2,172	1,863	4,035

表 3: 第 18 回統一地方選挙に立候補した現職議員の発言の有無 (期間：2011 年 4 月～2015 年 3 月)

番号	都道府県	議員 ID あり						合計
		発言あり			発言なし（議長など）			
		当選	落選	合計	当選	落選	合計	
1	北海道	58	10	68	11	0	11	79
2	青森県	40	3	43	0	0	0	43
3	秋田県	31	4	35	2	0	2	37
4	山形県	33	4	37	4	0	4	41
5	栃木県	39	7	46	0	0	0	46
6	群馬県	36	3	39	0	0	0	39
7	埼玉県	64	6	70	1	1	2	72
8	千葉県	69	5	74	2	0	2	76
9	神奈川県	59	18	77	4	0	4	81
10	新潟県	37	5	42	0	0	0	42
11	富山県	32	2	34	1	0	1	35
12	石川県	28	3	31	1	0	1	32
13	福井県	29	0	29	0	0	0	29
14	山梨県	25	2	27	0	0	0	27
15	長野県	43	8	51	0	0	0	51
16	岐阜県	34	3	37	0	0	0	37
17	静岡県	56	6	62	0	0	0	62
18	愛知県	64	9	73	0	0	0	73
19	三重県	39	4	43	0	0	0	43
20	滋賀県	33	4	37	0	1	1	38
21	京都府	45	2	47	0	0	0	47
22	大阪府	59	15	74	0	0	0	74
23	兵庫県	53	9	62	6	1	7	69
24	奈良県	33	5	38	0	0	0	38
25	和歌山県	33	2	35	0	0	0	35
26	鳥取県	25	3	28	0	0	0	28
27	島根県	26	5	31	0	0	0	31
28	岡山県	46	4	50	0	0	0	50
29	山口県	34	6	40	2	0	2	42
30	広島県	49	2	51	2	0	2	53
31	徳島県	28	3	31	0	0	0	31
32	愛媛県	37	1	38	1	0	1	39
33	香川県	35	2	37	1	0	1	38
34	高知県	23	4	27	0	0	0	27
35	福岡県	0	0	0	65	4	69	69
36	佐賀県	30	4	34	0	0	0	34
37	長崎県	33	6	39	1	0	1	40
38	熊本県	31	8	39	1	0	1	40
39	大分県	32	3	35	0	0	0	35
40	宮崎県	29	2	31	1	1	2	33
41	鹿児島県	35	6	41	0	0	0	41
合計	-	1,565	198	1,763	106	8	114	1,877

2.4 分析対象データ

データセットは，第 18 回統一地方選挙の選挙結果を予測するために，2015 年 4 月に議会選挙が実施された 41 都道府県を対象とした．分析対象データは，現職議員を対象としており，選挙結果を結びつけることができた議員のみが含まれる．表 3 は第 18 回統一地方選挙 (2015 年 4 月 12 日) の立候補者における現職議員を対象として，発言の有無を示している．本稿では，福岡県のデータを自動で結びつけることができなかったため，対象外とした [*3]．

3. 発言内容による分析

本章では，議会における発言内容 (発言に含まれる単語) が次回選挙に与える影響について調査する．

*3 本稿では，自動で連結したデータを用いているが，今後は，人手により確認したデータを用いる予定である．

3.1 分析方法

本研究では当選者および落選者の言語表現の特徴を明らかにするために，当選者と落選者の発言に含まれる単語の出現頻度の違いに着目する．

本研究では**対数尤度比**を用いて，当選者と落選者に特徴的な単語をみつける．**対数尤度比**は，次の式で計算する．

$$LLR = a\log\frac{an}{((a+b)(a+c))} + b\log\frac{bn}{((a+b)(b+d))}$$

$$+c\log\frac{cn}{((c+b)(a+c))} + d\log\frac{dn}{((c+d)(b+d))}$$

表 4 に**対数尤度比**を求めるために必要となる単語の頻度を示す．また，n は全単語数であり，$n = a+b+c+d$ である．対数尤度比を計算するために，当選者と落選者の発言を 2 つのファイルに分けて，NEolgd を用いた MeCab 形態素解析結果を用いて単語分割した後に，名詞だけを対象として，単語頻度を求めている．

表 4: 対数尤度比算出時に使用するクロス集計表

	落選者	当選者
単語 X の出現回数	a Lose(X)	b Win(X)
単語 X 以外の出現回数	c Lose(NotX)	d Win(NotX)

3.1.1 対数尤度比の結果

表 3 からわかるように，落選者が 10 名以上いる自治体が，北海道，神奈川県，大阪府である．表 5 に，落選者が多い 3 つの自治体において対数尤度比上位 5 単語を示す．上位の 5 単語には「お尋ね」「伺い」「見解」「所見」などの議員が質問するときに利用する表現が見られた．また,「日本海」「カジノ」「太陽光パネル」「泉南市」のように具体的な単語もみられた．しかしながら，これらの単語が発言においてどのように利用されているか，わからない．そこで，これらの具体的な単語が，当選者と落選者で異なる使い方をされているのかについて調べることにした．大阪府議会において「太陽光パネル」を含む発言した議員のなかから，落選した議員の発言と当選した議員の発言の例を下記に示す．この 2 つの発言をみると，太陽光パネルの設置を促進する同じような意見を述べている．このような場合には，発言の内容だけでは当落の判断が困難であることがわかる．

落選した議員の発言

「つまり、大阪府は、太陽光パネルの設置検討、これは確かにしたんですけれども、残念ながら、結果としてほとんど太陽光パネル、今年度設置いたしません。」

当選した議員の発言

「府は、二十五年度に、太陽光パネルなどの省エネ・省ＣＯ２設備設置の融資利息の軽減のための預託制度を実施するとのことですが、わずかな利子軽減では、太陽光パネル設置促進にはほど遠いと言わざるを得ません。」

上記 2 名の議員の場合，発言量（発言文字数）を比較すると，当選した議員が落選した議員の 2 倍の発言量であった．選挙結果を予測するには，発言に含まれる意見に加えて，発言量など他の要素も考慮する必要がある．

次節では，対数尤度比では計算できない，当選者のみが発言した単語について調査する．

表 5: 北海道，神奈川県，大阪府の対数尤度比の結果

北海道					
単語 X	Lose(X)	Lose(NotX)	Win(X)	Win(NotX)	LLR
試案	17	61,134	1	332,648	27.97
お尋ね	55	61,096	82	332,567	24.00
伺い	304	60,847	1,037	331,612	23.51
値上げ	58	61,093	92	332,557	23.48
日本海	26	61,125	17	332,632	22.44
神奈川県					
単語 X	Lose(X)	Lose(NotX)	Win(X)	Win(NotX)	LLR
海	80	84,140	42	333,510	59.05
見解	9	84,211	355	333,197	52.18
カジノ	30	84,190	2	333,550	41.02
所見	324	83,896	682	332,870	40.35
文化芸術	38	84,182	17	333,535	30.68
大阪府					
単語 X	Lose(X)	Lose(NotX)	Win(X)	Win(NotX)	LLR
お尋ね	284	55,104	345	202,439	87.69
障がい	62	55,326	34	202,750	41.27
太陽光パネル	44	55,344	13	202,771	40.27
わけ	56	55,332	565	202,219	34.58
泉南市	25	55,363	1	202,783	34.49

3.1.2 当選者のみが発言する単語

当選者のみ発言する単語とは，落選者の出現頻度が「0」の単語である．また，落選者が発言しない単語に対して，当選者はその単語を含めて，どのような発言をしているのか，考察する．表 6 に，全データの中で，落選者が発言していない単語の一部を示す．掲載した単語は，落選者が 6 名以上いる道府県において，当選者だけが発言する単語の対数尤度比上位 3 単語である．

神奈川県議会において当選議員が「生活支援ロボット」についてどのような発言をしていたのかを確認する．以下に「生活支援ロボット」を含む発言の一部を抜き出した例を示す．

1. さがみロボット産業特区は、生活支援ロボットの実用化、普及を通じて...
2. 神奈川版オープンイノベーションで開発していく生活支援ロボットのテーマを発信するとともに...
3. こうした未来像を実現するため、生活支援ロボットのさらなる普及に向けて...

神奈川県で当選した議員は，生活支援ロボットという「新しい取り組み」について言及していることがわかる．この例から，時代に合わせた政治課題（となるキーワード）を含む発言が当落の判断材料になり得るのか，検討の余地がある．

4. 選挙結果の予測実験

本章では，議会における発言内容を用いて，選挙結果の予測を行う．本実験の目的は，議会での発言内容を用いて，既存の機械学習でどの程度当選予測が行えるのかを調査することである．本実験では，入力を各議員の発言から作成した特徴ベクトルとして，出力を「当選」あるいは「落選」の 2 値とする．入力データの作成は，議員の地方議会会議録の発言を形態素解析ツール MeCab を用いて分割し，Bag-of-words のベクトルを作成する．素性とする単語は，4 回以上出現する単語とした．また，全議員の発言において 30%以上出現する単語

表 6: 道府県別の当選者だけが発言する単語の例

単語 X	Lose(X)	Lose(NotX)	Win(X)	Win(NotX)
北海道				
党	0	61,151	82	332,567
出先機関	0	61,151	60	332,589
移住	0	61,151	58	332,591
栃木県				
指定廃棄物	0	42,515	84	248,137
所管	0	42,515	68	248,153
常任委員会	0	42,515	58	248,163
埼玉県				
危険ドラッグ	0	34,030	78	349,558
県職員	0	34,030	75	349,561
認知症	0	34,030	72	349,564
神奈川県				
生活支援ロボット	0	84,220	95	333,457
朝鮮学校	0	84,220	82	333,470
がん患者	0	84,220	60	333,492
長野県				
消費税	0	58,493	110	392,635
討論	0	58,493	80	392,665
社会保障	0	58,493	72	392,673
静岡県				
避難所	0	32,205	95	335,423
自民改革会議	0	32,205	82	335,436
教師	0	32,205	72	335,446
愛知県				
意見書案	0	56,648	161	406,693
消防団員	0	56,648	132	406,722
暫時休憩	0	56,648	129	406,725
大阪府				
御堂筋	0	55,388	66	202,718
借金	0	55,388	58	202,726
臨時財政対策債	0	55,388	56	202,728
兵庫県				
公明党	0	33,289	93	236,402
商店街	0	33,289	81	236,414
まち	0	33,289	77	236,418
山口県				
岩国錦帯橋空港	0	77,286	81	339,782
開港	0	77,286	50	339,813
表現	0	77,286	48	339,815
長崎県				
td	0	55,281	405	345,529
(株)	0	55,281	245	345,689
農業生産法人	0	55,281	108	345,826
熊本県				
山鹿市	0	79,867	75	307,779
北朝鮮	0	79,867	74	307,780
公会	0	79,867	56	307,798
鹿児島県				
売却	0	73,763	98	474,951
臨港道路	0	73,763	88	474,961
患者	0	73,763	84	474,965

も対象外とした．その後で，ベクトルを LSI(Latent Semantic Indexing) を用いて 100 次元のベクトルに圧縮する．出力データは，当選を「 1 」，落選を「-1」のいずれかの値である．分類手法は，Support Vector Machine を用いる．実験データは，表 3 に含まれる「発言あり」の議員 1,763 人の発言である．学習データは北海道から広島県までの 1,411 人（当選 1,252 人, 落選 159 人）の発言とし，評価データは徳島県から鹿児島県までの 352 人（当選 313 人, 落選 39 人）の発言とした．表 7 に，SVM による予測の Precision， Recall ，F 値を示す．再現率が 1.00 になっているが，これは全て出力を「当選」としたためである．

この結果から，発言に含まれる単語から適切に学習できていないことがわかる．機械学習を扱う場合に一般的に問題となる「学習データの不足」「不均衡なデータセット」が原因だと考えられる．本研究で用いたデータの場合，自治体によって当選者数にばらつきがあることや，議員数が限られていることも影響している．

また，学習データと評価データの分け方にも工夫の余地がある．例えば，都道府県別にデータを分割し，47 分割の交差検定をすることも考えられる．また，同一自治体を対象として，2011 年の選挙，2015 年の選挙を学習データとして，2019 年の選挙を予測することも考えられる．

さらに，発言単語だけで選挙結果の予測をできるのか、という根本的な問題もある．この点については「発言量」を用いた川浦らの研究 [1] を参考にしながら，検討を進める予定である．

表 7: Suport Vector Machine による予測結果

Precision	Recall	F-measure
0.89 (313/352)	1.00 (313/313)	0.94

5. おわりに

本稿では，会議録，議員プロフィール，選挙結果が含まれるデータから，発言内容と選挙結果（当落）を結びつけて，データセットを構築する方法について述べた．そして，機械学習による選挙予測を行うための予備調査として，構築したデータセット内の各議員の発言内容（発言に含まれる単語）が次回選挙に影響を与えるのかについて，調査を行なった．本調査では，対数尤度比を用いて当選者と落選者の発言に特徴的な単語を明らかにした．また，当選者のみが発言している単語についても考察を行った．その結果，当選者・落選者に特徴的な語はあるものの，単語の出現頻度の情報だけでは当落の予測は困難であり，発言量や発言時期などの要素も考慮する必要があることを確認した．さらに，発言内容に含まれる単語を素性とした当落予測実験を行い，単純な素性では当落の判断が困難であることも明らかになった．

今後は，2019 年 4 月の第 19 回の統一地方選挙の結果を用いて研究を進める予定である．

謝辞

本研究は JSPS 科研費 JP16H02912，JP17K03785 の助成を受けています．

参考文献

[1] Akihiko Kawaura, Yasutomo Kimura, Keiichi Takamaru, and Yuzu Uchida. Elected officials in the local assembly: Analysis of prefectural plenary session transcripts. *Doshisha University Center for the Study of the Creative Economy, Discussion Paper Series*, No.2018-02, 2018.

[2] 湯淺 墾道. インターネット選挙運動と公職選挙法. **選挙研究**, 30(2):75–90, 2014.

[3] 上ノ原 秀晃. 2013 年参議院選挙におけるソーシャルメディア. **選挙研究**, 30(2):116–128, 2014.

[4] 鳥海 不二夫 and 吉田 光男. 2017 年衆議院選挙における政党公式アカウントフォロワーの分析. **人工知能学会全国大会論文集**, JSAI2018:1E305–1E305, 2018.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

機械翻訳とラフセット理論を利用した特許公報分類システム

A Study of Patent Publication Classification Using Machine Translation and Rough Set Theory

樽松理樹[*1]
Masaki KUREMATSU

[*1] 岩手県立大学
Iwate Prefectural University

Abstract: It is important to check exists patents before submitting own patents or sailing new products. However, it is hard task to check a lot of patents. In order to support this task, I proposed a framework of a patent publication classification system using machine translation and Rough set theory in this paper. It makes a classifier from patent publications labeled by experts with the following 4 steps. In step.1, this framework extracts sentences from abstracts of patents based on block tags. In step.2, it translates these sentences to English using Machine translation and extracts terms using Term Frequency and Rough Set reduction. In step.3, it makes a Document Term Matrix form extracted terms. In step.4, it makes a Naive Bayes Classifier and Rough set rules from a Document Term Matrix as classifier. It classifies unlabeled patent publications by these classifiers. I developed this framework by R language and some natural language processing tools and evaluated. In evaluation, I tried to classify some patent publications with an expert. Experimental results show the possibility of this approach.

1. はじめに

特許公報[発明協会 05]は，代表的な知的財産情報である．特許公報の処理として分類を行うことが多い．検索システム[藤井 12]を用いて行うことは可能であるが，実務においては，さらに細分化をする必要がある．研究協力者である企業の知的財産部門に所属する専門家は，その特許が述べている課題と手段で分類している．しかし，特許公報が膨大であるため，このような独自の処理に対応するツールが必要となっている．

この課題に対し，著者は企業と協力し，手法の構築 [樽松 18]に取り組んできた，これらの研究においては，人による検証・反映を意図し，理解できる分類モデルを構築することと目標に，表層情報を用いるナイーブベイズ分類（以後，NBC）を中心に進めてきた．しかし，分類精度は不十分である．その要因として，表記ゆれ，情報不足などが挙げられる．

以上の背景から本研究では，本研究では，機械翻訳とラフセット理論を利用した特許公報システムを提案する．本手法では，機械翻訳で英語に翻訳することで表記ゆれの削減を図る．また，ラフセット理論[Zdzislaw 82]における「属性の縮約」（クラスがお互いに識別されるために必要かつ十分な属性の組）を用いることで語句の絞込みを，決定ルールを用いることで語句間の関係を考慮することを図る．

2. 提案システム

2.1 システム概要

本システムは図1に示すように，大きく「DTM 構築部」「分類器作成部」「分類推定部」からなる．DTM（Document Term Matrix）とは，各列が語句，各列が文書に対応し，各文書における語句の出現数を行列形式で示したものである．「DTM 構築部」では，専門家によって与えられた特許公報から，分類処理に有用と評価し抽出した語句の文書毎の出現数から DTM を構築する．「分類器生成部」では，ラフセット理論に基づき，DTM から決定ルールを抽出する．また、NBC で利用する尤度表を構築する．「分類推定部」では，決定ルールおよび尤度表をもとに新たな特許の分類を行う．以降で各部分の説明を加える．

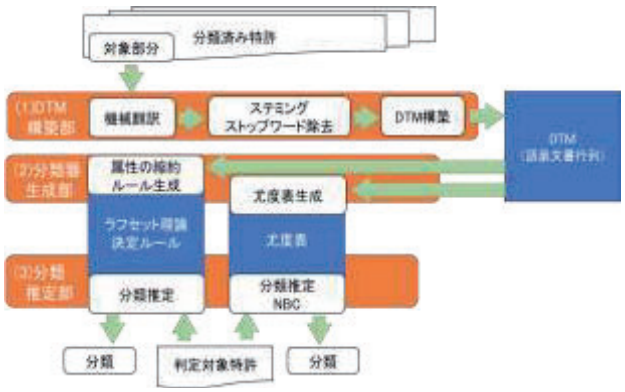


図 1. システム概要

2.2 対象とする特許公報

本システムでは，専門家によって ICP や F タームなどで絞り込まれた特許公報を対象とする．これらの特許公報から、独自の分類を行うために着目する部分を，ブロックタグを利用して抽出する．ブロックタグとは，特許に含まれるブックマークであり，特許の構成要素を示している．これを利用することで，特許から必要な部分が抽出可能となる．以後，抽出された部分を本稿では特許文と呼ぶ．

2.3 DTM 構築部

専門家に分類付けされた特許公報から，以下の流れで分類出現語句情報を抽出する．

① 機械翻訳を用いて特許文を英語に翻訳する．
② ①で得られた英文から，事前に指定する品詞の単語のみを取り出す．なお複数回出現する場合も 1 回のみ取り出す．取り出した単語に対し，ステミング，ストップワードの削除を行う．
③ ②で抽出した語句を元に，DTM を構築する．このとき，DTM の各要素は，出現の有無を示す 2 値とする．

連絡先：樽松理樹，岩手県立大学ソフトウェア情報学部，岩手県滝沢市巣子 152-52，電話：019-694-2582，FAX：019-694-2501，メール：kure@iwate-pu.ac.jp

2.4 分類器生成部

前述までの処理で構築した DTM から，(1)ラフセット理論に基づく決定ルール及び(2)NBC に必要となる尤度表をそれぞれ構築する．決定ルールを構築するために，はじめに属性の縮約を行う，その後，決定ルールを構築する．尤度表とは，各語句について，特定の分類の文書において出現した割合を示す表である．これは単純に数え上げることで作成する．

2.5 分類推定部

分類推定部では，推定対象となる特許に対し，ラフセット理論に基づく決定ルールおよび尤度表を用いた NBC を適用する．それぞれ最も評価値が高い分類を正解として推定する．

3. 検証評価

3.1 検証内容

提案手法の有用性を評価するために，専門家の協力のもと検証を行った．以下段階を追って説明する。

(1) 対象とする特許公報：専門家が分類わけを行った特許公報 470 件を用いる．各特許公報は，6 種類に分類わけされている．分類ごとの特許数は最大 118，最小 47，平均 78.3±27.6 と偏りがあるが．このまま利用した．

(2) 特許文抽出：今回利用する分類は，特許公報に挙げられた「解決すべき課題」である．その点から，課題に関する記述部分を対象とする．また明細書を利用する場合，ノイズが含まれることが多くなると考えられるため要約中の課題または目的に関する記述の部分を用いる．

(3) 機械翻訳：今回は，特許専用と銘打っているクロスランゲージ社製の PAT-Transer V12 for Windows[クロスランゲージ 14]を用いて翻訳を行った．

(4) 語句の抽出・DTM 構築：機械翻訳で得た翻訳文に対し，Helmut Schmid 氏が開発した TreeTagger[Schmid 94]を用い，名詞，動詞の動名詞・現在分詞・過去分詞を対象とした．これらは専門家との話し合いで決定している．さらに R 言語[The R Foundation]の tm パッケージ[Feinerer 18]を利用し，ステミング，ストップワードの削除を行う結果から，DTM を構築する．

(5)分類器生成：構築した DTM に対し，ラフセット理論に基づく決定ルールと尤度表の作成を行う．これらには，R 言語の RoughSets パッケージ[Riza 15]，e1071 パッケージ[Meyer 19]をそれぞれ用いた．なお NBC において Laplace は 1 に設定している．

(6) 予測：予測では，5-fold Cross Validation（訓練データ：平均 378 文，テストデータ：平均 92 文）を実施する．この際ラフセット決定ルールの投票は，成立したルールの Laplace 評価値の最大値を用いた．

3.2 検証結果

評価においては，Accuracy および Kappa(K 統計量)を用いる．Accuracy は正しく分類を推測した割合・精度であり，Kappa は偶然正しい予想になった確率を差し引いて Accuracy を調整した値である．また，テストデータ中の 1 クラスの割合の最大値 No Information Rate（NIR）は 0.19 である．

本検証においては，NBC では 7 文書以上出現する語句を用いた．これは出現数の平均が 7.7 であったことから決定した．結果，平均 150 個の語句を抽出した．一方，ラフセット理論による属性の縮約では平均 50 個の語句を抽出した．

分類の推定結果を図 2 に示す．図 2 において#は Cross Validation の回数，RST はラフセット理論の結果，ランダムは，ランダムで選択した場合の正解確率（1/分類数）を意味する．

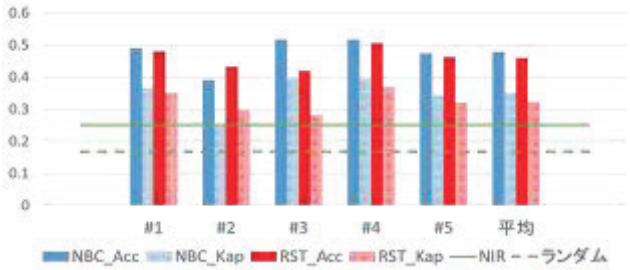


図 2 検証結果

3.3 評価

NBC，ラフセット理論による分類ともには，Accuracy，Kappa ともに NIR を上回ったことから，一定の効果があると考えられる．また NB とラフセット理論による分類の間には有意差があり，NBC の精度の方が高い．

4. おわりに

本稿では，機械翻訳とラフセット理論を用いた特許分類推定手法を提案した．評価実験の結果，NBC を用いた場合は一定の効果が見込まれたが，ラフセット理論を用いた結果は十分な成果を得られなかった．今後の課題としては，設定を変更した検証の実施を含めた検証結果の分析，その結果に基づく手法の改善，他の文書分類課題での適用結果を踏まえた手法の長所短所を明らかにすることが挙げられる．

謝辞

評価実験にご協力いただいた A 氏に感謝の意を表します．また本研究の一部は，科研費・基盤 C（課題番号 15K00154）の助成を受けております．

参考文献

[クロスランゲージ 14] クロスランゲージ社，PAT-Transer，https://www.crosslanguage.co.jp/products/pat-transer_v12/ ,2014

[Feinerer 18] Ingo Feinerer，Kurt Hornik，Artifex Software, Inc.The：Package ‘tm’，https://cran.r-project.org/web/packages/tm/ , 2018

[藤井 12] 藤井敦，谷川英和，岩山真，難波英嗣，山本幹夫，内山将夫：特許情報処理:言語処理的アプローチ，コロナ社，2012

[発明協会 05]社団法人発明協会：産業財産権標準テキスト 特別編，東京書籍，2005

[樽松 18] 樽松理樹：ラフセット理論を用いた特許公報分類支援システムの提案，人工知能学会全国大会第 32 回，2018

[Meyer 19] David Meyer， et.al : Package ‘e1071’， https://cran.r-project.org/web/packages/e1071，2019

[Riza 15] Lala Septem Riza, et.al ：Package ‘RoughSets’，https://cran.r-project.org/web/packages/RoughSets/，2015

[Schmid 94] Helmut Schmid: Probabilistic Part-of-Speech Tagging Using Decision Trees. Proceedings of International Conference on New Methods in Language Processing，pp.44-9 ，1994 ，http://www.cis.uni-muenchen.de/~schmid/tools/TreeTagger/

[The R Foundation 97] The R Foundation，https://www.r-project.org/，1997

[Zdzislaw 82] Pawlak，Zdzisław :Rough sets，International Journal of Parallel Programming，Vol.11，No.5，pp.341–356，Springer，Heidelberg , 1982

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

最も単純な文書分類器
The Simplest Document Classifier

白井　芳宜[*1]　Shirai, Yoshitaka
平田　豊[*1]　Hirata, Yutaka

[*1] 中部大学大学院　工学研究科　ロボット理工学専攻
Department of Robotic Science and Technology, Chubu University Graduate School of Engineering

Document Classification (DC) is the task to assign a document to a specific category. Deep convolutional neural network (DCNN) outperforms humans in DC in terms of speed and accuracy. However, the internal classification process of DCNN-based classifiers is in a black box. Here we propose an extremely simple algorithm for DC that is very fast and highly accurate, and allows us to examine classification processes. We demonstrate the validity of the proposed method, using major document data bases such as 20 Newsgroups, Livedoor-news, IMDB, and Twitter.

1. はじめに

近年, 膨大な情報を高速に処理する手段として人工知能が活用されている. 文書を複数のカテゴリに分類する文書分類問題では, 分類精度は畳み込みニューラルネットワーク(CNN)を利用した手法[Zhang 2015] により向上し, CNN における課題の一つである学習に要する時間は, fastText [Armand 2016]によって短縮され, 実用的な文書分類が可能となっている. しかしながら, 一般に指摘されているように, CNN による分類結果の導出過程はブラックボックスであり, 文書分類においても, 分類結果導出要因の分析が可能な方法が求められている[Balaji 2017]. そこで本研究では, 文書分類において, 高速かつ高精度でありながら, 分類結果の導出過程の分析が可能な手法を提案する. その分類性能を代表的な高速分類器であるfastTextと比較すると共に, Twitter データを例に, 分類結果に対する導出過程分析の実例を示す.

2. 提案手法

提案手法(Simplest Document Classifier:SDC)による分類器の生成と学習には, 人がそれぞれ C 種類のカテゴリのうちのいずれかを付与した L 件の文書を用いる. まず, L 件の文書に出現する全ての単語とその文章のカテゴリに対応した ID(単語ID:1~N, カテゴリ ID: 1~M)を持つ辞書$\{Wd, Cd\}$を作成し, $N\times M$ 次元の単語ベクトル V を生成し, 全ての要素を 1 とする. 次に, L 件の文章全てに対し, カテゴリC_nが付与された m 番目の文書 D_m の中に出現する j 番目の単語をW_{mj}とすると, $V[Wd(W_{mj})][Cd(C_n)]$ に 2 を代入する. ここで, $Wd(W_{mj}), Cd(C_n)$はそれぞれ単語W_{mj}の IDとカテゴリC_nの ID である. こうして初期化された単語ベクトルを用い, 式(1)で文書 D_m に対する各カテゴリ k(1~M)の評価値 $Score(k)$ を計算し, 式(2)で分類予測をする. L 件全ての文書のカテゴリを分類予測した後, 誤分類された文書D_xにおける正しいカテゴリをC_x, その中に出現する単語をW_{xj}として, 誤分類予測された X 件の文書全てを用いて式(3)で単語ベクトルを更新する. ここで, L 件の文書の分類予測と単語ベクトルの更新を繰り返す工程を学習と呼ぶ.

$$Score(k) = \Sigma_j \log_2 V[Wd(W_{l_j})][k] \quad (1)$$

$$Predict = \underset{1\leqq k\leqq M}{\operatorname{argmax}}\ Score(k) \quad (2)$$

$$V[Wd(W_{x_j})][Cd(C_x)] = V[Wd(W_{x_j})][Cd(C_x)] + 1 \quad (3)$$

3. 実験

3.1 データセット

本実験では, 2 クラスおよび多クラスに分類された日本語と英語のデータセットを用いた. 各データセットの名称と言語, ならびに学習と評価に用いた文書数とカテゴリ数を表 1 に示す.

表 1　実験に用いたデータセットの概要

名称	言語	学習用	評価用	カテゴリ
20 Newsgroups[*1]	英	11293	7528	20
Livedoor-news[*2]	日	5080	2287	9
IMDB[*3]	英	25000	25000	2
Twitter[*4]	日	12797	12797	2

各データセットは参照先の URL に公開されているものを使用した. このうち, Twitter は何らかの商品への意見が述べられた約 54 万件のツイートを人が 5 つの項目(1: ポジティブ, ネガティブいずれの内容も含まれる. 2: ポジティブな内容が含まれる. 3: ネガティブな内容が含まれる. 4: ニュートラルな内容が含まれる. 5: 無関係な内容が記述されている)によって評価したものであり, 本実験では項目 2, 3 に該当するデータを使用した.

3.2 評価方法

表1に示した各データセットを用い, 学習時間と分類精度を評価した. また, 4 つのデータセット内の全データを含む合成データを構成し, 学習以外に要する時間を計測した. 具体的には, データの読み込みと分類器の生成に要する時間 ReadTime, 分類器の保存に要する時間 SaveTime, データ及び分類器の読み込みと文書分類に要する時間 TestTime を評価した. fastText は, github に公開されているソースコード[*5]を使用した.

連絡先:
白井　芳宜, 中部大学大学院　工学研究科 ロボット理工学専攻, shiyoshic@gmail.com
平田　豊, 中部大学大学院　工学研究科 ロボット理工学専攻, yutaka@isc.chubu.ac.jp

*1 ana.cachopo.org/datasets-for-single-label-text-categorization
*2 www.rondhuit.com/download.html#ldcc
*3 www.tensorflow.org/tutorials/keras/basic_text_classification
*4 bigdata.naist.jp/~ysuzuki/data/twitter/
*5 github.com/facebookresearch/fastText

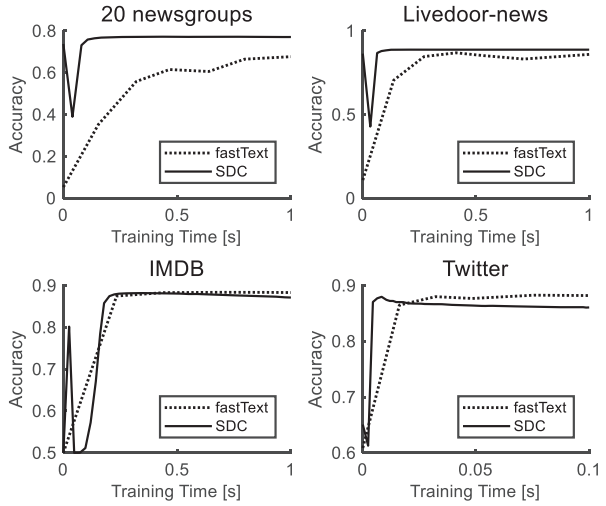


図1　学習時間と分類精度の関係

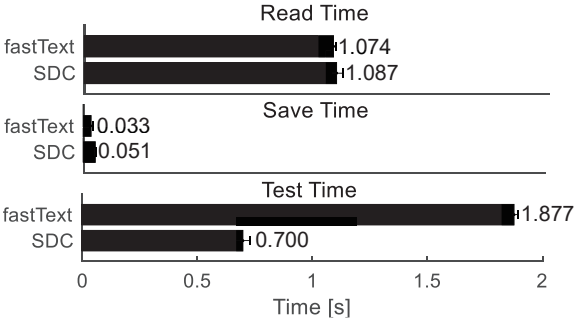


図 2　学習以外に要する時間 (10 回の平均値±SD)

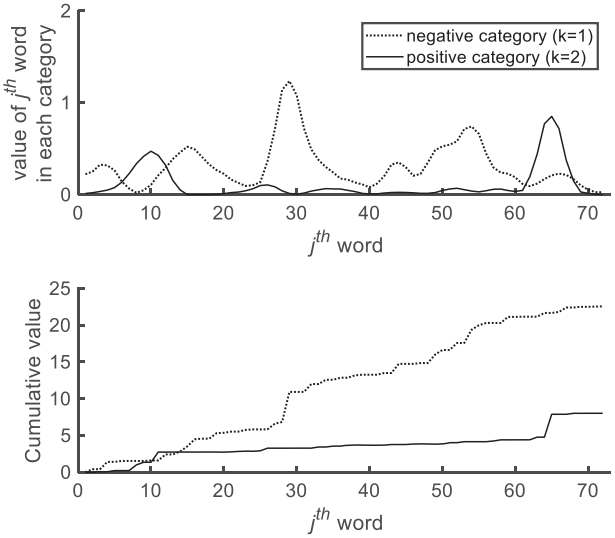


図 3　提案法 SDC による文書分析の結果例

4. 結果

4.1 学習時間と分類精度

fastText と SDC における学習時間と分類精度の関係を図1に示す. 多クラス分類である 20 newsgroups, Livedoor-news においては, SDC がより高速で高精度な分類器となっている. 2 クラス分類である IMDB, Twitter においては, 分類精度の差は極めて小さく, 学習が収束する時間も同程度となった. このことから SDC は, 2クラス分類では fastText と同様に極めて短い学習時間で高い分類精度を持つ分類器であり, 多クラス分類では fastText より高速かつ高精度な分類器であるといえる.

4.2 学習以外に要する時間

合成データを用いた学習以外に要する時間の計測結果を図 2 に示す. ReadTime と SaveTime に大きな差は見られないが, TestTime において, SDC が fastText より 2.683 倍高速であった. 以上の結果と 4.1 の結果から, SDC は総合的に fastText より高速で, 同等またはより高い精度を持つ分類器といえる.

4.3 文書分類導出過程分析

Twitter データセットを用いた SDC の分類結果導出過程の分析例を図 3 に示す. この分類過程分析に用いた文書は「*ZenpadS8.0 でデレステ。スペック的に 3D プレイは特に問題ないのはわかっていたが、やはり音遅延が激しい。リズム判定で 27 とか出るので SE のシャンシャンがズレまくる。こればかりはどうしようもないので仕方なく SE なしでプレイ。Xperia は音関係優秀なんやなぁ。*」である. 図 3 上図は, 出現順 (j) に並べられた単語の各文書カテゴリ(否定的 k=1, 肯定的 k=2)に対する式(1)右辺内の$\log_2 V[Wd(W_{l_j})][k]$ に移動平均処理を施して滑らかにしたものである(灰色:k=1, 黒:k=2). 下図は, 式(1)右辺内 j の増加に伴う左辺 *Score* (灰色:k=1, 黒:k=2)の推移を示す. 上図から, 文書中に複数の否定的な言葉が出現し, 肯定的な言葉は終盤に出現していることが分かる. また下図では, 最終的に *Score*(1) > *Score*(2)となっており, この文書が否定的な文書(k=1)に分類されたことを示している. この文書例では, Xperia と ZenpadS8.0 の使用者が, 前者の音響性能に不満を述べつつ, 終盤に後者の音響性能を評価している. また,「音遅延が激しい」「ズレまくる」「どうしようもない」と否定的な言葉が頻発し, 肯定的な言葉「Xperia は音関係優秀」は終盤に出現しており, 図 3 上段の各線の推移がこれを表している. 実際には, データベースにおけるこの文書の正解カテゴリは, Xperia に対する意見として肯定的な文書(k=2)に分類されており, SDC は誤分類していることになる. ただし, 上述のように, この文書には否定的な単語が多く含まれており, Xperia に対する意見という先見知識が無ければ, 人も SDC と同じ判断をする可能性が高い. さらに, SDC はこの例のみならず, 評価した他の文章においても, 文書中の肯定的内容と否定的内容を出現語順に正確に評価しており, 今後, この情報を元に評価対象を抽出する手法を付加することにより, 分類精度がさらに向上する可能性がある.

5. 結論

近年, 深層学習によって, 人工知能の性能は急速に向上した. しかしながら, 文書分類においては, SDC のように極めて単純な手法でも充分な有効性が確認された. また SDC では, 分類結果に対する導出過程の直感的把握も可能である. 今後, 深層学習を用いた分類器が不得意とする結果導出の要因分析が必要となる様々な場面において SDC が活用できるものと期待される.

参考文献

[Armand 2016] Armand Joulin, Edouard Grave, Pitor Bojanowski, and Tomas Mikolov: Bag of Tricks for Efficient Text Classification, arXiv preprint arXiv:1607.01759, 2016.

[Balaji 2017] Balaji Laskshminarayanan, Alexander Pritzel, Charles Blundell: Simple and scalable predictive uncertainty estimation using deep ensembles, In *Proceedings of NIPS*, 2017.

[Zhang 2015] X Zhang, Junbo Zhao, and Yann LeCun: Character-level convolutional networks for text classification, In *Proceedings of NIPS*, 2015.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

LSTM と Attention を用いた自動採点及び採点支援の実用化に向けて

Automatic Scoring and Scoring Support System using LSTM and Attention

高井 浩平 *1 Kohei Takai　竹谷 謙吾 *1 Kengo Taketani　早川 純平 *2 Junpei Hayakawa　森 康久仁 *3 Yasukuni Mori　須鎗 弘樹 *3 Hiroki Suyari

*1千葉大学 大学院融合理工学府 情報科学コース
Department of Applied and Cognitive Informatics, Graduate School of Science and Engineering, Chiba University

*2千葉大学 工学部 情報画像学科
Department of Informatics and Imaging Systems, Faculty of Engineering, Chiba University

*3千葉大学 大学院工学研究院
Graduate School of Engineering, Chiba University

In the university unified entrance examinations from 2020, a new kind of question to require answers in description style will be introduced. In this paper, we apply the scoring using LSTM and attention. We use about 1,200 score sheets and prepare two datasets((a), (b)) in the evaluation. (a) is randomly generated and (b) is generated using an automatic scoring system. As a result, the accuracy is 0.91 for (a) and 0.73 for (b).

1. はじめに

2020 年度より大学入試センター試験に短答記述式問題が導入される予定であり，採点には多大なコストがかかると予想されている．そこで，竹谷らは自動採点をメインとしたシステムを目指し開発を行っている [竹谷 19]．その竹谷らの採点システムでは採点精度を重視し，機械学習手法を取り入れていない．

本研究では，自動採点で機械学習手法が採点においてどれほど効果を発揮するかを検証するため，bidirection-LSTM と self-attention を用いた文書分類モデルを構築し，採点を行った際の精度を検証する．また，self-attention を利用することで予測理由の可視化を行い，採点の際に何に注目しているかを確認する．実験では，実際に中学生が解答した約 1,200 人分のデータを用い，採点は正解/不正解の 2 値分類とした．全データをランダムに分割して作成したデータセットと，竹谷らの採点システムにおいて採点を行った結果をデータセットとした 2 つのデータセットに対して実験を行い，結果を比較する．

2. 関連研究

竹谷らの自動採点システムは，シーケンスアライメントアルゴリズムを用いたルールベースのシステム（図 1）となっており，国語・理科・社会の 3 科目それぞれ平均して 1,188 人分の解答データに対して自動採点率約 68%，採点精度約 99.8%という結果を実現している（表 1）．

表 1: 実験結果 [竹谷 19]

	国語	理科	社会	平均
データ数	1198	1195	1174	1188
自動採点率 (%)	64.5	76.4	63.2	68.0
採点精度 (%)	99.9	100	99.6	99.8

連絡先: 高井 浩平，千葉大学 大学院融合理工学府 須鎗・森研究室，263-8522 千葉市稲毛区弥生町 1-33，e-mail : k.takai@chiba-u.jp

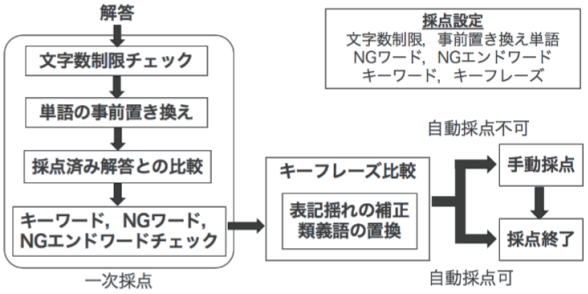


図 1: システム構成図 [竹谷 19]

ニューラルネットワークを用いた採点に関する研究では，寺田らが SVM，CNN の各手法の精度を検証している [寺田 16]．高校学習範囲の試験問題を大学生に解かせたものをデータとして，正解/不正解の 2 値分類を行い，どちらの手法も 90%近い精度で分類可能であることを確認している．

また，水本らが国語記述式答案を対象として，採点項目ごとの採点を行うモデルを提案している [水本 18]．モデルは LSTM と複数の attention を用いて構築されており，どの問題においても高い性能で予測が可能である．複数の項目点を予測することで学習者に対するフィードバックを可能にし，attention の分析によって学習支援に活用する可能性を示唆している．

しかしながら，どちらの手法も手動によるラベル付けが必要であり，全自動で採点を行った際の有効性を考慮していない．本研究では，手動によるラベル付けを行って実験した結果を踏まえた上で，採点システムを利用して全自動で採点を行った場合の精度を検証する．

3. self-attention を用いた文書分類モデル

本研究では，Zhouhan らの提案したモデル [Zhouhan 17] を参考に，日本語のテキストを入力として，正解/不正解の 2 値ラベルを出力する文書分類モデルを構築した．

bidirection-LSTM にテキストデータを与え，各単語に対応

する隠れ層から，ラベル予測の際にどの単語に注目するべきかを表す確率（self-attention）を予測する．その後，self-attention の重みを与えた各単語に対応する隠れ層を足し合わせ，正解/不正解の 2 値ラベルの予測を行う．このとき，self-attention の重みを可視化することで，予測の際にどの単語に注目したのかを確認することができる．本研究の実験では epoch 数を 300 に設定して学習を行い，self-attention の重みが大きい単語は赤色で強調される仕様になっている．

ラベルが付与されたデータに対し構築したモデルのみで採点を行うだけでなく，竹谷らの採点システムにモデルを導入して全自動で採点を行うことで精度を比較する．

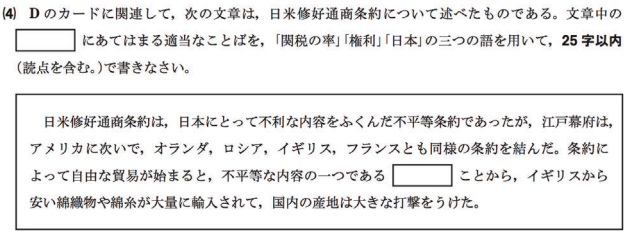
4. 評価実験

4.1 実験設定

株式会社進学研究会から提供して頂いた「中学生を対象に行われた模試の記述式問題 3 科目分の解答データ」を検証データとして用いた．ここで，解答が空欄のものはデータとして適切ではないため除外した．また，各解答には正解/不正解の 2 値ラベルが付与済み（採点済み）である．各科目の問題の特徴は表 2 のようになっており，例として図 2 に社会の問題文を示す．

表 2: 各科目の問題の特徴

国語	20 字以内 穴埋め形式
理科	字数制限なし 自由記述形式
社会	25 字以内 穴埋め形式


(4) D のカードに関連して，次の文章は，日米修好通商条約について述べたものである。文章中の［　　］にあてはまる適当なことばを，「関税の率」「権利」「日本」の三つの語を用いて，**25 字以内**（読点を含む。）で書きなさい。

日米修好通商条約は，日本にとって不利な内容をふくんだ不平等条約であったが，江戸幕府は，アメリカに次いで，オランダ，ロシア，イギリス，フランスとも同様の条約を結んだ。条約によって自由な貿易が始まると，不平等な内容の一つである［　　］ことから，イギリスから安い綿織物や綿糸が大量に輸入されて，国内の産地は大きな打撃をうけた。

図 2: 社会の問題文

4.1.1 実験 (a)：ランダム

全解答データに正解/不正解のラベルが付与済み（採点済み）であることを前提として，文書分類モデルでの採点を行う．

使用するデータセットは，全データをランダムに分割して，約 7 割の解答をトレーニングデータ，残りをテストデータとして設定する（表 3）．

表 3: 実験 (a) データセット 内訳

	国語	理科	社会
トレーニングデータ数	781	951	819
テストデータ数	157	191	164

4.1.2 実験 (b)：竹谷らの採点システムを利用

全解答データに正解/不正解のラベルが付与されていなかった場合を想定し，竹谷らの採点システムに構築した文書分類モデルを導入することで全自動での採点を行う．

データセットとして，竹谷らの採点システムで自動採点されたものをトレーニングデータ，自動採点できなかったものをテストデータとして設定する（表 4）．

表 4: 実験 (b) データセット 内訳

	国語	理科	社会
トレーニングデータ数	447	773	549
テストデータ数	491	369	434

4.2 結果・考察

4.2.1 実験 (a)

実験 (a) の結果を表 5 に示す．結果の値は実験を 5 回行った際の平均値となっており，データセットは実験毎にランダムに作り直している．

また，最も精度の高かった社会のなかで，正解の解答を正しく予測したものと，正解の解答を正しく予測できなかったものの self-attention を可視化した例を図 3，図 4 に示す．

表 5: 実験 (a) 結果

	国語	理科	社会
accuracy	0.83	0.81	**0.91**
precision	0.80	0.84	**0.92**
recall	0.89	0.93	**0.95**
F-measure	0.84	0.88	**0.93**

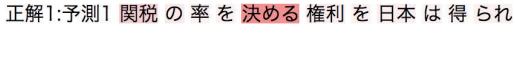


図 3: 実験 (a) にて正解の解答を正しく予測した例

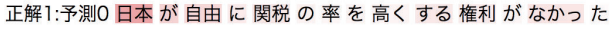


図 4: 実験 (a) にて正解の解答を正しく予測できなかった例

実験 (a) では，すべての科目で精度 0.8 以上を記録し，社会に関しては精度 0.9 以上に達することが確認できた（表 5）．各科目の精度を比較してみると，理科の精度が 0.81 と最も低かったが，これは問題形式が「字数制限なし 自由記述形式」だったことが原因であると考えられる．実際に解答データを確認してみても，生徒の解答内容はバラバラであり，中には単語のみで解答しているものもあった．よって，トレーニングデータを使って学習してもテストデータに対応できなかったのだろうと考えられる．

一方，0.91 と最も精度の高かった社会の問題形式は「25 字以内 穴埋め形式」であり，解答も全体的に似通った答え方のものが多かった．self-attention を可視化した図 3 を見ると，「決める」「なかった」という指定語以外の解答条件に沿った部分に注目できていることが確認できた．しかし，図 4 を見ると，「高くする」という表現に対応できず予測を誤っていることがわかる．この解答は正解なのだが，「高くする」という表現を使っている解答が他にないため，予測を誤ってしまったのだと考えられる．

4.2.2 実験 (b)

実験 (b) の結果を表 6 に示す．結果の値は実験を 5 回行った際の平均値となっている．竹谷らの採点システムでは採点毎に結果が変化しないため，データセットは実験毎に変更していない．

実験 (a) と比較するため，社会のなかで，正解の解答を正しく予測したものと，正解の解答を正しく予測できなかったものの self-attention を可視化した例を図 5，図 6 に示す．

表 6: 実験 (b) 結果

	国語	理科	社会
accuracy	**0.73**	0.67	0.67
precision	0.79	**0.94**	0.91
recall	0.57	**0.67**	0.53
F-measure	0.66	**0.78**	0.67

正解1:予測1 輸入 品 の 関税 の 率 を 決める 権利 が 日本 に は ない

図 5: 実験 (b) にて正解の解答を正しく予測した例

正解1:予測0 関税 の 率 を 日本 で 決め られる 権利 が なかっ た

図 6: 実験 (b) にて正解の解答を正しく予測できなかった例

実験 (b) では，全ての科目で精度が下がり，最高精度も 0.73 ポイントという結果になった（表 6）．これは，竹谷らの採点システムがルールベースで採点を行っていることから，自動採点ができた解答（トレーニングデータ）に似た表現の解答が集まり，手動採点が必要な解答（テストデータ）に対応できなかったことが原因であると考えられる．また，3 科目ともに precision 値が高く，recall 値が低いという共通点が見られた．つまり，文書分類モデルが正解と予測したものが実際に正解である精度は高いが，実際は正解の解答を誤って不正解と予測しているケースが多いということである．以上より，実験 (a) でも述べたことであるが，やはり稀有な表現が用いられている解答に対しては正しい予測が困難であると考えられる．

5. おわりに

本研究では，国語，理科，社会の 3 科目それぞれ約 1,200 人分の解答データに対して，(a) ランダムに作成したデータセットと，(b) 竹谷らの採点システムを利用して作成したデータセットの 2 つのデータセットを用意し，ニューラルネットワークを用いた文書分類モデルによる評価実験を行った．その結果，(a) の実験では精度 0.91 ，(b) の実験では精度 0.73 という結果が得られた．

実験から，ニューラルネットワークを用いた採点では，ある程度解答の表現に制限を設けられる問題形式のものに関しては高い精度で採点を行えるが，解答の表現が幅広い自由記述形式の問題では高い精度で採点を行うことは難しいことがわかった．また，竹谷らの採点システムの出力を利用して採点を行ったが，採点精度が約 7 割という事実は実用上問題があり，本アルゴリズムをシステムに導入するのは難しく，全ての解答を自動で採点するにはまだまだ解決すべき問題がある．しかし，self-attention を可視化することで注目した単語を確認することが可能になるので，採点支援の観点では利用する価値がある．

6. 謝辞

本研究にて評価実験を行うにあたり，データを提供して下さった株式会社進学研究会に心から感謝申し上げます．

参考文献

[竹谷 19] 竹谷 謙吾，高井 浩平，清水 杏奈，早川 純平，森 康久仁，須鎗 弘樹：大規模実データにおける記述式問題自動採点システムの検証，言語処理学会 第 25 回年次大会，2019.

[寺田 16] 寺田 凛太郎，久保 顕大，柴田 知秀，黒橋 禎夫，大久保 智哉：ニューラルネットワークを用いた記述式問題の自動採点，言語処理学会 第 22 回年次大会 発表論文集，2016.

[水本 18] 水本 智也，磯部 順子，関根 聡，乾 健太郎：採点項目に基づく国語記述式答案の自動採点，言語処理学会 第 24 回年次大会 発表論文集，2018.

[Zhouhan 17] Zhouhan Lin, Minwei Feng, Cicero Nogueira dos Santos, Mo Yu, Bing Xiang, Bowen Zhou, Yoshua Bengio : A Structured Self-attentive Sentence Embedding，Conference paper in 5th International Conference on Learning Representations，2017.

General Session | General Session | [GS] J-13 AI application

[2J3-J-13] AI application: consumption and living

Chair:Toshihiro Kamishima Reviewer:Yuiko Tsunomori

Wed. Jun 5, 2019 1:20 PM - 3:00 PM Room J (201B Medium meeting room)

[2J3-J-13-01] A study on cost reductions in labeling annotation of food images

○Naoki Kobayashi[1], Mitsunori Nanno[1] （1. FiNC Technologies, Inc.）

1:20 PM - 1:40 PM

[2J3-J-13-02] How can we predict the accuracy of weather forecast with machine learning?

○Masahide Funaki[1] （1. Niigata University）

1:40 PM - 2:00 PM

[2J3-J-13-03] Visualization of conceptual model of cooking workspace

○Ryutaro Hama[1], Azusa Mori[1], Yukari Takaku[1], Atsushi Harada[1], Atsushi Hashimoto[2] （1. LIXIL Corporation, 2. Kyoto University）

2:00 PM - 2:20 PM

[2J3-J-13-04] Clustering time-series data of cooking using object detection

○Azusa Mori[1], Ryutaro Hama[1], Atsushi Harada[1], Yukari Takaku[1], Atsushi Hashimoto[2] （1. LIXIL Corporation, 2. Kyoto University）

2:20 PM - 2:40 PM

[2J3-J-13-05] Comparison of Anomaly Detection Performance by Outlier Detection Methods for Household Power Consumption

○Miho Hashimoto[1], Yutaro Yagi[1], Takahiro Nishigaki[1], Takashi Onoda[1] （1. Aoyama Gakuin University）

2:40 PM - 3:00 PM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

食事画像のラベル付け作業の省力化に関する考察

A study on cost reductions in labeling annotation of food images

小林尚生 *1　南野充則 *1
Naoki Kobayashi　Mitsunori Nanno

*1株式会社 FiNC Technologies
FiNC Technologies, Inc.

In this paper, we discuss the cost reduction in labeling annotation of food images. Since the number of categories of food images is large, it takes time to select an appropriate label. We examine whether the cost reduction is possible by answering only the success or failure of the candidate label presented in advance by food image classifier. We compared the labeling speed with the method in which labeling workers watch the food image and select an appropriate label without any candidate labels. As a result, we concluded the cost reduction is possible in some categories. In other categories, we concluded improving the classifier accuracy is needed for the cost reduction.

1. はじめに

健康管理のためには，食生活の管理が重要である [厚生 00]. 食生活の管理とは，栄養バランスの整った食事を継続することである [厚生 15]. 食生活の改善や，習慣を維持するための方法の一つとして，食事記録（セルフモニタリング）が有効であると言われている [Burke 11] が，記録に手間がかかり，継続して行うのは容易ではない．食事記録をより簡単にすることは，食事記録の促進とその継続に繋がり，人々の健康管理に役立つと言える．こうした背景を踏まえ，近年，深層学習での一般物体認識を利用して食事内容が記録できるアプリケーションが人々の関心を集めている *1．一般物体認識の精度が向上することは，継続してアプリケーションを利用する動機につながるため，食事画像の一般物体認識の認識精度を向上させることは健康管理にとって意義があると言える．

食事の一般物体認識を実現するために，食事の画像と，画像中の食事の位置を示した矩形のアノテーション，及びその矩形に対して付与するラベルのアノテーションで構成されるデータセットが必要であるが，このうち，食事画像においては，ラベルのアノテーション作成の時間コストが矩形のアノテーションに比べて高い．これは，食事のカテゴリの数が多く，適切なラベルを選択するのに時間がかかるためである．データセットが多くなればなるほど，認識精度の改善が見込める [Sun 17] ため，ラベルのアノテーション付与の時間コストを低くし，より多くのデータセットを簡単に作成可能にすることは意義がある．

本稿では，ラベルのアノテーションの作成コストの省力化方法について考察する．食事画像のクラス分類器の推論結果を使うことによって，一からラベルを選択する作業よりも低コストでラベルを付加できる可能性があることを示す．

2. 省力化の方法

人が画像を見ながら一からラベルを考えて選ぶかわりに，事前に学習済みのクラス分類器で矩形を推論した結果を表示しておき，その推論の結果が正しいか否かだけを人が判断する方法を取る．人が判断するのは，正しいか，正しくないかの 2 択なので，考える時間が少なくなり，結果としてラベル付けのコストが大幅に削減されると考えられる．ラベルは大きく以下の 3Step を通して付与していく．

Step1: 推論に使うクラス分類器を学習する

Step2: 学習済みのクラス分類器で矩形を推論する

Step3: 推論結果の成否を人がチェックする

3. 実験

3.1 学習用の食事画像のデータセット

事前の推論のためのクラス分類器の学習には，Web 上で収集した画像データセットを使った．画像の合計枚数は 66,541 枚で，食事のカテゴリ数は 668 である．1 枚の画像には，1 つの食事が写っている．1 枚の画像に対して 668 カテゴリのうち，どれか 1 つのカテゴリだけが付与されている．データセットはカテゴリ名をクエリに Google 画像検索 API*2 を利用して集めたあと，カテゴリに合わない画像を人手で確認しながら削除することで構築した．最終的に，1 つのカテゴリに平均して 100 枚（最小で 44 枚，最大で 135 枚，最頻値 119 枚）の画像が集まった．

3.2 モデルの学習

ImageNet[Deng 09] のデータセットで学習済みの Resnet50[He 16] を最終層の出力数を 668 にして転移学習した．学習の最適化のアルゴリズムには確率的勾配降下法を用い，学習率は 0.01 に設定した．バッチサイズは 32 を用い，100 epochs 学習を実行した．データセットのうち，各カテゴリ 10 枚ずつはテスト用のデータとし，残りの 59,861 枚のうち 90%をトレーニング用のデータに，残りの 10%を毎 epoch の評価用のデータとして使った．学習曲線を図 1 に示す．最終的に Top1 Accuracy は 52.3%になった．

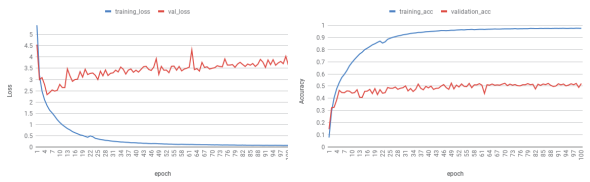
3.3 推論対象のデータセット

食事画像に付与されている矩形アノテーション 328,164 個を対象とした．この矩形アノテーションはランダムに抽出した食

連絡先: 株式会社 FiNC Technologies 〒 100-0006 東京都千代田区有楽町 1 丁目 12-1 新有楽町ビル 5F. TEL: 050-1748-7000

*1 https://company.finc.com/news/11311

*2 https://cloud.google.com/vision/



b) Loss の推移　　a) Accuracy の推移

図 1: 学習曲線

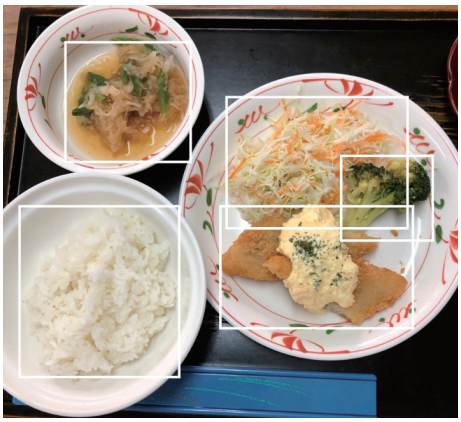


図 2: 矩形アノテーションの例．白色で描かれた四角形が矩形のアノテーションである．この例では 5 つの矩形が描かれている．

事記録アプリケーションのユーザーの食事画像 98,278 枚に人力で付与したものを利用した．矩形のサンプルを図 2 に示す．

3.4　推論結果の成否の確認

これらの矩形に対して学習したモデルで推論を実施した．推論結果のうち，上位 5 つの中にそのカテゴリが含まれる矩形のリストを各カテゴリごとに作成し，そのリストの推論結果の正しさを確認した．確認作業は図 3 のように，画面に推論結果と矩形付きの画像を表示し，推論内容が正しいかどうかを選ぶアプリケーションを用いて実施した．

今回は，9 つのカテゴリにおいてのみ確認作業は実施した．1 回答あたりの時間を計測したところ，平均で 3.84s であった．この値を使い，正解ラベルを 1 つ作成するのにかかる平均の作業時間，**正解ラベル作成速度**を下記の計算式で算出した．

$$\text{正解ラベル作成速度} = (\text{総件数} \times 3.84) \div \text{正解数} \quad (1)$$

各カテゴリごとに確認結果をまとめたものを表 1 に示す．

3.5　推論結果がない矩形へのラベル付け作業速度

正解ラベル作成速度の比較のために，推論結果がない状態で最適なラベルを選ぶ作業を実施した．対象の矩形は 328,164 個の矩形から 100 個抽出した．ラベル名を自由入力で検索して選べるアプリケーションを用いてラベルを選ぶ作業は実施した（図 4）．結果，100 個全てのラベルを付与するのにかかった合計の時間は 1 時間 34 分 20 秒で，一枚平均 56.6s であった．



図 3: 使用したアプリケーションの画面．左に食事画像と矩形が表示され，上部に記載されているカテゴリ名に当てはまるか否かを回答する．

表 1: 推論の精度と正解ラベル作成速度

カテゴリ名	総件数 (件)	正解数 (件)	正解率 (%)	正解ラベル作成速度 (s/件)
味噌汁	4104	3332	81.2	4.73
肉じゃが	546	157	28.8	13.4
天丼	347	99	28.5	13.5
親子丼	219	58	26.6	14.5
ソース焼きそば	1318	293	22.2	17.3
目玉焼き	5969	896	15.0	25.6
小松菜のおひたし	3953	509	12.9	29.8
オムレツ	4646	328	7.06	54.4
まぐろ丼	6320	186	2.94	130

4.　考察

参考となる通常のラベル付け作業では正解ラベル作成速度が 56.6(s/件) であったので，それよりも速かったカテゴリにおいては作業の省力化が見込める結果となった．一方で「まぐろ丼」のカテゴリにおいては，正解ラベル作成速度が悪化した結果となった．推論時の正解率が高くなれば正解ラベル作成速度は速くなるので，悪化したカテゴリについてはモデルの精度を改善することで，省力化が見込めるのではないかと考えられる．

いずれのカテゴリも学習用のデータセットでのテスト用データでは Top5 の正解率は 90%を超えているが，味噌汁を除いた全てのカテゴリにおいて，推論時の正解率が 30%と，推論時の正解率が著しく低い結果となっている．以下 2 点が原因として考えられる．

- 学習用の食事画像と推論用の食事画像には特徴の差分があり，その差分の学習がうまくできていない
- 本稿で扱った 668 のカテゴリには当てはまらないカテゴリの料理が推論対象の食事画像には出現する

前者の問題は，ユーザーの食事画像のデータセットもモデルの学習時に利用することで改善を見込める．後者の問題は，カテゴリ数を増やすことで改善を見込める．



図 4: 推論結果がない状態で最適なラベルを選ぶ作業の際に使用したアプリケーションの画面．左に食事画像と矩形が表示され，右側でラベルを選択する．ラベルは文字だけでなく，サンプル画像が表示されている．右側上部には自由入力でラベルを検索できる検索窓がある．

5. まとめ

本稿ではクラス分類によって，ラベルのアノテーションの作成コストの省力化の可能性について考察した．Google 画像検索 API で収集した画像を用いてクラス分類器を学習し，その推論結果の成否を判断することでラベル付けを行う作業と，通常のカテゴリが未知の食事画像の矩形に対してラベル付けを行う作業の作業時間を比べることで，手法の良さを評価した．結果，一部のカテゴリにおいてはラベル付けの省力化の可能性が見込める結果となった．それ以外のカテゴリにおいても，推論に使うクラス分類器を改善することによって省力化が見込めるのではないかと考察した．

参考文献

[Burke 11] Burke, L. E., Wang, J., and Sevick, M. A.: Self-monitoring in weight loss: a systematic review of the literature, *Journal of the American Dietetic Association*, Vol. 111, No. 1, pp. 92–102 (2011)

[Deng 09] Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., and Fei-Fei, L.: Imagenet: A large-scale hierarchical image database, in *Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on*, pp. 248–255Ieee (2009)

[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*, pp. 770–778 (2016)

[Sun 17] Sun, C., Shrivastava, A., Singh, S., and Gupta, A.: Revisiting unreasonable effectiveness of data in deep learning era, in *Computer Vision (ICCV), 2017 IEEE International Conference on*, pp. 843–852IEEE (2017)

[厚生 00] 厚生省：健康日本 21. 21 世紀における国民健康づくり運動について, 健康日本 21 計画策定検討会報告書 (2000)

[厚生 15] 厚生労働省（編）：生活習慣病予防その他の健康増進を目的として提供する食事の普及に係る実施の手引, 第 1 章, 厚生労働省 (2015)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

機械学習による天気予報の当たり外れ予測の可能性

How can we predict the accuracy of weather forecast with machine learning?

船木将秀*
Masahide Funaki

*1 新潟大学創生学部
College of Creative Studies, Niigata University

A better weather forecast (WF) is of public interest. Over the past decades, the precision of WFs has been significantly improved by developments of more advanced forecasting techniques with state-of-the-art numerical models and machine learning. However, validation results of such precision hardly go public, and thus individual WF user tends to evaluate the accuracy of every WF through his 'rules of thumb'. Predictive values of a forecast inevitably vary with changes in temporal-spatial dynamics of the atmosphere which is simulated by a set of numerical models that have both strength and weakness in their performances. Largely using web-scraping, we examine the causality of simulated atmospheric dynamics (inputs) and predictive values (outputs) through deep learning, in order to evaluate the accuracy of WFs in a daily basis. It is anticipated that our evaluation results will allow users to choose better forecasting systems.

1. はじめに

天気予報は，複雑な気象系の解析・予測の結果であり，それは社会活動に大きな影響を及ぼすものである．したがって，予報精度向上のために，気象庁や民間の予報業務許可事業者を中心に，日々様々な取り組みがなされている．例えば，観測データの量的・質的向上や解析手法・計算能力の高度化に伴って，気象庁の数値予報は，1959 年のコンピュータ導入以降，年々予報精度は向上している[気象庁 2018].

また，近年では，機械学習による気象予測をする研究[気象研究所予報研究部 2000][吉兼 2018]もなされている．実際の予報業務においても，機械学習の利用は進められている．気象庁では，予報ガイダンスの導出に機械学習を用いて気温予報精度に努めており[高田 2016]，民間の予報業務許可事業者でも，機械学習の導入により，予報精度が大幅に向上した例が報告されている[ウェザーニュース 2018].

天気予報の精度全体は年々向上している一方で，予報精度が定量的に分析・公表されることは少ない．利用者は利用する予報が実際に当たるかどうかを感覚的にしか理解できないのが現状である.

本研究では，現時点での天気予報の当たり外れを，天気予報の得手不得手という観点から機械学習で予測するシステムの構築に当たり，その可能性について議論する.

2. 天気予報の適中精度

2.1 予報における誤差

予報精度が年々向上しているとはいえ，大気の状態を完全には表現できない以上，予報には常に誤差が含まれる．この誤差は，予報モデルと現実との差異によって生じるものである．気象庁の天気予報を例に挙げると，数値予報で大気の状態をシミュレートするときと，天気予報で数値予報を解釈するときに，それぞれ誤差が発生している.

連絡先：船木将秀，新潟大学創生学部，新潟市西区五十嵐 2 の町 8050 番地，x18c064j@mail.cc.niigata-u.ac.jp

(1) 数値予報

数値予報では，大気の支配方程式を積分することで未来の大気の状態を予測する．この際に用いる計算モデルは，気象機関や予報内容によって解像度や計算処理内容が異なっている．モデルの違いは予報内容に影響を与え，例えば熱帯低気圧の進路予報では，それぞれが異なった予報を出している[Yamaguchi *et al.* 2017].

数値予報の誤差が出る要因は3つに集約される．1点目は計算モデルの入力値に観測誤差が含まれることである．2点目は数値予報の初期値は，客観解析などの近似計算による誤差が含まれるということである．現実的にこれら2点の根本的な解決は不可能であり，数値予報モデルが完全に大気の状態をシミュレートできないということである．3点目は，初期値の誤差が時間の経過とともに拡大することである．一般に，大気の支配方程式は非線形であり，数値予報の結果はカオス理論的な振る舞いを示すことが知られている[Lorenz 1963].

それぞれのモデルの違いは，いわばモデルごとの得手不得手であり，モデルの癖とでも言うべきものである．2004 年～2014 年における全球での熱帯低気圧の 3 日後の進路予測と実際の中心位置との誤差について，各気象機関で大きな差が出ている(図 1)．

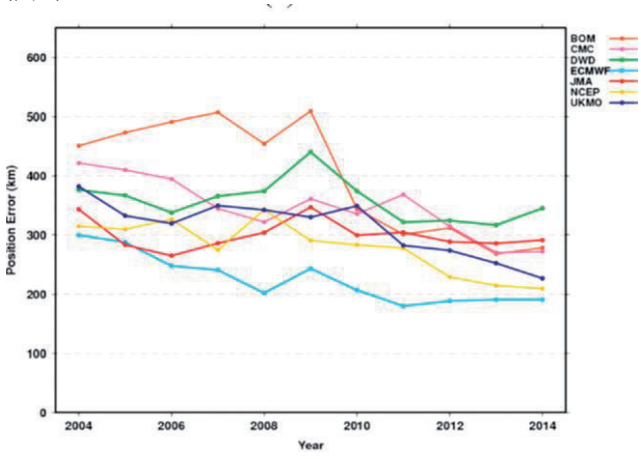


図 1 熱帯低気圧 3 日後予測進路と実際の中心位置

との誤差（出典：[Yamaguchi *et al.* 2017]）

(2)　予報ガイダンス

予報ガイダンスは，数値予報の結果（大気の状態）を翻訳・修正して得られる予測資料である．数値予報の翻訳・修正の過程では，数値予報での予測値を補正し誤差を軽減したり，天気や発雷確率などの数値予報で出力しない情報を作成したりする．

予報ガイダンスでは，統計的な手法を用いて，数値予報の誤差や数値予報にない予報データを導出する．気象庁では，線形重回帰のロジスティック回帰ほか，ニューラルネットやカルマンフィルターなどの機械学習の導入も行われている．

(3)　天気予報

天気予報は，数値予報や予報ガイダンスなどの予測資料と，気象衛星や AMeDAS などの観測資料をもとに，予報官や気象予報士が作成している．この過程で，それぞれの担当者の経験や知識といったものが加味されている．また，ウェザーリポート[ウェザーニュース　2018]のように，追加で独自のデータを加味することもある．発表予報を作成する過程では，担当者の経験や知識に予報精度が左右される側面がある．

また，それだけではなく，予報範囲の問題もある．気象庁は 2019 年 1 月現在 142 の予報区で予報を行っている．一方で，日本気象協会では，市区町村別の予報を発表している．この二者を比較したとき，前者のほうが予報する区域が広く，予報区内で天気にばらつきがあるような，不安定な大気の状態であれば，必然的に前者のほうが的中率は低くなる．

2.2　予報精度の現況

予報精度について，気象庁では月ごとに前月の各予報区・地方ごとに，天気予報の予報精度の検証結果を公表している[気象庁　2019]．この検証では，気象庁 5 時・17 時発表の天気予報の，降水の有無，最高・最低気温の予報データと観測データとを比較し，1 ヶ月単位で集計している．この検証データによれば，長期的な精度の向上はあるものの，地域や季節によって予報精度にばらつきがある（図 2）．

前述のように，冬（12 月～2 月）の北海道の降水の有無の予報精度は全国平均と比較して低い．また，全国的に夏（7 月～8 月）の降水の有無の予報精度も低くなる傾向がある．このような天気予報には季節性や地域性を帯びた予報精度のばらつきは，前述の 2 つの誤差に起因するものである．つまり，予報の難易度は，大気の状態のシミュレーションの難易度に依存し，それは，予報精度の地域性や季節性と言ったパターンで表面化している．

ところが，この季節性や地域性は，あくまで平均的な傾向であり，気象状況によって，予報の難易度が変化することもある．2018 年と平年値（1992 年～2017 年の平均）を比較すると，2018 年の降水の有無の適中率は，差分が 0～3%程度が続くなど，概ね平年値と同様に推移しているが，多くの地域が高気圧に覆われ大気の状態が安定していた期間が長かった 3 月，7 月の適中率は平年値より 9%程度高かった（図 3）．

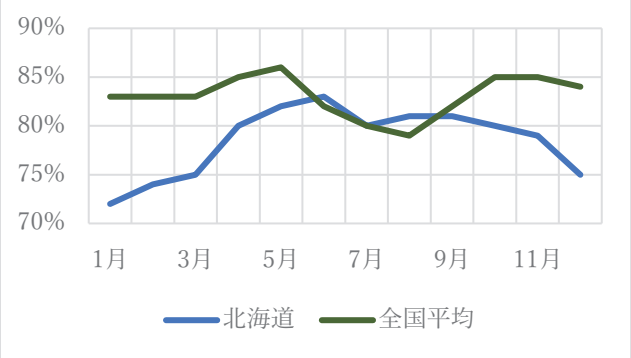


図 2　気象庁翌日予報（１７時発表）の降水の有無の適中率・平年値（1992～2017 年の平均値）

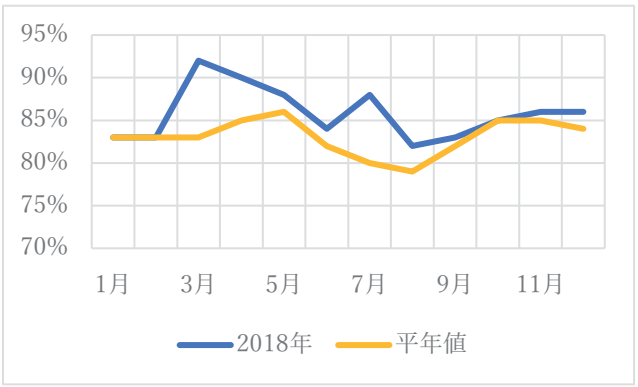


図 3　気象庁翌日予報（17 時発表）の降水の有無の適中率の平年値（1992 年～2017 年）と 2018 年との比較

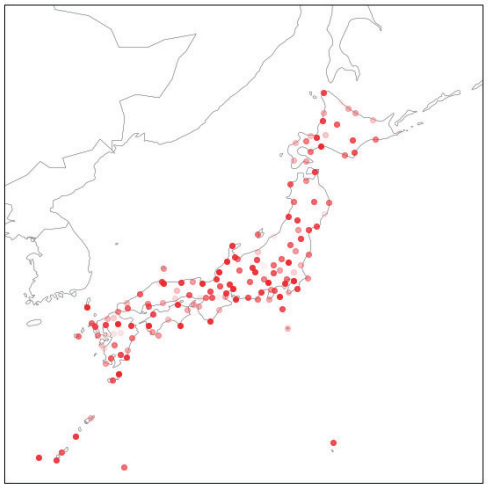


図 4　各観測地点での適中率（イメージ）

3.　機械学習による天気予報の当たり外れ予測

天気予報の当たり外れは，従来，感覚的な経験則や気象庁の予報検証のような統計分析によるものであった．しかし，天気予報の予報精度には規則性があるとはいえ，その要因は複雑

であり，現時点での予報が，当たるか外れるかは予測することが困難であった．しかし，深層学習を利用することで，人間に認識できないパターンを発見することが期待される．

3.1 機械学習での当たり外れ予測の概要

本システムでは，各予報時点での気象状態（数値予報の初期値）と予報地点・時刻ごとの天気予報を入力とし，その予報の当たり外れを出力とすることを想定している．過去の予報の当たり外れに関しては，予報の内容と当該時点の AMeDAS などの気象観測網でのデータとの比較を行うが，twitter での天気に関するツイートを収集し，地点情報と紐づけて天気の実況データとして扱うことを構想している．これは，AMeDAS の間隔が降水で約 17km 間隔，気温や風で約 21km 間隔であることや，全天の 8 割が雲で覆われていても晴れである場合のように，観測値と体感の違いがあると考えられるため，より一般利用者の感覚に合った予報適中予測をするためである．

これを，予報者（気象機関・予報許可事業者など）ごとに学習することで，大気の状態や予報内容と，予報適中率との規則性をニューラルネットワークが獲得する．

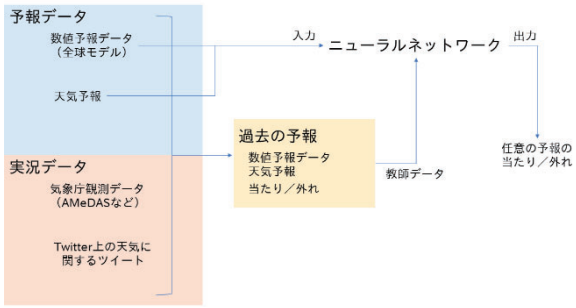


図 5　天気予報の当たり外れ予測システムの構想図

3.2 機械学習での当たり外れ予測の課題点

機械学習の実装において，重要となってくるのは，学習するデータの量・質を必要十分に設定することである．気象のような複雑でカオス性を持つものは特に，適切な種類で十分な量のデータを吟味して，収集することが必要である．しかし，過去の予報データは，それ自体には何ら価値はなく，振り返って収集することが困難である．したがって，天気予報の当たり外れを予測するにあたっては，十分な量の予報データを集められるかが課題となる．

3.3 当たり外れ予測への期待

2019 年 1 月現在，日本には，気象・波浪の予報業務許可事業者が 74 者存在し，そのすべてが天気予報の業務を行うことができる．また今後，解析精度や計算能力の向上，機械学習の利用等で，更に天気予報の質・量ともに増大することが見込まれる．こうした中で，各種天気予報の当たり外れを予測ができれば，利用者が目的に応じて，最も可能性の高い予報を利用することができることが期待される．これは，今まで感覚的に行われてきたことであるが，定量化することで，広く一般に，より正確な予報を得られる様になると考えられる．また，機械学習で一定以上の品質が担保できれば，機械学習による逐次的な予測をすることで，統計分析による予報精度の定量的比較より現時点での予報の当たり外れに即した評価ができるだろうと期待される．

謝辞

本研究に取り組むに際しまして、予報データの分析や研究資料の検索に協力してくださった、新潟大学創生学部・峰川拓人さん、齋藤 季さんによって、本稿は完成することができました。ありがとうございました。

参考文献

[Lin et al. 2018] Lin, S.-Y., Chiang, C.-C., Lic, J.-B., Hunga, Z.-S., Chao, K.-M.: Dynamic fine-tuning stacked auto-encoder neural network for weather forecast, Future Generation Computer Systems Volume 89, 446-454, The International Journal of eScience, 2018.

[Lorenz 1963] Lorenz, E.N.: Deterministic Nonperiodic Flow, Journal of the Atmospheric Sciences Vol.20, 130-141, AMS, 1963.

[Yamaguchi et al. 2017] Yamaguchi, M., Ishida, J., Sato, H., Nakagawa, M.: WGNE Intercomparison of Tropical Cyclone Forecasts by Operational NWP Models: A Quarter Century and Beyond, Bulletin of the American Meteorological Society 98, AMS, 2017.

[気象研究所予報研究部 2000] 気象研究所予報研究部: 帰納的機械学習手法の天気予報への応用，気象研究所技術報告 第 39 号, 2000.

[気象庁 2018] 気象庁: 数値予報の精度向上，2018，https://www.jma.go.jp/jma/kishou/know/whitep/1-3-9.html .

[気象庁 2019] 気象庁: 天気予報の検証結果（平成 30 年の年集計），2019，https://www.data.jma.go.jp/fcd/yoho/data/kensho/HPdata2018/zc_2018.html.

[国次 1997] 国次雅司: カルマンフィルターを用いた天気予報ガイダンス, 天気 44(6), 413-417, 日本気象学会, 1997.

[松村 2006] 松村崇行: 天気予報ができるまで, 細氷 52 号, 日本気象学会北海道支部, 2006.

[三隅 2014] 三隅良平:気象災害を科学する，ベレ出版，2014.

[饒村 2002] 饒村曜: 気象災害の予測と対策，オーム社，2002.

[小倉 2015] 小倉義光:日本の天気 その多様性とメカニズム，東京大学出版会，2015.

[小倉 2016] 小倉義光: 一般気象学，東京大学出版会 ,2016.

[高田 2016] 高田伸一: 気象庁における機械学習の利用，先端 IT 活用推進コンソーシアム，2016，http://aitc.jp/events/20160916-Seika/20160916_特別講演_気象庁における機械学習の利用.pdf.

[ウェザーニュース 2018] ウェザーニュース:目指せ精度 99.9%，ウェザーニュースの予報がわずか 1 年で大幅に改善した前代未聞のプロジェクト，2018，https://weathernews.jp/s/topics/201703/220235/.

[山下 2018] 山下隆義: イラストで学ぶ ディープラーニング，講談社サイエンティフィク，2018.

[吉兼 2018] 吉兼隆生，芳村圭: 機械学習による局地気象予測の試み，人工知能学会全国大会論文集 第 32 回全国大会，人工知能学会，2018，https://www.jstage.jst.go.jp/article/pjsai/JSAI2018/0/JSAI2018_4Pin134/_pdf/-char/ja.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

調理作業スペースの概念モデルの可視化の検討

Visualization of conceptual model of cooking workspace

濱 龍太郎 *1 Ryutaro Hama　森 梓 *1 Azusa Mori　原田 篤 *1 Atsushi Harada　高久 由香里 *1 Yukari Takaku　橋本 敦史 *2 Atsushi Hashimoto

*1株式会社 LIXIL LIXIL Corporation　*2京都大学教育学研究科 Kyoto University

This paper proposes a method for visualizing and analyzing conceptual models of cooking space in kitchen. We hypothesized that users recognize the space as a set of separated areas to which the users allocate cooking items (tools and foods) along with the concepts in their mind. To model such concepts, we separated cooking areas according to the detected items' location, then characterized these areas by the located items' categories; we use Single shot multibox detector (SSD) for item detection, the EM algorithm with Gaussian Mixture Model (GMM) for dividing the space into areas based on the detected items, and characterize each area with term frequency - inverse document frequency (tf-idf), where we regard each area as a document and items as terms. In conclusion, we visualized their conceptual models of relationships of kitchen items and the areas, and their shape patterns.

1. 緒言

キッチンは住生活において食を支える設備であり，何年にも渡り日々使われる設備であるため，そのユーザビリティは極めて重要である．プロダクトデザインのユーザビリティにおいて，ユーザーの持つ，行為の対象物に対する概念モデルと，その対象のシステムイメージとが一致しないときにユーザビリティが下がると言われている [Norman 13]．キッチン設備においても調理に関するユーザーの概念モデルを把握できれば，概念モデルに則した機能提案や評価ができる可能性がある．

キッチン設備は図 1 の様にシンク，コンロ，作業スペース，収納などの要素からなるが，多くの作業は作業スペースを中心に行われるため，作業スペースの概念モデルを把握することはその他の機能提案にも重要であると考え，本研究では作業スペースに注目した．

作業スペースに対する概念モデルは，作業スペースが基本的には平面からなるため，自由度が高いが，用いる器具や食材の特性，水気や火気，身体からの距離などの影響を受けていると考えられる．これらの影響からユーザーは作業スペースを空間的に分割して捉え，分割したエリアに対して物体を配置しているのではないかという仮説を立てた．

本研究では，食材や調理器具が設備中のどこに配置されていたかは調理の概念モデルに基づいた行動の結果が表れていると考えられることから，食材・調理器具（以下アイテムとする）の種類，作業スペースへの配置に基づいた分析を行うこととした．

本研究では分析データの取得において深層学習による物体検出技術に着目した．キッチンワークトップ全体を天井カメラで撮影し，深層学習の物体検出フレームワーク Single Shot MultiBox Detector (SSD)[Liu 16] でワークトップ上での物体検出を行うことにより，目的とするアイテムの種類ならびに配置座標を推定できる．

この物体検出結果を元に，作業スペースに対するユーザの概念モデルの解析手法を提案し，その可視化結果を示した．

連絡先: 濱 龍太郎，株式会社 LIXIL
Technology Research 本部　人間情報科学研究所
〒 136-8535 東京都江東区大島 2-1-1 LIXIL WING ビル
E-mail: ryutaro.hama@lixil.com

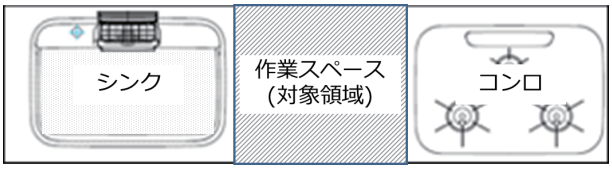


図 1: キッチン定義

2. 問題設定

2.1 数学的記述

本研究において，調理中に登場しうるアイテムを既知として，その集合を O とし，物体検出の出力は検出された物体 $o \in O$，時刻 t, および矩形座標 (x_1, y_1, x_2, y_2) からなる．対象領域とする作業スペースの左手前を原点とした．アイテムの検出座標の代表値を矩形中心 (cog, center of graph) を $cog = (x_1 + x_2)/2 + (y_1 + y_2)/2$．また，ワークトップのエリア分割 S，および各エリア $s \in S$ とし，検出アイテムのエリアに対する滞留時間を $\tau_{o,s}$ とする．

3. 提案手法

本論文では， ユーザーは作業領域を空間的広さや用いるアイテムの特徴に基づいて，大きく分割して認識し，その領域に用途や形状などの特徴に基づいてアイテムを配置していると仮定した．以下の手順で配置とアイテムの関連性や空間の分割のモデルを分析する手法を提案する．まず，調理中のアイテムを物体検出アルゴリズムを用いて検出し，配置されたアイテムを抽出する．次に，空間的な分割の概念モデルを実際のアイテム配置位置に基づいて分析する．さらに，分割されたエリアに配置されたアイテムを特徴としてエリアをクラスタリングし，意味づけを行う．

3.1 食材・調理器具の検出

調理における道具や食材（アイテム）のデータの取得方法として，調理作業を上方より撮影した動画像に対し，フレームごとに物体検出モデルを適用した．この検出には SSD[Liu 16]

を用いた．SSD の畳み込み層には ResNet50 を用いた．対象物が画像領域に対して微小なため，検出精度の高い SSD-512 を用いた．

3.2 移動・滞留判定

アイテムの配置位置を評価するにあたり，検出されたアイテムの移動・滞留を判定し，滞留時のデータを用いることとした．

3.1 で得られた検出アイテムに対し，アイテムの cog のフレーム間移動距離を求め，移動平均によって平滑化を行なった．この移動距離の平均・偏差を求め，移動距離が平均+標準偏差の範囲内を滞留・それ以上を移動と判定することとした．平滑化は検出領域の変動による物体の中心位置の移動の影響をなくすためである．

3.3 滞留領域のエリア分割

ユーザーは自身の空間や物体の概念モデルに基づいて，空間を大まかにエリアに分割してアイテムを配置するものとすると，アイテムはユーザーの概念モデルに合致するときに長期的に配置位置に滞留し，合致しないとき又は一時置きの概念モデルのときには短期的な滞留となると考えられる．このとき配置は，滞留時間を重みとした確率密度が正規分布に近似できると仮定して，EM アルゴリズムを用いた GMM (Gaussian Mixture Model) へのフィッティングを行い，その分布を抽出することとした．この際，前後左右それぞれに 3 分割程度のエリアを想定し，10 を最大分割数として BIC 基準でエリア数を決定することとした．

3.4 エリアの内包アイテムによる意味付け

3.3 にて分割したエリアがユーザーの空間に対する分割意図を反映しているのか，その意図は何か，をエリアの座標情報だけでなく，内包するアイテムにより意味付けすることで評価したい．本研究ではアイテムによるエリアの意味づけにおいて，term frequency - inverse document frequency (tf-idf) を用いたベクトル空間モデルを適用し，余弦類似度でエリア同士の類似度を表現した [奥野 16].

tf-idf の適用にあたり，エリアに対するアイテムの出現頻度を tf, あるアイテムの存在するエリアの頻度を idf とする．式 1 に計算過程を示す．エリアの特徴をアイテムの出現頻度あるエリア s に対するあるアイテム o の tf の計算において，被験者の違いによる調理時間差や用いたアイテム数の差による影響を少なくするために，アイテム i の滞留時間 $\tau_{o,s}$ を全アイテムの滞留時間 $\sum_k \tau_{k,s}$ で正規化した．ここで，滞留時間は短いもので数秒，長いもので数十分と差が大きいため，tf を対数で正規化した．この際に，tf が負の値を取らない様に 1 を加算した．

また，アイテム o の出現するエリアの数 df_o を，全エリア数を N で除した値を idf とした．

$$tf - idf(o,s) = \log\left(\frac{\tau_{o,s}}{\sum_{o'} \tau_{o',s}} + 1\right) \cdot \frac{\log N}{df_o} \quad (1)$$

この余弦類似度を元に Ward 法で階層的クラスタリングを行い，各クラスタにおけるアイテムの特徴量を元にエリアの意味づけを行う．

4. 実験

4.1 実験条件

4.1.1 実験環境

モニター調査は弊社施設内の実験環境にて行った．実験環境全体図を 2 に示す．LIXIL 製システムキッチン RICHEL SI(幅:2585 mm, 奥行:650 mm, 左勝手; 左手にシンク) を使用した．また，それぞれの横幅はシンク幅 770 mm，作業スペース 750 mm, コンロ (LIXIL 製ひろまるコンロ) 815 mm である．カウンタータイプのキッチンであるが，壁付けタイプを想定して奥行き 650 mm 地点に境界を設けてその手前にて作業を行うこととした．撮影は天井設置カメラ (Panasonic 製 AG-HMR10A) を使用し，29.97 fps で撮影後，1920 × 1080 pixel で保存した．

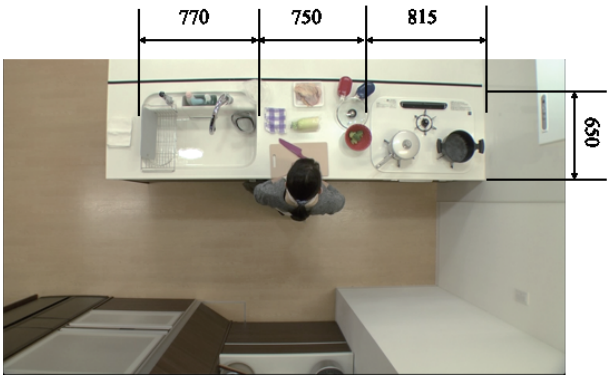


図 2: 対象としたキッチン

4.1.2 調理モニター

実験参加者は一般，社員含めて 20 ～ 60 代の男女 24 名を対象とした．調理メニューは調理の基本動作のうち「切る，和える，味付け，焼く，茹でる，盛り付け」を含むように設計し，ご飯（2 合・電気炊飯器使用)，照り焼きチキン（鶏もも肉 2 枚)，添え野菜（カットトマト，茹でブロッコリー)，味噌汁（大根，しめじ，長ネギ)，きゅうりの酢の物（きゅうり，シラス）とした．食器および食材は 2 名分とした．実験条件の統一のため，調理メニューは事前に告知し，用意した道具の位置や機器の使い方以外の調理作業の動作教示は行わず，それぞれの手順にて調理を行った．

4.2 深層学習による物体検出

4.2.1 データセット

先述の被験者のうち，16 名の動画を 0.5 fps でフレーム化し，33,045 枚の画像を切り出し，出現した 89 種類のアイテム全てにアノテーションをおこなったものをデータセットとした．

4.2.2 SSD の学習・検出

SSD512 に ResNet50 の事前学習済みのモデルを適用し学習を行った．学習用・検出用の画像は全て 512 × 512 pixel に縮小して処理を行った．PASCAL VOC 基準で評価を行うと mAP (mean Average Precision) が 0.62 と算出された．アイテムの検出精度において，出現回数が少ないもの (フォークなど)，形状が大きく変化するもの (食材や料理など) に関しては検出精度が下がってしまっていた．その検出結果の例を図 3 に示す．

本研究では分析対象を配置に関わる調理器具および加工前の食材の 61 種類とした．これにより形状変化の大きい加工された料理を除外した．また，出現回数が少ないものは影響が限定的であると考え，そのまま扱うこととした．データの拡充と変化する物体の検出は今後の課題である．

4.3 エリア分割

手法 3.3 に基づき分割された領域数を BIC 基準で選定するとそれぞれ 8~10 であった．EM アルゴリズムによる GMM

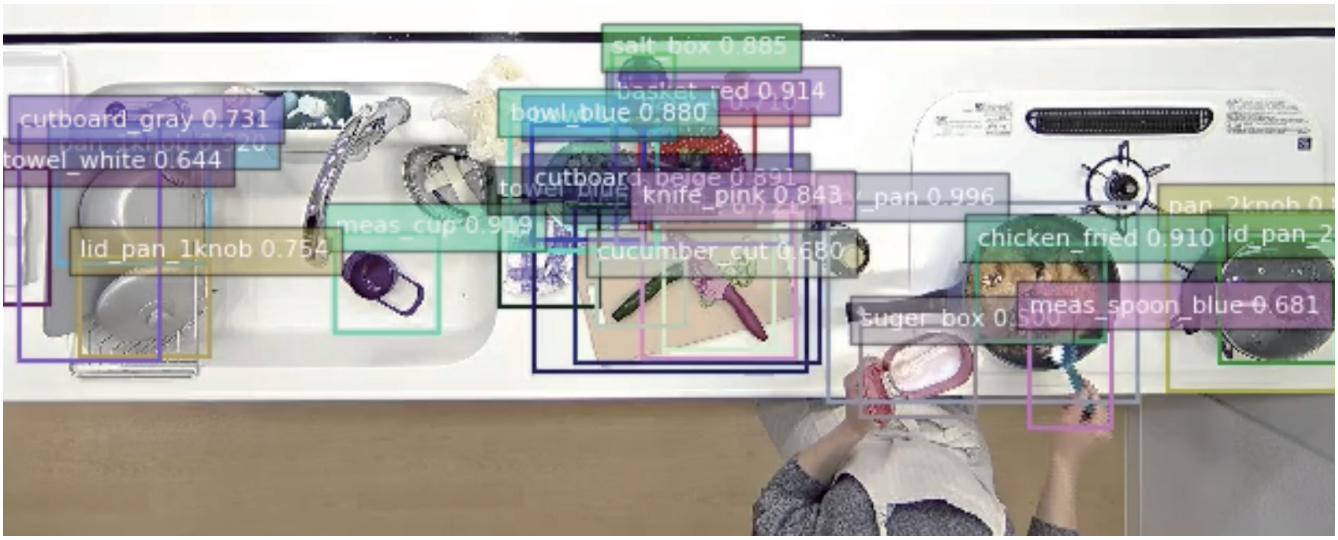
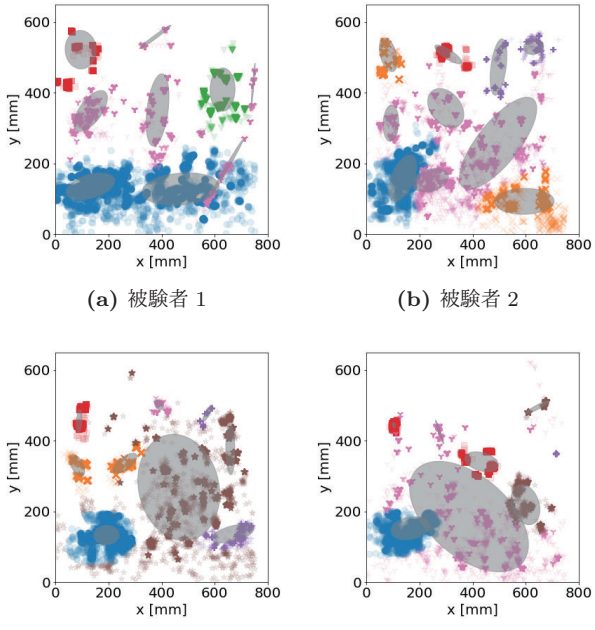


図 3: 深層学習 (SSD) による調理器具および食材の物体検出例

へのフィッティングは scikit-learn v0.19.2 におけるモデルを用いた [Pedregosa 11]．図 4 にその結果の一部を示す．灰色の楕円部は GMM で分割された各エリアの平均と分散からなる領域である．色および記号は 4.4 にて記述する．図 4(a),(b) では空間の前後，左右に分割されたエリアが形成されたが，図 4(c),(d) では広域のエリアと複数の細かいエリアが形成された．



(a) 被験者 1　　**(b)** 被験者 2

(c) 被験者 3　　**(d)** 被験者 4

図 4: アイテムの配置に基づくエリア分け

また，図 5 に示すように全被験者の BIC を比較すると，オーダーが同一であったため，およそ同程度の基準で分割できていた．

以上より，被験者の作業スペースのエリア分割の概念モデルを明確なエリア分割があるタイプと，エリア分割が曖昧なタイプとで表現することができたと考えられる．

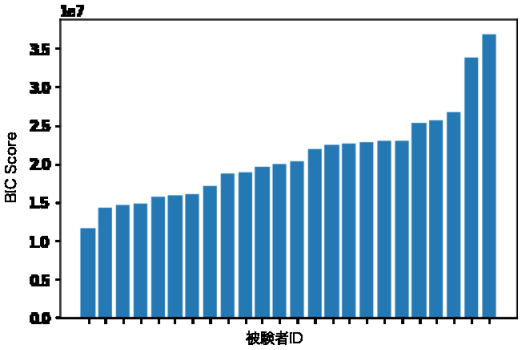


図 5: 被験者間の BIC 比較

4.4　エリアの意味づけ

前述 4.3 により得られたエリア $s \in S$ に対し，3.4 により類似したエリアを集約した．クラスタ内の tf-idf の平均値と内容を元に 7 クラスタに決定した．分類のデンドログラムを図 6 に示す．このクラスタごとの tf-idf の値が高いアイテムを表 1 に示す．図 4 の色および記号が，アイテムの配置と種類を反映した例である．この凡例を表 1 中に示した．

同様にエリアに対し特徴的なアイテムを表 1 の 1~6 に示す．また，お玉や計量カップなどの道具類，醤油やみりんなどのボトル調味料は作業スペース上のエリアに固定される傾向が薄いアイテムであることがわかった．

この 24 名の作業スペースのエリア分割と，その主要アイテムから以下の結果が得られた．

もっとも特徴として強く出たまな板・包丁からなるエリアは，図 4(a) のように左右に分布している群 9 名と，図 4(b)~(d) に示すようにシンク寄りの手前側に配置される群 15 名とに分けることができた．

5.　考察

クラスター配置と種類，実際の動画観察を元に概念モデルの形状を図 7 のように表現した．図 7(b)~(d) のうち，図 7(a),(b) は奥行き方向で分割し，長時間置く物を奥に置いていた．両被験者の違いとしてカット位置を固定しているかがあったが，被

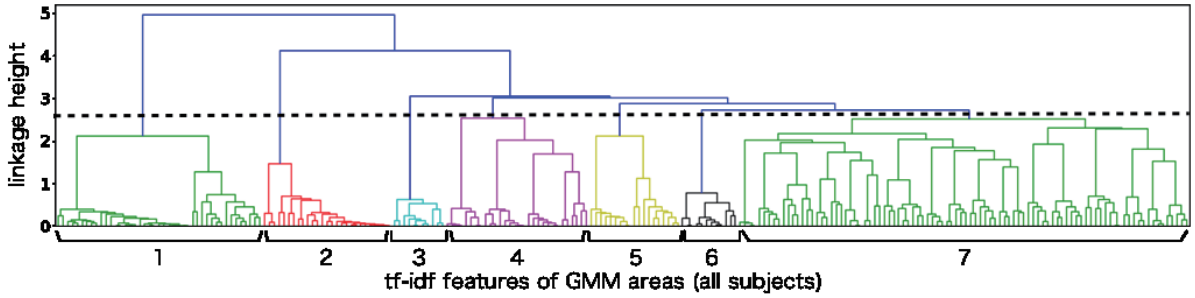


図 6: アイテムを特徴量としたエリアのクラスタリング

表 1: エリアの意味付け.

clusterNo	主要アイテム	凡例
1	まな板・包丁	●
2	台拭き	×
3	塩・砂糖	▼
4	ボール・ザル	■
5	鍋蓋類	+
6	大皿	★
7	その他（食材・器具）	Y

験者 2 においてはカット以外の作業を立ち位置を変えて行なっていた．(c) は左右で分割され，右側全体を盛り付けを含むフリーエリアとして利用していた．また，(d) ではカット以外の作業も作業位置を固定し，極座標系の手の届く距離で配置を行なう傾向が見られた．

このように，作業スペースの空間認識において，奥行き方向，左右方向だけでなく，極座標系の概念モデルを主要な形状として抽出することができた．

このような方法でタイプを分類すると，全被験者においては奥行き方向の意識が強い前後分割タイプの被験者が 11 名，左右分割意識が強い左右分割タイプの被験者が 4 名，極座標系タイプの被験者が 9 名であった．

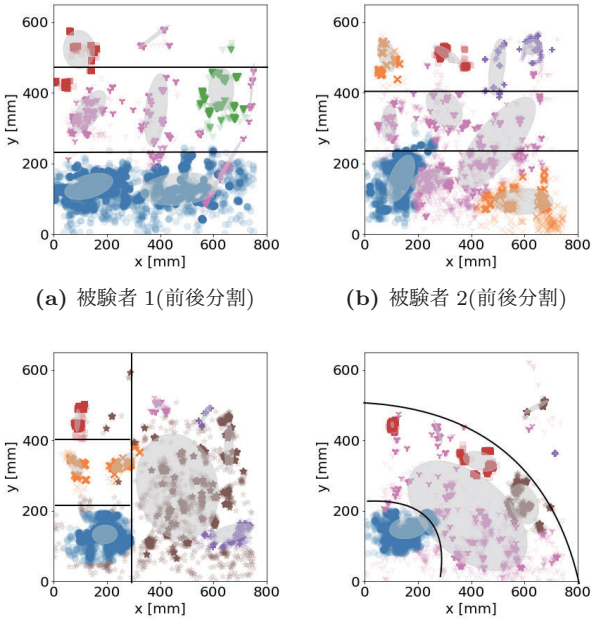
また，多くの被験者において単独のモデルでなく左右や奥行き，極座標などのモデルを組み合わせることで作業スペースを認識していたと考えられる．

6. まとめ

本研究では物体検出データを用いた調理行動における作業スペースのエリア分割とその意味づけによる概念モデルの可視化の手法を提案した．実際に被験者の調理モニターを行い，作業や設備と配置アイテムの関連性を評価することで，ユーザーのキッチンスペースに対する概念モデルとして，物体配置において特徴的なアイテムと配置の形状パターンを得ることができた．この形状パターンはユーザーによって異なっていたため，個人の性格や調理に対する意識，経験が影響を与えていると考えられる．

今後の課題として，形状パターンの分類が定性的な評価を含むため，定量的な評価指標の検討を行いたい．また作業スペースに対するコンロやシンクの配置変化や調理のメニューや器具変化により，配置の傾向がどのように変化するのか，その要因は何かを分析すること，調理中の時系列変化を捉えることが挙げられる．

さらに，この調理行動のパターンを分析することでユーザビリティの高いキッチン設備の提案につなげていきたい．



(a) 被験者 1(前後分割)　(b) 被験者 2(前後分割)

(c) 被験者 3(左右分割)　(d) 被験者 4(極座標系)

図 7: 作業スペースの意味区分

参考文献

[Norman 13] Norman,D.A.: The design of everyday things ?Revised and Expanded edition, New York:Basic Books(2013)(邦訳 :岡本 明ら, 新曜社 (2015))

[Liu 16] Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C., and Berg, A.: SSD: Single shot multi-box detector, *European conference on computer vision*, pp. 21?37, Springer (2016)

[Pedregosa 11] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Pret- tenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M. and Duchesnay, E.: Scikit-learn: Machine Learning in Python, *Journal of Machine Learning Research*, Vol. 12, pp. 2825?2830 (2011)

[奥野 16] 自然言語処理の基本と技術 (仕組みが見えるゼロからわかる)・奥野 陽ら，翔泳社 (2016)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

物体検出を用いた調理の時系列パターンによる分類

Clustering time-series data of cooking using object detection

森 梓[*1] Azusa Mori　濱 龍太郎[*1] Ryutaro Hama　原田 篤[*1] Atsushi Harada　高久 由香里[*1] Yukari Takaku　橋本 敦史[*2] Atsushi Hashimoto

[*1] 株式会社 LIXIL LIXIL Corporation　[*2] 京都大学教育学研究科 Kyoto University

This paper presents an appliance of object detection with deep learning for a series of cooking video frames and an analysis of these time-series detection data. Our final goal is offering personalized kitchens. We have observed and analyzed cooking behaviors with visual observation and spread sheet software. However this conventional method was too tough to perform with sufficient precision and subject numbers. Furthermore, it was difficult to analyze from various viewpoints. So, we introduced object detection with deep learning as a tool for automation of the method. We applied object detection for a series of cooking video frames which contains about 90 objects, extracted these data and analyzed with Python, and found that the time-series data counting number of detected objects clustered 3 patterns in sink area. This discovery contributes to understanding of cooking patterns which leads to offering personalized kitchens.

1. はじめに

キッチンは毎日、何回も、長年にわたって使い続けるため、使いやすさが重要である。これまで弊社では行動観察やアンケート、インタビュー等の調査手法を用いて、ユーザーの潜在的な困りごとを発見し、新しいキッチンの提案につなげてきた[村上 2010]。

これらの調査手法の中でも行動観察※[松波 2013]は、得られる情報が多い反面、工数が膨大にかかる点が難点であった。一般的な主菜、副菜、汁物、ご飯から構成されるメニューの調理には約 1 時間かかる。この 1 時間の調理行動をキッチンの天井に取り付けたカメラで撮影し、動作単位に分解する。動作はのべ約 1000 回含まれ、そこに時間(秒)、座標(ブロック単位)、調理アイテムの種類(調理道具・食材約 150 種類)、調理アイテムの状態、設備(水栓、コンロ、収納等)へのアクセス、キッチンスペースの使われ方等の情報を付随させる。このような分析を目視観察と Excel をベースにした従来のスタイルで行う場合、1 件あたり約 3 か月かかった。工数的にも分析者のモチベーション的にも限界があり、他にも、一定の品質での精密なデータが取得できない、母数を増やせない、集計分析にとどまる等の問題があった。然して、分析視点も限定的にならざるを得なかった。

そこで私たちは調理アイテムを自動検出させることを考え、深層学習による物体検出技術を採用した。理由は 2 つある。ひとつは、特定のレシピに応じた学習サンプルさえ用意すれば食材の色や形の変化、分裂や結合にも対応可能であること、もうひとつは、将来的に実験用キッチン以外でのデータ取得の可能性を配慮し、カメラひとつで対応可能であることである。この技術を用いることにより一定の品質かつ精密なデータで母数を多く取得できれば、集計分析だけでなく統計分析、さらには機械学習による分析も可能となる。そうすることで分析・発見の切り口を増やし、より使いやすいキッチンを一人一人にフィットした形で提案を行っていきたいと考えている。

今回はファーストステップとして、調理動画に深層学習による物体検出技術を適用し、そこから得られたデータをもとに、キッチン上に出現する調理アイテム数の時系列変化について分析した結果を報告する。

連絡先:森 梓, 株式会社 LIXIL, Technology Research 本部 人間情報科学研究所, 〒136-8535 東京都江東区大島 2-1-1 LIXIL WING ビル, azusa.mori@lixil.com

※ここでは狭義の行動観察、すなわち行動観察調査における発見フェーズをさすものとする。本来、行動観察調査という言葉は、①発見する(事実の収集)、②再構築する(気付きと考察)、③着想を得る(解釈からの発想)、④想像する(経験のデザイン)の全体をさす[松波 2013]。

2. 目的

キッチンのパーソナライズ提案につなげるために、調理動画に深層学習による物体検出技術を適用して、より一定の品質かつ精密なデータで母数を多く取得する。これにより分析・発見の切り口を増やして、調理のユーザー特性を把握する。

3. 目標

本報告では、キッチンにおける調理のユーザー特性として、調理アイテム検出数の時系列変化を取り上げる。24 名の調理動画に深層学習による物体検出技術を適用して、89 種類の調理アイテム(食材・調味料・調理道具・食器)、時刻、座標のデータを取得する。ここからエリア別に調理道具・食器のデータを抽出し、調理アイテム検出数の時系列変化に基づく分類を行う。分類した結果はもとの調理動画ならびにアンケート・インタビューと照合し、定性的な妥当性を確認する。最後に、各分類に対して提案されるキッチンのイメージを取り上げる。

4. 実験

4.1 実験条件

4.1.1 環境

調理モニター調査は弊社施設内の実験環境にて行った。実験環境全体図を図 1 に示す。LIXIL 製キッチン RICHEL SI (幅:2585 mm、奥行:970 mm(650 mm)、左勝手;左手にシンク)を使用した。シンク横スペース、水切りカゴ、シンク、作業スペース、コンロの横幅は、それぞれ 250 mm、230 mm、540 mm、750 mm、815 mm である。なお、本キッチンはカウンタータイプであるが、より一般的な壁付けタイプを想定して奥行 650 mm 以上のエリアは使用しないこととした。

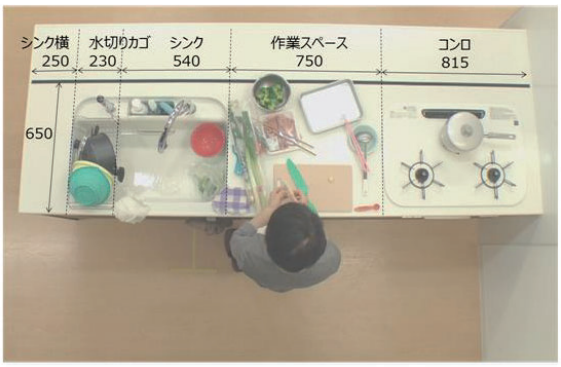


図1．実験環境全体図

撮影は天井に設置したカメラ(Panasonic 製 AG-HMR10A)を用いて 29.97 fps で行い、1920×1080 pixel で保存した。

4.1.2 調理モニター(動画の取得)

被験者は、一般、社員含めて 20 代～60 代の男女 24 名とした。調理メニューは、調理の基本動作のうち「切る、和える、味付け、約、ゆでる、盛り付け」を含むように設計し、照り焼きチキン(鶏もも肉 2 枚)、添え野菜(ゆでブロッコリー、カットトマト)、酢の物(きゅうり、しらす)、味噌汁(大根、しめじ、ねぎ)、ごはん(2 合;電気炊飯器使用)とした。食材 2 名分とその他の調理アイテム(調味料・調理器具・食器)はあらかじめ用意した。調理メニューは被験者に事前告知し、用意した調理アイテムの収納場所や機器の使い方以外の調理作業・動作の教示は行わず、被験者それぞれの手順で調理させた。なお、調理された料理は被験者と実験者で摂食し、あわせて 10 項目のアンケートとインタビューも実施した。アンケート内容は自宅キッチンでの調理に関するもので 5 段階評価とした。

4.2 予備調査

調理におけるユーザー特性を把握するために、本報告では調理アイテム検出数の時系列変化に着目する。以下の本調査に先立ち、上記 24 名外の 2 名の調理動画について、Excel を用いて 5 秒単位で分解し、調理アイテム検出数の時系列変化に明確な差異があることを確認した(図 2)。この予備調査により、調理アイテムの出し入れや洗いのタイミングに差があることが示唆された。

4.3 深層学習による物体検出

4.3.1 データセット

被験者 24 名中 16 名の調理動画から 0.5fps でフレームを抜き出し、33,405 枚の画像とし、出現した調理アイテム(食材・調味料・調理器具・食器)89 種類すべてにアノテーションしたものをデータセットとした。

4.3.2 SSD の学習・検出

SSD512 に ResNet50 の事前学習済みのモデルを適用し学習を行った[Liu 2016]。学習・検出用の画像は全て 512×512 pixel に縮小して処理を行った。PASCAL VOC 基準で評価を行うと mAP (mean Average Precision)は 0.62 であった。調理アイテムの中で出現回数が少なかったり、形状が大きく変化したりする食材や調味料の検出精度が低かった。このモデルに 24 名の調理動画を供した。検出精度については今後の課題としたい。

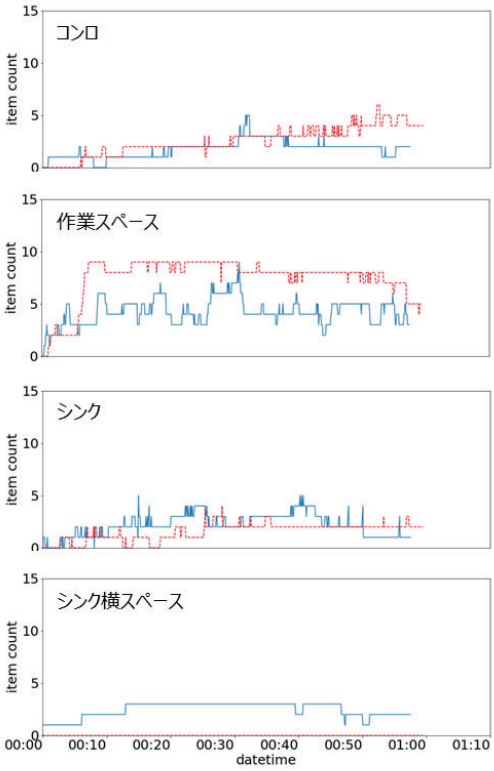


図２．調理アイテム数の時系列変化（目視・手動記録；n=2；— 被験者A, --- 被験者B）

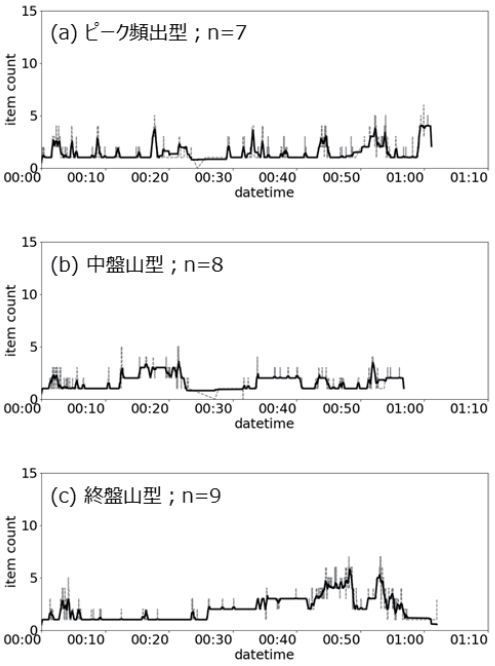


図3．シンクエリアにおける調理アイテム検出数の時系列変化のパターン分類（機械学習による物体検出ならびに目視分類；n=24；--- 原系列，— 移動平均（n=60））

4.4 データ抽出

上記により取得した調理アイテム、時刻、座標の 3 つのデータから、キッチン全体、シンク横スペース、水切りカゴ、シンク、作業スペース、コンロの 6 エリアについて、それぞれ調理アイテム検出数の時系列変化を抽出した。本報告では、検出精度の低い食材・調味料は検出数に対する影響が大きいため除去し、調理道具・食器の検出数をカウントした。なお、抽出にあたっては、解析環境の制約により、1/10 にダウンサンプリング処理を施した。

4.5 調理アイテム検出数の時系列変化

4.5.1 各エリアにおけるユーザー特性

6 エリアでの調理アイテム検出数の時系列変化について、目視分類を行った。この際、判別のしやすさのために、移動平均（n = 60）に変換した。

本報告では、予備調査で示唆された洗いのタイミングに関係のあるシンクエリアに着目することとした。他のエリアの分類妥当性や、エリア間のユーザー特性の関連性、あるいは分類の自動化（統計処理あるいは機械学習）については今後の課題とする。

4.5.2 シンクエリアにおけるユーザー特性

シンクエリアに着目すると、調理アイテム検出数の時系列変化のパターンは 3 つに大別された。ピーク頻出型、中盤山型、終盤山型の 3 つである。これら 3 つのパターンの代表的な例を図 3 に示した。点線は原系列、実線は移動平均である。

ピーク頻出型では細切れに短時間のピークが現れている。他方、中盤山型や終盤山型では、検出数が増加した状態が一定時間以上継続する “山”が見られる。この山の出現タイミングが調理中盤にあるか（終盤にも現れるパターンを含む）、調理終盤のみにあるかで判別を行った。

なお、ここで出現するピークあるいは山は、後述するように、「洗い」動作のみではないことに注意が必要である。

4.6 考察

4.6.1 妥当性検証（動画照合）

分類の妥当性を検証するために、被験者 24 名中 8 名のデータについて、以下の 3 つの作業を行った。まず、調理アイテム検出数の時系列変化に現れたピークを抽出した。次に、ピーク時刻における動作を、調理動画から目視で手動記録し、動作を「洗う、拭く、出し入れ・移動、注ぐ・流す、左手の映り込み、その他」の 6 種類に区分し、被験者毎に動作種類の割合を算出した。ここで、「左手の映り込み」とは、作業エリアにおいて右手で何らかの動作しているときに、左手に把持した調理アイテムがシンクエリアに映り込んでいる場合を指す。また、「その他」はシンクエリアでの動作が見られない場合を指す。この原因については調査中であるが、検出精度（検出逃しや誤り）の時系列でのばらつきが、ピークとして抽出されている可能性が高い。最後にこれを分類結果と照合した。照合結果を図 4 に示す。

調理工程のリセットにかかわる動作、すなわち「洗う、拭く、出し入れ・移動」の割合を比較すると、ピーク頻出型では平均 56.7%、中盤山型と終盤山型では平均 41.7%となった。この差について有意水準 5%で t 検定を行ったところ、t (6) = 2.83, p = .03 であり、有意であると認められた。ピーク型と山型の 2 種の判定は、調理工程の前進に必須ではないリセット動作の割合の多寡と一致し、妥当であるといえる。

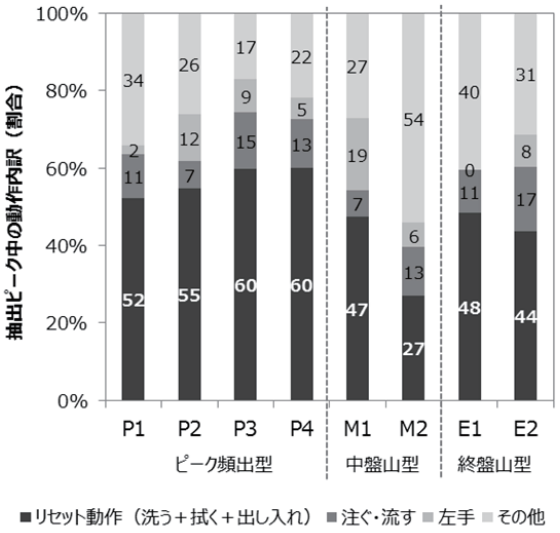


図4．抽出ピーク中の動作内訳と3分類の照合（n=8）

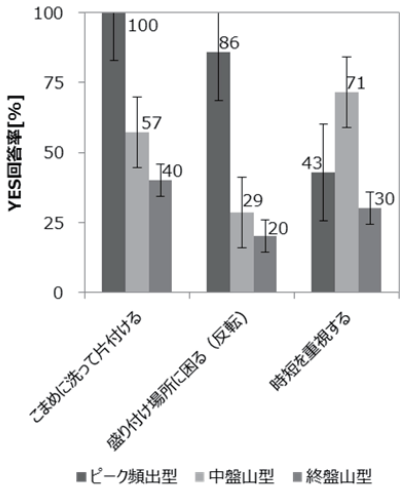


図5．アンケート回答と3分類の照合（n=24）

表1．3つの分類型における調理時間（中央値；n=24）

	ピーク頻出型	中盤山型	終盤山型
調理時間	1:10:47	1:04:41	1:10:40
片付け時間	0:19:05	0:21:58	0:21:51
合計時間	1:27:50	1:25:18	1:31:48
Δ調理時間	0:06:06	0:00:00	0:05:59
Δ片付け時間	- 0:02:53	0:00:00	- 0:00:07
Δ合計時間	0:02:32	0:00:00	0:06:30

ここで、さらに、リセット動作の割合に差が生じる原因を探るために、各分類型のリセット動作自体を比較した。リセット動作のひとつである「まな板洗い」に着目すると、ピーク頻出型では、例えばブロッコリーを切り終わった時点で即座に洗う等、各メニューの各工程が完了するたびに発生した。中盤山型では、フライパンにひいた油を温めている間に、フライパンの状態を確認しながら洗い、油が温まると鶏もも肉をフライパンに載せ、焼き加減を見ながら再度洗いに戻るというように、待ち時間にまな板洗いが発生した。終盤山型では、まな板洗いは発生せず、野菜を切っていたまな板で鶏もも肉を切ると、その後は新しいまな板が

表2．キッチンを対象とする行動観察の量的進化

	第１世代	第２世代	第３世代
手法	目視・手動記録	目視・手動記録	自動検出・自動記録
可視化形態	図化	疎な数値化	密な数値化
N数	1件	2件	制限なし（今回24件）
分析	（センスと経験）	• 集計分析 • 比較分析	• 集計分析 • 統計分析 • 機械学習分析
記録	• 調理動作（約1000回） • 時間（秒） • 調理アイテムの種類（約150種類） • 設備（水栓、コンロ、収納等）へのアクセス • 手の状態（ドライ、ウェット）	• 調理動作（約1000回） • 時間（秒；動作発生毎） • 座標（25cmブロック単位） • 調理アイテムの種類（約150種類） • 調理アイテムの状態（使用・待機・放置・完了） • 設備（水栓、コンロ、収納等）へのアクセス	• 調理アイテムの種類（今回89種類） • 時間（ミリ秒；29.97fps） • 座標（1cm単位）
手動計算	–	• 調理アイテム数の時系列変化 • ブロック毎のアイテム出現特性 他	–
自動計算	–	–	• 調理アイテムの時系列変化 • エリア毎の調理アイテム出現特性 • 調理アイテムの状態（移動・滞留）他
主なツール	• Power Point（可視化）	• Excel（計算、可視化）	• 深層学習（物体検出） • Python（抽出、計算、可視化） • Tableau（可視化）

取り出された。このことから、山型の 2 種間の分類も妥当であると考えられる。

4.6.2 妥当性検証（アンケート照合）

他方、自宅での調理に関するアンケート 10 項目（5 段階評価）との照合も実施した。上述の 3 分類と合致する傾向が見られた質問項目は、「こまめに洗って片付けるか」、「盛り付け場所に困るか」であった。照合結果を図 5 に示す。「こまめに洗って片付けるか」という自意識に対する YES 回答率は、ピーク頻出型では 100%であったのに対し、中盤山型と終盤山型では 50%程度にとどまった。また、「盛り付け場所に困るか（反転）」に対する YES 回答率は、ピーク頻出型では 86%、中盤山型と終盤山型では約 20%であった。これらの照合から、ピーク型と山型 2 種の分類判定は、被験者の自意識とも合致していた。

なお、インタビューにける「時短を重視するか（YES、NO、回答なし）」とも照合を行ったところ、YES 回答率は、ピーク頻出型 41%、中盤山型 71%、終盤山型 30%と、明確な差が出た（図 5）。特筆すべきは、中盤山型の割合の高さと、終盤山型の積極的に NO という被験者の存在である。

そこでさらに調理時間実測値と照合してみると、時短重視の中盤山型は、ピーク頻出型や終盤山型に比べて、約 6 分早いことがわかった（表 1）。調理中盤に現れるリセット動作は、時短意識に基づいていると考えられる。

終盤山型の NO と回答した被験者のインタビューからは、「追い込まれたくない」、「気ままに調理を楽しみたい」といった意見を聞くことができた。これらの被験者は、調理において便利さやスピードといった合理性を追求していない。このような特徴的な価値観は、行動観察だけでなくアンケートやインタビューとの掛け合わせから気付きを得る場合が多い。私たちはユーザーがそれぞれ求めることを、行動データの解析と傾聴の双方から理解し、パーソナライズ提案につなげていきたいと考えている。

4.6.3 各分類に対する提案

以上 2 つの検証から、シンクエリアにおけるユーザー特性の 3 分類は妥当であるといえる。これらの各分類に対し、例えば、ピーク頻出型にはこまめにリセット動作が行いやすいキッチン、中盤山型にはリセット動作と確認動作を並行しやすいキッチン、終盤山型には盛り付けまで広々と使いやすいキッチン等、調理のユーザー特性にフィットした提案が可能である。

5. まとめと今後の展開

調理動画に深層学習による物体検出技術を適用した。この効果は表 2 の通りであり、工数削減が 100 分の 1、被験者数増加が 12 倍（今回）、粒度細密化が時間 10 倍、空間 25 倍、さらに均質性向上、すなわち同一のデータを用いて複数名が別に異なる視点で分析可能となった。

得られたデータから、6 エリアにおける調理アイテム検出数の時系列変化を分析した。この中で、シンクエリアにおけるユーザー特性を目視分類すると、ピーク頻出型、中盤山型、終盤山型の 3 つに大別された。これらの分類について、動画ならびにアンケートと照合すると、妥当性は良好であるといえた。

各分類に対しては、例えば、ピーク頻出型にはこまめにリセット動作が行いやすいキッチン、中盤山型にはリセット動作と確認動作を並行しやすいキッチン、終盤山型には盛り付けまで広々と使いやすいキッチン等、調理のユーザー特性にフィットした提案が可能である。

今後は、検出精度の向上、統計処理や機械学習を用いた自動分類、洗い等の動作の自動判定、シンクエリア以外のエリアにおけるユーザー特性との掛け合わせ、あるいはアイテム検出数の時系列変化以外の切り口での分析ならびにその結果との掛け合わせ等の課題に取り組み、より確度の高いパーソナライズ提案につなげていきたい。

参考文献

[村上 2010] 村上孝子：システムキッチンの調理スペースについての一考察～調理補助アイテムの提案～，人間生活工学，vol.11，no.1，通巻 33 号，2010

[松波 2013] 松波晴人：「行動観察」の基本，ダイヤモンド社，2013

[Liu 2016] Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C., and Berg, A.: Ssd: Single shot multibox detector, in European conference on computer vision, pp. 21–37, Springer (2016)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

一般家庭の消費電力を対象とした外れ値検出手法による異常検知性能の比較

Comparison of Anomaly Detection Performance by Outlier Detection Methods for Household Power Consumption

橋本 美穂 *1 Miho Hashimoto　八木 悠太朗 *1 Yutaro Yagi　西垣 貴央 *1 Takahiro Nishigaki　小野田 崇 *1 Takashi Onoda

*1青山学院大学 理工学部 経営システム工学科
Department of Industrial and Systems Engineering, College of Science and Engineering, Aoyama Gakuin University

After the Great East Japan Earthquake, energy-saving consciousness is increasing in Japan. Then, HEMS attracts attention. HEMS is the system managing household power comsumption. However, HEMS is at risk of a cyber attack through the Internet. So, it is necessary to detect a cyber attack. When an electronic equipment is hit by a cyber attack, the power value is different from the steady state because load is applied to electric state. So, we detect abnormal power consumption by outlier detection methods and compare the result. The outlier detection methods are 'Hotelling', 'k-NN', 'Local Outlier Factor', 'One Class SVM', 'SVDD' and 'Density Ratio Estimation'. As a result, 'Density Ratio Estimation' is the best.

1. はじめに

東日本大震災以降、原子力発電所停止等により日本の電力事情が大きく変わり省エネルギー意識が高まりつつある。それに伴い、家庭のエネルギーを管理し、制御することで今まで余分に使われていたエネルギーを削減できるようなシステムとしてHEMS(Home Energy Management System) に注目が集まっている。この HEMS とは一般的な例として図 1 のように照明器具、エアコン、太陽光発電といった電気機器をつないで家庭内のエネルギー使用量状況を見える化し、管理するシステムのことである。しかしながら、HEMS はインターネットを通じてデータの送受信を行うため、ここからサイバー攻撃を受けて HEMS 全体が停止してしまうリスクがあげられる。従って、HEMS へのサイバー攻撃を防ぐセキュリティ対策を行うことの必要性がこれまで以上に高まっている [奥村 13][加藤 13]。現在、工場や発電所などの大規模な環境での外れ値検知や異常検知の研究は多く行われているが HEMS を対象としたものはあまり行われていない [須藤 15][小野田 16]。従って、本研究では HEMS を対象とした外れ値検出手法による異常検知の検討を行う。

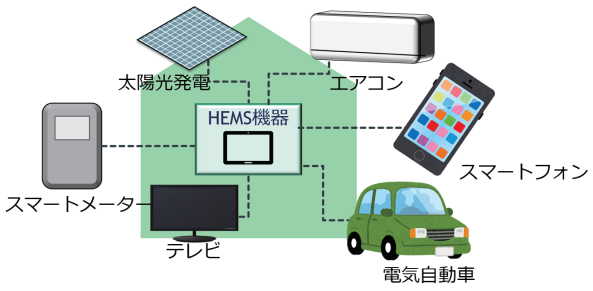


図 1: HEMS の例

連絡先: 橋本美穂，青山学院大学 理工学部
経営システム工学科，a5715062@aoyama.jp

2. 関連研究

2.1 スマートハウスにおける異常検知

まず、スマートハウスとは HEMS などのエネルギー管理システムを用いて、家庭エネルギー消費量を最適に制御する住宅のことである。関連研究として論文 [奥村 13] では、スマートハウスにネットワーク不正侵入があった場合、電気機器へ負荷がかかると定常時とは異なる電力値の変化が生じることに着目し、電力値に統計的異常検知手法を適用した侵入検知を行っている。評価用データセットには、1 台の家電機器がコンセントにつながっている場合の定常時の電力値と非定常時の電力値を合成したデータを用いている。結果として、異常を検知することができた。しかし、この実験では 1 台の家電機器がコンセントにつながっている場合のみでしか行っておらず、多数の電気機器がつながっている場合の異常検知には至っていないという課題があげられる。

2.2 研究課題と目的

論文 [奥村 13] では 1 台の家電機器がコンセントにつながっている場合の異常検知を行っている。しかし、今後、各家電機器、電気設備ごとに異常検知システムを開発・実装していくのは効率が悪いといえる。この時、一般家庭の消費電力量が基本的にほぼ規則的、あるいは特徴的な傾向を持つならば、その消費電力データにおいて外れ値検出手法による異常検知が可能であるといえる。従って、本研究では一般家庭の総消費電力において、どの外れ値検出手法が適しているのかを調べるためにその異常検知性能の比較を行う。

3. 実験条件

本研究では著書 [井出 15] を参照に「ホテリング法」、「k-NN 法」、「Local Outlier Factor(以下、LOF)」、「One Class Support Vector Machine(以下、OCSVM)」、「Support Vector Data Description(以下、SVDD)」、「密度比推定法」の 6 つの外れ値検出手法を選択し、その実験結果を比較する。

3.1 使用データ

実験データには群馬県太田市の太陽光発電実証試験で計測された一般家庭の消費電力データを用いる。表 1 は計測されたデータの概要である。本研究では家庭内で消費された電力

表 1: 集中連携型太陽光発電システム実証研究データ概要 [電工 13]

データ概要	
期間	2006/04/01 ～2008/02/19
時間解像度	1 秒
戸数	496～553(途中参加あり)
観測項目	PV アレイ発電電力 (直流)
	PCS 有効電力 (交流)
	家庭内負荷有効電力 (交流)
ファイル数	384,216
データサイズ	約 714GB

値を扱うので、表 1 における家庭内負荷有効電力の部分にあたるデータを用いる。また、表 2 における PV アレイ発電電力は、太陽光発電で得られた電力のことであり、PCS(Power Conditioning System) 有効電力は PV アレイ発電電力を直流から交流に変換して出力したものである。

3.2 データ加工

データは表 2 のように 1 列目には時間、2 列目には各時間における 1 分ごとの消費電力量の合計値が入力したものを用いる。消費電力量は家電機器の突入電流等の影響を考えて、時間解像度を 1 秒のまま使用するのではなく、1 分間の合計を用いる。突入電流とは電気機器に電源を投入したときに、一時的に定常状態で流れるよりも大きな電流が流れることである。

表 2: 使用データ例

時間 (分)	消費電力値
0.0000	49.743
0.0167	49.004
0.0333	49.207
⋮	⋮
23.950	42.477
23.967	42.820
23.983	41.494

その後、データは以下の式によって正規化を行ったものを使用する。

$$\boldsymbol{x}_{tr} = \frac{\boldsymbol{x}_{tr} - \boldsymbol{\mu}_{tr}}{\boldsymbol{\sigma}_{tr}} \tag{1}$$

$$\boldsymbol{x}_{te} = \frac{\boldsymbol{x}_{te} - \boldsymbol{\mu}_{tr}}{\boldsymbol{\sigma}_{tr}} \tag{2}$$

$\boldsymbol{x}_{tr}$: 学習データ集合　　$\boldsymbol{x}_{te}$: 試験データ集合

$\boldsymbol{\mu}_{tr}$: 学習データの平均　$\boldsymbol{\sigma}_{tr}$: 学習データの標本偏差

しかしながら、今回使用した手法の一つである OCSVM はカーネルを linear にしたため、上記の式で正規化すると結果を出すことができない。なぜなら、この正規化を行うと負の値が出てくることから、全てのデータは第 1 象限に集まらずうまく識別超平面を見つけることができない。従って、OCSVM のみに関しては以下の式によって正規化を行ったものをデータとして扱う。

$$\boldsymbol{x}_{tr} = \frac{\boldsymbol{x}_{tr} - \boldsymbol{x}_{tr\_min}}{\boldsymbol{x}_{tr\_max} - \boldsymbol{x}_{tr\_min}} \tag{3}$$

$$\boldsymbol{x}_{te} = \frac{\boldsymbol{x}_{te} - \boldsymbol{x}_{tr\_min}}{\boldsymbol{x}_{tr\_max} - \boldsymbol{x}_{tr\_min}} \tag{4}$$

$\boldsymbol{x}_{tr}$: 学習データ集合　　$\boldsymbol{x}_{te}$: 試験データ集合

$\boldsymbol{x}_{tr\_max}$: 学習データの最大値　$\boldsymbol{x}_{tr\_min}$: 学習データの最小値

3.3 実験条件

本研究で使用する消費電力データには正常状態のデータ数が多いものの異常状態のデータ蓄積はほとんどなく、また、異常状態に関するデータの測定は容易ではない。従って、全て正常データであると仮定した一般家庭の消費電力データを学習データと試験データに分ける。実験における試験データには、異常データとして以下の 4 つの正常データを加工したものを用意した。

試験データ 1 消費電力値全体を 10 倍

試験データ 2 ある時間帯 (12 時～13 時) の消費電力値を 10 倍

試験データ 3 消費電力値全体を 2 倍

試験データ 4 家庭番号が異なる別の家庭の消費電力値

また、以下の図にそれぞれの 1 日分のデータ例を示す。それぞれ、縦軸は消費電力値 (1 分ごとの消費電力量の合計値)、横軸は時間を表している。図 2 の左図には正常データを示す。右図には同じく左図の正常データを○で、試験データ 1 を×、試験データ 3 を△で示している。更に、図 3 の左図は試験データ 2 を示している。実際に 12 時から 13 時の部分において正常データを 10 倍したデータが突出していることがわかる。図 3 の右図は試験データ 4 を示しており、学習データ (図中○) と試験データ (図中×) の家庭の消費電力データを表している。

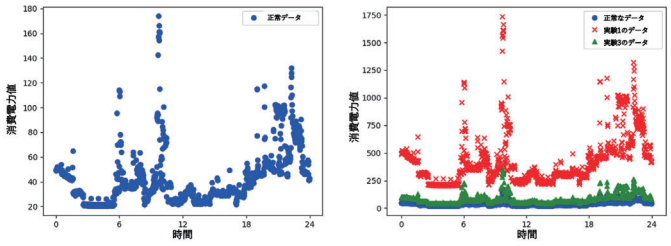


図 2: 正常データ (左図) と試験データ 1,3 のデータ (右図) 例

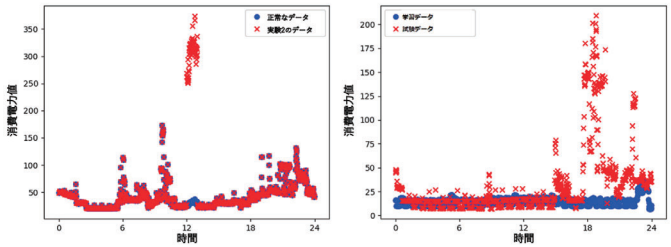


図 3: 試験データ 2 データ (左図) と試験データ 4 のデータ (右図) 例

3.4 評価指標

本実験では外れ値検出手法における異常検知性能の比較をするうえで、F 値 (調和平均) を求めた。以下 F 値について説

明する。F 値は正常標本精度と異常標本精度のバランスをとったものであり、以下の式で表すことができる。

$$f = \frac{2r_0 r_1}{r_0 + r_1} \tag{5}$$

r_0: 正常標本精度　r_1: 異常標本精度

この時、F 値の値が高いほど精度よく判定できているといえる。ここで正常標本精度とは正常である標本の中で正常と正しく判定できた割合であり、以下の式で表せる。

正常標本精度 =

$$\frac{\text{実際に正常である標本の中で正常と正しく判定できた数}}{\text{実際に正常である標本の総数}} \times 100 \tag{6}$$

この時、正常標本精度の値が高いほど判定の精度が高いといえる。これに対し、異常標本精度は異常である標本の中で異常と正しく判定できた割合のことであり、以下の式で表せる。

異常標本精度 =

$$\frac{\text{実際に異常である標本の中で異常と正しく判定できた数}}{\text{実際に異常である標本の総数}} \times 100 \tag{7}$$

この時、異常標本精度の値が高いほど判定の精度が高いといえる。これらにおいては設定した異常判定の閾値によって正常標本精度と異常標本精度の値が変わってくる。異常判定の閾値が無限に小さいとき、全ての標本を異常と判定してしまう。正常標本を一つも正解できないので正常標本精度は 0 だが、異常標本精度は 1 となる。また、異常判定の閾値が無限に大きいとき、全ての標本を正常と判定してしまう。異常標本を一つも正解できないので異常標本精度は 0 だが、正常標本精度は 1 となる。これではうまく、異常判定をできている状況とは言えない。従って、本実験では正常標本精度だけ、異常標本精度だけで比べるのではなく、二つのバランスをとったこの F 値を算出し、実験結果を比べる。

また、今回の試験データ 1〜3 では消費電力データに欠損のない 18 件の家庭でそれぞれ実験を行い、それぞれ家庭ごとの正常標本精度、異常標本精度、F 値を算出した後、全ての家庭の結果の平均をとったもので比較を行う。式としては以下のようになる。ここでの f_i は欠損のない i 番の家庭の F 値（又は正常標本精度、異常標本精度) を表す。

$$F = \frac{\Sigma_{i=1}^{18} f_i}{18} \tag{8}$$

3.5　使用パラメータ

各外れ値検出手法のパラメーター及び閾値は次の表 3 の通りである。

4.　実験結果, 考察

以下,、実験結果を示す。この時、全ての実験にいて学習期間及び試験期間は以下の通りである。

学習期間　2007/06/01〜2007/06/29

試験期間　2007/06/30

表 3: 各手法における設定したパラメーター

ホテリング	閾値	3σ
k-NN	近傍数	1
	閾値	$t > 0.1$
LOF	近傍数	20
One class SVM	カーネル	linear
	パラメータ	ν=0.01
SVDD	カーネル	radial basis function
	パラメータ	c=0.99
		γ=1
密度比推定	閾値	$0.1 < t < 10$

4.1　試験データ 1:消費電力値を全て 10 倍

試験データ 1 を入力した結果としては表 4 のようになった。結果を見るとホテリング法が一番 F 値が高いことがわかる。この理由は、試験データとして消費電力値をすべて「10」倍にしたデータを用いたからであると考えられる。ホテリング法はデータが正規分布に従うと仮定したとき、未知データが学習データの平均と分散より、学習データからどれだけ離れているかで異常判定を行う。この実験において、図 4 の左図のようにもとの消費電力データの最大値を 10 倍した消費電力データの最小値がゆうに超えるため、学習データと試験データをはっきりと分けれることができる。従って、ホテリング法は試験データ 1 において F 値が一番高くなったと考えられる。このことは k-NN 法や OCSVM でも同じことが言える。k-NN 法は近傍の学習データから、未知データである試験データが正常か異常かを判断する。試験データ 1 の場合は先ほど述べたようにはっきりと正常データと異常データを分けることができるので自然と k-NN 法でも近傍のデータの異常か正常か、はっきりと分かれ、このような結果になったと考えられる。OCSVM は値の大きな外れ値データは特徴空間に写像した際、原点側に来ることを利用して異常を判断する。従って、試験データ 1 では試験データがはっきりと値が大きな異常データとしてわかるため、この結果になったと考えられる。しかし、ホテリング法をはじめとしたこれらの手法は今回の 10 倍ではうまくいったものの、消費電力データを 10 倍ではなく、10 倍より小さい倍数にした場合、図 4 の右図のように学習データと試験データは値として重なる部分がでてくるので F 値が 10 倍の時よりも低くなると考えられる。

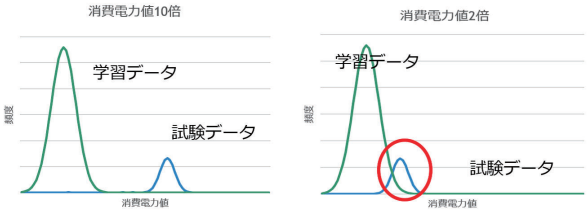


図 4: 学習データと試験データの関係

一方で、LOF や SVDD、密度比推定は他手法に比べて F 値が低くなった。その理由としては LOF では指定した近傍数内の未知データの局所密度と学習データの局所密度を比較し、未知データの局所密度が学習データの局所密度に比べて大きい場合、異常と判定する。従って、今回の実験では試験データの局所密度と学習データの局所密度に大きな差がみられず、このような結果になってしまったと考えられる。次に、SVDD は識

別器として学習データすべて (またはほとんど) を含むような球体を求め、球より外側にあるデータが異常と判定される。しかし、この方法では今回は 1 日分のデータを扱っているため、一般的に昼間の消費電力値が高い時も夜の消費電力値の低い時も球としてすべて囲むので球が大きくなりすぎてしまい、うまく判別に至らなかったと考えられる。密度比推定は学習データの確率密度 $p(\boldsymbol{x})$、試験データの確率密度 $p'(\boldsymbol{x})$ を個別に推定し、密度比 $r(\boldsymbol{x}) = p'(\boldsymbol{x})/p(\boldsymbol{x})$ を求めるのではなく、直接、データから密度比を推定し、この密度比から異常かどうかを判定する。この時、密度比 $r(\boldsymbol{x})$ が 1 より大きく離れたデータを異常値とみなす。密度比推定がこのような結果になった理由としては試験データ 1 での正常標本精度が他手法に比べて低いことが影響しているからと考えられる。密度比推定では学習データ内ではある時間帯にいつも電力を使用しているが、試験データの日はたまたま、使用しなかったような場合も密度比は 1 以外を示すため、異常と判定する。従って、通常の高い消費電力値を示したときに異常と判定する以外にも異常判定要素があるため、正常標本精度が下がり、このような結果になったと考えられる。

表 4: 試験データ 1 の結果

F 値					
ホテリング	k-NN	LOF	SVDD	OCSVM	密度比推定
98.14	95.59	86.61	76.22	94.75	86.22

4.2 試験データ 2:ある時間帯の消費電力値を 10 倍

結果は表 5 のようになった。この結果より試験データ 2 は試験データ 1 とほぼ同等の結果が得られたことから一部 10 倍の時も外れ値検出手法を用いて異常検知ができると考えられる。また、このとき、結果を見るとホテリング法の F 値が一番高いことを示しているが、このような結果となったのは、試験データ 1 の時と同様の理由が考えられる。

表 5: 試験データ 2 の結果

F 値					
ホテリング	k-NN	LOF	SVDD	OCSVM	密度比推定
98.44	93.86	82.13	71.62	96.75	67.7

4.3 試験データ 3:消費電力値を全て 2 倍

結果は表 6 のようになった。表 6 を見ると、ホテリング法をはじめとした密度比推定法以外の手法においての F 値が低くなっていることがわかる。これは、試験データ 1 で行った考察のとおり、消費電力が 10 倍の時は正常データ (学習データ) と異常データ (試験データ) をはっきりと分けれたが、このように消費電力値の倍数を 2 倍すると値として重なる部分が存在するからである。それに対し、密度比推定は試験データ 1 から F 値は多少落ちるものの他手法に比べ、高い結果を出している。これに対して、密度比推定法では学習データにおける各時間ごとの消費電力と試験データにおける各時間ごとの消費電力の密度比を用いた異常検知では 2 倍の時も 10 倍の時と同じような結果になる。従って、密度比推定を用いた時が一番 F 値が高くなった。

4.4 試験データ 4:家庭番号が異なる別の家庭の消費電力値

結果は表 7 のようになった。全体的な結果として F 値が低い。これは、異なる二つの家庭において消費電力パターンに顕著な差がみられなかったためと考えられる。異常消費電力量の規則性や特徴的な傾向が似ている家庭の場合は, 学習データと試験データが別の家庭であっても正常と判定することが多いと考えられ、異なる家庭における異常検知は現状、難しいといえる。

表 6: 試験データ 3 の結果

F 値					
ホテリング	k-NN	LOF	SVDD	OCSVM	密度比推定
40.02	36.51	45.4	40.67	28.02	77.03

表 7: 試験データ 4 の結果

F 値					
ホテリング	k-NN	LOF	SVDD	OCSVM	密度比推定
17.52	13.26	19.2	36.98	13.83	29.05

5. まとめ

本研究ではネットワークを通じて不正侵入がされた際に電子機器への負担がかかり、定常時とは異なる消費電力値の変化が生じることに注目して一般的な外れ値検知手法である「ホテリング法」、「k-NN 法」、「Local Outlier Factor」、「One Class Support Vector Machine」、「Support Vector Data Description」、「密度比推定法」の 6 つの外れ値検出手法で実験を行い、その結果を比較した。その結果として、一般家庭の消費電力の異常検知としては密度比推定が他手法に比べて F 値が高いことがわかった。一方で、密度比推定法以外の手法では今回適用したデータ加工の仕方が良くなかったため、結果が悪かったと考えられる。今後、外れ値検出手法の異常検知の性能の比較をするためには、各手法に対して適したデータ加工の仕方を考える必要がある。

参考文献

[奥村 13] 奥村 晃弘 白石善明 岩田彰: Ro-004 スマートハウスにおける電力変動からの不正アクセス検知の検討 (o 分野：情報システム。査読付き論文), 情報科学技術フォーラム講演論文集,Vol.12,No.4,pp.87-90(2013)

[加藤 13] 加藤 力也:家庭用エネルギー管理システム (HEMS) の普及に関数課題とその動向, 電力中央研究所報告, Y12011(2013)

[須藤 15] 須藤 昌吉 渡邉 経夫 松本 篤 大谷 圭子 高原 薫:火力発電プラント機器の異常兆候を検出するデータマネージメントシステム, 第 77 回全国大会講演論文集 pp.463-464(2015)

[小野田 16] 小野田 崇:火力発電所の運転データからの異常予兆発見研究について：水力発電所における異常予兆発見のアナロジーとして（特集第 43 回定期公演会 (米子)）, 日本ガスタービン学会誌,Vol.44,No.1pp.48-53(2016)

[井出 15] 井出 剛 杉山 将:異常検知と変化検知 (機械学習プロフェッショナルシリーズ), 講談社 (2015)

[電工 13] 株式会社関電工:平成 14 年度 nedo 委託業務成果報告所 (2013)

General Session | General Session | [GS] J-9 Natural language processing, information retrieval

[2L1-J-9] Natural language processing, information retrieval: fusion with image

Chair:Chiaki Miyazaki Reviewer:Tomoya Yoshikawa

Wed. Jun 5, 2019 9:00 AM - 10:00 AM Room L (203+204 Small meeting rooms)

[2L1-J-9-01] Evaluation uncertainties in Image-Caption Retrieval

○Kenta Hama[1], takashi matsubara[1], uehara kuniaki[1] (1. Kobe University)

9:00 AM - 9:20 AM

[2L1-J-9-02] A Study on Behavior of Deep Neural Text-to-Image Generative Model

○Chihiro Fujiyama[1], Ichiro Kobayashi[1] (1. Ochanomizu University)

9:20 AM - 9:40 AM

[2L1-J-9-03] Towards Building a Logical Inference System for Text and Visual Information

Riko Suzuki[1], ○Masashi Yoshikawa[2], Hitomi Yanaka[3], Koji Mineshima[1], Daisuke Bekki[1] (1. Ochanomizu University, 2. Nara Institute of Science and Technology, 3. RIKEN Center for Advanced Intelligence Project)

9:40 AM - 10:00 AM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

画像テキスト検索における不確かさの評価

Evaluation uncertainties in Image-Caption Retrieval

濱 健太　松原 崇　上原 邦昭
Hama Kenta　Matsubara Takashi　Uehara Kuniaki

神戸大学 大学院システム情報学研究科
Graduate School of System Infomatics, Kobe University

Deep learning algorithms are able to learn powerful representations for many tasks. These models' outputs are often taken blindly and assumed to be accurate, however, which are not always the case. This blind assumption causes many issues such as AI unsafety and social bias. Therefore, a meaningful measure of uncertainty is essential. It has been shown that Monte Carlo (MC) Dropout can model epistemic uncertainty, and enhance model performance in machine learning tasks. In this paper, we propose an evaluation method of uncertainty in image caption retrieval and verified its significance by qualitative evaluation. Also, we show that a learning model using MC Dropout improves accuracy in image caption retrieval.

1. はじめに

機械学習のアルゴリズムやシステムの発展と共に, その手法を適用したアプリケーションが様々な分野で成果を挙げている. これらのアルゴリズムの多くは, 人間には解釈できない入力と出力の間の複雑なマッピングを学習する. そのため精度が十分得られていれば, 実用上のアプリケーションでは出力結果を正しいものと仮定して利用するしかない. 異なる入力に対して, モデルがどの程度確信を持って結果を出力しているのかを評価するのは困難である. しかし安全性や社会的問題という観点から見ても, 実用上のアプリケーションでモデルの出力の不確かさを, 評価することは重要である. [Kendall 17] は自動画像分類アプリが人種差別的な画像分類を行なって, 問題となった例をあげている. 我々は精度が良いことに加え, 出力の不確かさを正しく評価できるシステムを必要としている. もし十分に不確かさを評価できれば, 上記のような問題を回避することができる.

機械学習のモデルの不確かさはその要因によって分類され, 様々な定義が存在する. 本研究では, モデルのパラメタや構造選択に関わる不確かさ (epistemic uncertainty) と, 出力に対するモデルの確信度合いを表す予測分布のエントロピー (predictive entropy) を扱う. epistemic uncertainty は十分な学習データがあれば減少し, モデルが持つ不確かさと捉えられる [Kendall 17]. Bayesian neural networks (BNN) [MacKay 92] は epistemic uncertainty を評価する方法の一つである. BNN はニューラルネットワークの重みがある事前分布に従うと仮定する. そこで, ネットワークの重みを何度もサンプルし, その出力のブレを見ることで epistemic uncertainty を評価できる [Gal 16].

近年, 様々な機械学習のモデルで不確かさを評価する研究がされている. 画像認識の分野では, セグメンテーションや深度推定への適用 [Kendall 15,Kendall 17] や, 自然言語処理の様々なタスクへの適用 [Xiao 18], また異常検知 [Choi 18], 行動認識 [Subedar 18], 時系列データ解析 [Zhu 17] など多岐に渡る. しかし, 画像テキスト検索においては, その双方向性から入力となるクエリと, 出力となるターゲットの両方の不確かさを考えることができる点で他のタスクと異なる性質を持っている. クエリ側の不確かさの評価結果から, より良い検索文を入力するようユーザに促す, システムの学習データの不足を検知し管理者に知らせる. ターゲット側の不確かさの評価結果から, 表示する検索結果を変えて精度の改善を測る等, 画像テキスト検索では不確かさに関わる情報はシステムの改善にとって重要である. 本研究は, 画像テキスト間検索における不確かさの評価方法を提案し, その不確かさが捉えた意味を定性的に評価し検証した. また提案手法が, 画像テキスト間検索で精度を向上させたことを示す.

連絡先: 濱 健太, 神戸大学 大学院システム情報学研究科, hamaken@ai.cs.kobe-u.ac.jp

2. 関連研究

2.1 Bayesian Neural Network (BNN)

ニューラルネットワークは重み W をパラメタとして持つ. 教師あり学習では, データセット $D = (x_i, y_i)_{i=1}^N$ に対して, 何らかの目的関数を最大化する W を推定するよう学習する. ベイズ推定では W は, 事前分布 $p(W)$ に従うと仮定し, 最適なパラメタ W ではなく, D に対する最適な事後分布 $p(W|D)$ を推定することを目標としている. またモデルの出力を $f^W(x)$ とすると, BNN の予測値 y は推定した事後分布 $p(W|D)$ から得られる W で, $f^W(x)$ を周辺化した値となる.

しかし, 近年の深層ニューラルネットワークは高次元のパラメタ W を持ち, 構造も非線形で複雑なため, 事後分布を計算できない. そこで, 様々な近似計算の方法が提案されている. 特に, Monte Carlo dropout (MC dropout) [Gal 16] は元のモデルに対する大きな変更なしで利用できる. MC dropout は, ネットワークの非線形層の間に Dropout 層を追加し, モデルの評価時に Dropout を適用しながら複数回ネットワークから出力を得て, その平均をモデルの出力として利用する. [Gal 16] では, MC dropout があるモデルの変分ベイズ法の近似計算であることが数学的に示されている. Dropout のマスク行列をサンプルして得られるモデルの出力は, 事後分布 $p(W|D)$ からサンプルした W を用いて計算した $f^W(x)$ と解釈できる. また, モデルの不確かさはこの方法を繰り返して得られた複数の出力の分散を見ると, 近似的に評価できる.

2.2 Visual Semantic Embedding++

画像テキスト検索における一般的な手法として，Visual-Semantic Embeddings (VSE) [Kiros 14] がある．VSE は，CNN で画像の特徴量を抽出し，Recurrent Neural Network(RNN) でテキストの特徴量を抽出し，それらを類似度の計算が可能な共通の空間に線形変換で埋め込む．本研究では，ベースラインとして VSE++ [Faghri 17] と呼ばれる，VSE の損失関数を改良し精度を向上させたモデルを用いる．この VSE++では画像の特徴量は ImageNet で学習済みの VGG か ResNet を，テキストは LSTM を用いて抽出する．

VSE++の損失関数について説明する．入力画像とその特徴量をそれぞれ x, h とし，入力テキストとその特徴量をそれぞれ y, t とする．ここで，画像の特徴量とテキストの特徴量を共通空間に埋め込む行列を M_x, M_y とすると，共通空間上の画像，テキストの表現は $z_x = M_x h$, $z_y = M_y t$ という形で得られる．これらの表現の類似度は VSE++では以下の cos 類似度を用いて計算される．

$$\mathrm{sim}(z_x, z_y) = \frac{z_x \cdot z_y}{\|z_x\|_2 \|z_y\|_2}$$

VSE++は次の rank-loss と呼ばれる式を用いて損失関数を定義する．

$$\begin{aligned} r(x, y) = &\max_{\hat{y}} \max\{0, \alpha - \mathrm{sim}(z_x, z_y) + \mathrm{sim}(z_x, \hat{z_y})\} \\ &+ \max_{\hat{x}} \max\{0, \alpha - \mathrm{sim}(z_x, z_y) + \mathrm{sim}(\hat{z_x}, z_y)\} \end{aligned} \tag{1}$$

$\hat{z_x}, \hat{z_y}$ は入力データ x, y と関連しないデータ (負例) の埋め込み点を意味する．マージン α は関連するデータ (正例) と負例の類似度の差を調節するハイパーパラメタである．rank-loss を用いて，VSE++の損失関数は以下のように定義される．

$$L = \frac{1}{N} \sum_{n=1}^{N} r(x_n, y_n)$$

ただし，N は訓練データ数である．

3. 提案手法

3.1 不確かさの定義

モデルの出力の不確かさは，その要因によって大きく 2 種類に分類される [Kendall 17]．入力データセットそのものの複雑さや，観測ノイズなどが原因とされるそれ以上減らすことのできない不確かさ (aleatoric uncertainty) と，モデルへの入力データの不足や，それによる学習不足が原因とされる不確かさ (epistemic uncertainty) である．本研究では epistemic uncertainty とモデルの出力に対する確信度合いである predictive entropy の二つを取り扱う．まずは [Kendall 17] による，epistemic uncertainty の定義を説明する．BNN ではデータセット $D = (x_i, y_i)_{i=1}^N$ が与えられたときの，重み $\mathbf{W}$ の事後分布を推定する．扱う問題が分類問題の場合，入力 x から得られる予測値 y は次のようにして得られる．

$$y|\mathbf{W} \sim \mathrm{Categorical}(\mathrm{Softmax}(f^{\mathbf{W}}(x)) \tag{2}$$

事後分布 $p(\mathbf{W}|D)$ が与えられた際，新たな入力 x^* が，クラス y^* に分類される確率は次の式で与えられる．

$$p(y^*|x^*, D) = \int p(y^*|f^{\mathbf{W}}(x^*)) p(\mathbf{W}|D) d\mathbf{W} \tag{3}$$

ほとんどの場合，事後分布の計算が解析的に不可能なため，変分ベイズ方が用いられる．変分ベイズ法では，パラメタ θ を用いて真の分布 $p(\mathbf{W}|D)$ を近似するための分布 $q_\theta(\mathbf{W})$ を置き，これら二つの分布を Kullback-Leibler (KL) divergence の最小化によって近づける．変分ベイズ法は第 2.1 項で述べた用に，MC Dropout で近似できる．本研究では Epistemic Uncertainty の評価に MC Dropout を用いる．モデルの評価時，最適化された事後分布の近似である $q_\theta(\mathbf{W})$ を用いて，式 (4) の $p(\mathbf{W}|D)$ と置き換えて，M 回のサンプルによるモンテカルロ積分により予測分布は次のように得られる．

$$p(y^*|x^*, D) \approx \frac{1}{M} \sum_{j=1}^{M} \mathrm{softmax}(f^{\mathbf{W}'_j}(x^*)) \tag{4}$$

ここで，epistemic uncertainty $U_m(x^*)$ は次のように定義する．

$$U_m(x^*) \approx \frac{1}{C} \sum_{y=1}^{C} \frac{1}{M} \sum_{j=1}^{M} \mathrm{softmax}(f^{\mathbf{W}'_j}(x^*))^2 - \mathbb{E}(y|x^*)^2 \tag{5}$$

C はクラス数，$\mathbf{W}'_j$ は分布 $q(\mathbf{W})$ からサンプルされたモデルのパラメタである．また predictive entropy は，モデルの予測分布 (4) のエントロピーとして定義する．

3.2 Image-Caption Retrieval

この節では，画像テキスト間検索というタスクを確率論の枠組みで捉え直す．初めに，議論を簡単にするため，一つのクエリに対してターゲットが正例と負例の二つのみの場合を考える．クエリを x，正例を y，負例を y' とする．このとき，点 x が状態 y または y' を取る確率が，ボルツマン分布に従うと仮定する．点 x が，状態 y を取る確率は次のように表される．

$$p(y|x) = \frac{e^{-E_y}}{e^{-E_y} + e^{-E_{y'}}} \tag{6}$$

ここで，点 x に対する状態 y が与えられている場合，対数尤度 $\log p(y|x)$ の最大化によって分布を学習できる．$\log p(y|x)$ は次のような式で表される．

$$\begin{aligned} \log p(y|x) &= \log \frac{1}{1 + e^{-E_{y'} + E_y}} \\ &= -\mathrm{softplus}(-E_{y'} + E_y) \end{aligned}$$

従って，対数尤度 $\log p(y|x)$ の最大化は，式 $\mathrm{softplus}(E_{y'} - E_y)$ を最小化することと等しい．この softplus 関数 (logistic loss) と，$\max(0, x)$ (hinge loss) は互いに近似としてよく用いられる．また 2 値分類問題において，目的関数に logistic loss もしくは hinge loss を用いた場合の識別境界が似た形になることは知られている [Bishop 06]．ここで，エネルギー関数 E_y を $E_y = -\mathrm{sim}(x, y)$ と仮定すると，$\log p(y|x)$ の最大化は式 (1) の最小化とほとんど等価である．クエリとターゲットのドメインを入れ替えることで，式 (1) の第二項目に関しても同様のことが言える．換言すれば，上記の確率場における対数尤度の最大化は，VSE の rank-loss の最小化と等しいと解釈できる．

次に，ターゲットの数が 2 つ以上の場合を考える．この場合，点 x が状態 y を取る確率は次のように表される．

$$p(y|\mathbf{x}) = \mathrm{softmax}(E_y) \tag{7}$$

正解となる状態 y が与えられている場合，この問題は多クラス分類問題として解釈される．2 値分類問題における softplus

表 1: Results on the MSCOCO dataset

Model	Dropout VGG	Dropout GRU	#models	Caption Retrieval R@1	R@5	R@10	Med r	Mean r	Image Retrieval R@1	R@5	R@10	Med r	Mean r
VSE++(baseline)	○	×	1	49.6	78.6	88.2	1.8	6.0	37.3	72.2	84.3	**2.0**	9.2
+ dropout	○	○	1	50.1	78.6	87.8	**1.6**	6.2	**38.1**	**73.1**	**85.2**	**2.0**	**8.5**
+ MC dropout	○	○	1	43.2	73.7	84.2	2.0	8.0	31.2	65.1	78.6	3.0	13.9
+ MC dropout	○	○	10	49.3	79.2	**88.6**	**1.6**	6.2	37.4	72.3	84.8	**2.0**	8.7
+ MC dropout	○	○	30	49.8	79.1	**88.6**	1.8	**5.9**	37.9	72.9	85.0	**2.0**	8.4
+ MC dropout	○	○	50	**50.4**	**79.5**	88.5	**1.6**	**5.9**	37.5	73.0	**85.2**	**2.0**	**8.5**

関数と hinge loss の関係は, softmax 関数と multi-class SVM の損失関数との関係と同じである. この研究では, 多クラス分類問題における対数尤度最大化と, VSE の rank-loss 最小化がほとんど等価であるという考えに基づいて, 画像テキスト間検索におけるクエリ x^* に対する epistemic uncertainty を次のように定義する.

$$U_m(x^*) \approx \frac{1}{C}\sum_{y=1}^{C}\frac{1}{M}\sum_{j=1}^{M}\mathrm{softmax}(\mathrm{E_{j,y}})^2 - \mathbb{E}(\mathrm{y}|\mathrm{x}^*)^2 \qquad (8)$$

ただし, $\mathbb{E}(y|x^*) \approx \frac{1}{M}\sum_{j=1}^{M}\mathrm{softmax}(\mathrm{E_{j,y}})$, $E_{j,y} = \mathrm{sim}(z_{x_j}, z_{y_j})$. また, z_{x_j}, z_{y_j} はそれぞれ, ドロップアウトを用いた x, y の j 回目の埋め込み表現である.

4. 実験・結果

MC dropout における検索精度を確認するため, 次の設定で実験を行なった. 実験には Microsoft COCO (MS COCO) [Lin 14] データセットを用いた. またデータの分割は [Faghri 17] と同様, 訓練用画像 113,287 枚, 検証用画像 1,000 枚, 評価用画像 5,000 枚にした. また評価は画像 1,000 枚ずつのスコア 5 回分の平均を用いた. 訓練時には入力画像に大きさ 224×224 のランダムクロップを適用し, 評価は大きさ 224×224 でセンタークロップした画像で行なった.

本研究では, VSE++のテキスト側のエンコーダである GRU への入力と出力に, ドロップアウト層を適用する. ただし, 画像側のエンコーダである VGG はすでにドロップアウトが適用済みであるため, 新しく層は追加しない. 共通空間の次元は 2048 次元で, 単語の埋め込み次元は 600 とし, ドロップアウト率は 0.1 で学習を行なった. その他のパラメタや最適化アルゴリズムは全て [Faghri 17] のものを使用した.

評価指標は, 画像テキスト検索において一般的な R@1, R@5, R@10, Med r, Mean r を用いる. R@k は, 評価データ中全てのクエリに対して, 正解となるターゲットが検索結果の k 番目以内に含まれる割合を表す. Med r は, 全てのクエリの正解となるターゲットの順位の中央値であり,Mean r は平均である.

結果は表 1 のようになった. Baseline はドロップアウト層を GRU に追加していない通常の VSE++であり, Baseline + ドロップアウトは, GRU にドロップアウトを追加し評価時は全ての重みを使用する (weight averaging) モデルである. そして提案手法である Baseline+MC dropout は, 評価時に MC dropout を用いた. 表 1 から分かるように, baseline + ドロップアウトは画像検索の精度を向上させ, 提案手法はさらにそこから, テキスト検索の精度を向上させている. また, 評価時のサンプル数が大きいほど精度が向上することが確認できた.

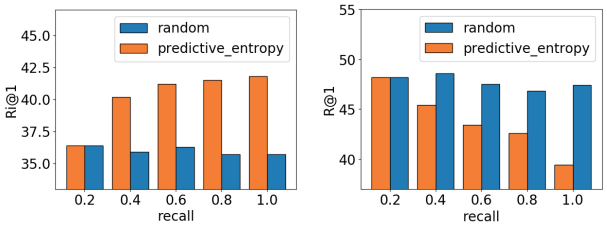


図 1: Left is R@1 for image retrieval. Right is Ri@1 for text retrieval. Horizontal axis means the rate of decreasing the query.

5. 検証

この節では, 定義した不確かさが検索タスクにおいて持つ意味を検証する. predictive entropy は予測結果に対するモデルの確信の度合いを表す. 図 1 は評価データのクエリから predictive entropy の大きいデータを除去しながら, R@1 の値をプロットしたものである. テキスト検索 (左) の場合, 除去する割合が大きくなるほど精度が向上しているため, predictive entropy がクエリーからターゲットを予測することの難しさを捉えていると考えられる. しかし, 画像検索 (右) の場合は精度が低下している. 画像からテキストへの検索は訓練データセットの構造上, 一つの画像に対する正解のテキストが 5 つ存在し, rank-loss は全てに画像が近くように学習を行う. predictive entropy が小さいデータはどれか一つのテキストに対して画像が過度に近づくなどして, 汎化学習が上手くできていない可能性がある. 次に, 評価用のデータセット内で predictive entropy が大きい入力データと小さい入力データを表示した. 図 2 は上段は predictive entropy が最大のものを左から順に, 下段は小さい順に表示している. predictive entropy が大きい画像は熊や馬などの動物が写っている画像が多いが, 小さい画像は人が写っているものが多い. これは画像認識において, 人の画像は動物よりも学習時に多く与えられるため, 識別性能が高いためだと考えられる. また表 2 は, predictive entropy の大きいテキストと小さいテキストの例である. 大きいテキストは, 具体性の低い文章であるが, 小さいテキストは状況を具体的に説明しているテキストになっている.

次に, 定義した epistemic uncertainty が学習不足を検知するかどうかを検証する. 図 3 は訓練データに MS COCO を用いて, 評価データに flickr30k [Young 14] のデータ 1000 枚を用いた場合と, MS COCO データ 1000 枚を用いた場合の入力データの epistemic uncertainty のヒストグラムである. 評価データに学習データと異なる flickr30k を用いた場合の方が, epistemic uncertainty が大きいことから, この不確かさが学習の不足を捉えていることが確認できる.



図 2: Examples of input images in MSCOCO dataset with high and row data uncertainties. The top row shows top 5 examples with high epistemic uncertainty. The bottom row shows bottom 5 examples.

表 2: Examples of input texts in MSCOCO dataset with high or low data uncertainties.

highly uncertain texts
· A person is doing something that is quite fun.
· A person is separated from everyone else in the picture and doing something there.
lowly uncertain texts
· A bench is sitting amongst the trees and the bushes.
· A boat floating on a lake next to a shore.

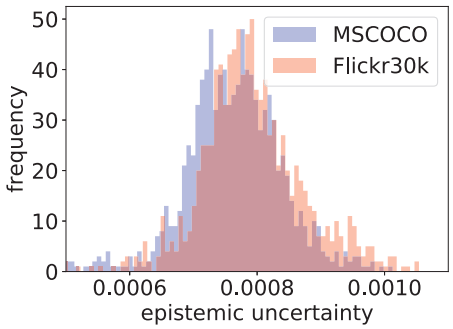


図 3: Distribution of epistemic uncertainty. Blue denotes MSCOCO, and red denotes Flickr30k.

6. 結論

本研究では, 検索タスクにおける不確かさの指標として epistemic uncertainty と predictive entropy を評価する方法を提案し, それらが意味のある指標であることを定性的実験により確かめた. また, 不確かさの評価のため用いた MC dropout という手法が, 検索タスクにおいて精度を向上させることを確認した. 今後の課題として, 他の不確かさの定義の検討や, 本研究で得られた不確かさの指標を用いて検索の実性能を向上させる方法の考案, 不確かさを用いた学習率などのパラメタの自動調節などを考えている. 本研究は総務省 SCOPE(受付番号 172107101) の委託を受けて行われた.

参考文献

[Bishop 06] Bishop, C. M.: *Pattern Recognition and Machine Learning*, Springer (2006)

[Choi 18] Choi, H. and Jang, E.: Generative ensembles for robust anomaly detection, *arXiv* (2018)

[Faghri 17] Faghri, F., Fleet, D. J., Kiros, R., *et al.*: VSE++: Improved Visual-Semantic Embeddings, *arXiv* (2017)

[Gal 16] Gal, Y. and Ghahramani, Z.: Dropout as a Bayesian approximation: Representing model uncertainty in deep learning, in *ICML* (2016)

[Kendall 15] Kendall, A., Badrinarayanan, V., and Cipolla, R.: Bayesian segnet: Model uncertainty in deep convolutional encoder-decoder architectures for scene understanding, *arXiv* (2015)

[Kendall 17] Kendall, A. and Gal, Y.: What uncertainties do we need in bayesian deep learning for computer vision?, in *NIPS* (2017)

[Kiros 14] Kiros, R., Salakhutdinov, R., and Zemel, R. S.: Unifying Visual-Semantic Embeddings with Multimodal Neural Language Models, *arXiv* (2014)

[Lin 14] Lin, T., Maire, M., Belongie, S. J., Hays, J., *et al.* : Microsoft COCO: Common Objects in Context, *ECCV* (2014)

[MacKay 92] MacKay, D. J.: A practical Bayesian framework for backpropagation networks, *Neural computation* (1992)

[Subedar 18] Subedar, M., Krishnan, R., Meyer, P. L., *et al.*: Uncertainty aware multimodal activity recognition with Bayesian inference, *arXiv* (2018)

[Tang 13] Tang, Y.: Deep learning using linear support vector machines, *arXiv* (2013)

[Xiao 18] Xiao, Y. and Wang, W. Y.: Quantifying Uncertainties in Natural Language Processing Tasks, *arXiv* (2018)

[Young 14] Young, P., Lai, A., Hodosh, M., *et al.*: From image descriptions to visual denotations: New similarity metrics for semantic inference over event descriptions, *Transactions of the Association for Computational Linguistics* (2014)

[Zhu 17] Zhu, L. and Laptev, N.: Deep and confident prediction for time series at uber, in *ICDMW, 2017 IEEE International Conference on* (2017)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

言語から画像を生成する深層学習モデルの挙動に関する考察

A Study on Behavior of Deep Neural Text-to-Image Generative Model

藤山 千紘 *1　　小林 一郎 *2
Chihiro Fujiyama　　Ichiro Kobayashi

*1お茶の水女子大学 人間文化創成科学研究科 理学専攻 情報科学コース
Advanced Sciences, Graduate School of Humanities and Sciences, Ochanomizu University

*2お茶の水女子大学 基幹研究院 自然科学系
Advanced Sciences, Graduate School of Humanities and Sciences, Ochanomizu University

In this study, we analyze the behavior of the computational mechanism and the structure of the feature representation space in a deep neural text-to-image generative model. This is a fundamental approach with a goal to construct artificial general intelligence reflecting the mechanism of human intelligence. First, we explore whether the model is capable of encoding captions and of generating valid images under the circumstance given input captions without word boundaries. Qualitative and quantitative evaluations demonstrate that it can generate compelling images, but the computational mechanism does not acquire the units of meaning. Secondly, we analyze the semantic compositionality in the embedding space. Our experimental result suggests that the semantic compositionality appears between words indicating positions.

1. はじめに

近年，汎用人工知能の構築を目指して，ヒトの知能に関する知見を取り入れた人工神経回路網の研究が盛んに行われている [Cox 14, Lotter 17]．また，機械学習モジュールが自然言語の意味を理解することを，自然言語から画像へのグラウンディングができることとして捉え，自然言語の意味理解，ひいては自然言語からの概念の獲得を目指して，自然言語で記述されたキャプションを入力とする画像生成モデルの提案が数多くなされている [Mansimov 16, Xu 18, Zhang 18]．一方で，深層学習分野での研究成果は経験的な成果として示されることが多く，モデルの計算機構の挙動や特徴表現空間の構造についての分析はあまり行われていない．

本研究では，ヒトの知能のメカニズムを模倣して構築された，キャプションを入力とする画像生成モデルを対象に，入力の粒度を変更した際の計算機構の挙動や，特徴表現空間の構造を，ヒトの知能との親和性の観点から分析する．

2. alignDRAW

Mansimov ら [Mansimov 16] は，ヒトが絵を描く際の,「特定の言語表現に着目してそれに対応する部分を描く」というプロセスの反復を，深層学習の枠組みで実現することを意図して構築した画像生成モデル alignDRAW を提案している．このモデルは，Variational AutoEncoder[Kingma 14a] を拡張し，生成画像の段階的な高精細化および空間的注意を導入した画像生成モデル Deep Recurrent Attentive Writer(DRAW)[Gregor 15] を，キャプションで条件付けて画像生成できるようにした Encoder-Decoder モデルである．alignDRAW は，単語単位のキャプションを入力にとり，双方向 LSTM[Hochreiter 97] で構成される言語エンコーダで処理を行った後，DRAW を画像デコーダとして，attention mechanism[Bahdanau 15] と合わせて用いることにより，反復的に画像生成を行う．alignDRAW の概要図を図 1 に示す．

連絡先: 藤山千紘，お茶の水女子大学，〒 112-8610 東京都文京区大塚 2-1-1，fujiyama.chihiro@is.ocha.ac.jp

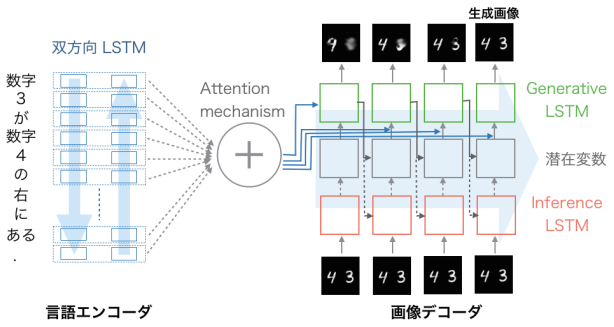


図 1: alignDRAW 概要図

3. 提案手法

3.1 alignDRAW を用いた単語分割タスクを含む画像生成

先行研究 [Mansimov 16] では，単語分割済みのキャプションから画像生成を行っているが，本手法では入力を単語分割されていないキャプションに変更し，単語の境界情報が失われた，すなわち意味の単位の情報が欠落した場合の alignDRAW の言語エンコード能力および画像生成能力を評価する．具体的には，単語分割されていないキャプションに対して，妥当な画像を生成し得るか，またその際の attention mechanism の挙動が言語の意味の単位を表現しているかを考察する．

3.2 alignDRAW における言語の意味の構成的特性の分析

本手法では，モデルの特徴表現空間において言語の意味の構成的特性が表現されるかを評価する．先行研究 [Mansimov 16] では，キャプションに含まれる各単語を one-hot ベクトルとして双方向 LSTM に入力しているが，本手法では各単語を分散表現に埋め込んだ後，双方向 LSTM に入力するよう，埋め込み層を追加する形でモデルの拡張を行う．モデルは単語分割済みのキャプションを用いて学習し，埋め込み層の分散表現について，単語の意味の構成的特性を分析する．

4. 実験

4.1 実験設定

データセットは，表 1 に示すテンプレートと手書き数字画像のデータセット MNIST[*1] を用いて作成した．キャプションはプレースホルダーを含むテンプレートを各実験 8 種類用意し，MNIST から無作為に抽出した画像および正解ラベルの組のうちラベル情報を埋め込む形で作成した．画像は，ラベルと対応する MNIST 画像をキャプション内容に適合する領域に，無作為に 4 ピクセルのゆらぎを持たせて配置した 60×60 ピクセルのグレースケールの画像とした．両実験ともに，学習データ 40,000 事例，開発データ 4,000 事例，評価データ 4,000 事例を用いた．モデルの実装には深層学習のフレームワーク TensorFlow[*2] を用い，学習は各実験，表 2 の設定で行った．

表 1: キャプション作成時のテンプレート

単語分割タスクを含む画像生成	構成的特性の分析
すうじ＿がすうじ＿のひだりにある．	数字 ＿ が画像の左にある．
すうじ＿がすうじ＿のみぎにある．	数字 ＿ が画像の右にある．
すうじ＿がすうじ＿のうえにある．	数字 ＿ が画像の上にある．
すうじ＿がすうじ＿のしたにある．	数字 ＿ が画像の下にある．
すうじ＿がぞうのひだりうえにある．	数字 ＿ が画像の左上にある．
すうじ＿がぞうのひだりしたにある．	数字 ＿ が画像の左下にある．
すうじ＿がぞうのみぎしたにある．	数字 ＿ が画像の右下にある．
すうじ＿がぞうのみぎうえにある．	数字 ＿ が画像の右上にある．

表 2: alignDRAW 学習時のハイパーパラメータ

	単語分割タスクを含む画像生成	構成的特性の分析
入力語彙サイズ	33	28
言語エンコーダ	one-hot ベクトル → 128 ユニット双方向 LSTM	32 次元分散表現 → 128 ユニット双方向 LSTM
attention mechanism	512 ユニット Bahdanau Attention	256 ユニット Bahdanau Attention
デコーダ	300 ユニット DRAW LSTM	
描画反復回数	32 ステップ	
潜在変数 z	150 次元	
最適化アルゴリズム	RMSProp [Tieleman 12]	
学習率	初期学習率: 0.001 110 エポック以降 0.0001 に減衰	初期学習率: 0.001 75 エポック以降 15 エポック毎に 0.5 倍
パラメータ初期値	平均: 0, 分散: 0.1 の正規分布乱数	
学習エポック数	200	150

生成画像の定量評価としては，生成された画像を入力キャプション毎に分類する分類器を用い，弁別性の自動評価を行った．分類器の学習は alignDRAW の学習に用いたデータセットと同一のデータセット上で行い，ハイパーパラメータは表 3 に示す設定とした．なお，キャプションは単語分割タスクを含む画像生成で 440 種類，構成的特性の分析で 80 種類であるので，各々440 クラス分類，80 クラス分類となる．

表 3: 定量評価のための分類器学習時のハイパーパラメータ (両実験とも共通)

アーキテクチャ	(CNN+最大値プーリング) × 4 層 + 全結合 × 1 層
畳み込みに関する設定	フィルタサイズ: 5 × 5 (全層) チャネル数: 入力層から順に 32, 64, 128, 256 0 パディング ストライド: 1
全結合層	1024 ユニット
活性化関数	ReLU 関数
損失関数	交差エントロピー損失
勾配クリッピング	[-10.0, 10.0]
最適化アルゴリズム	Adam [Kingma 14b]
初期学習率	0.0001
パラメータ初期値	平均: 0, 標準偏差: 0.1 の $\pm 2\sigma$ の切断正規分布乱数
学習エポック数	100

*1 http://yann.lecun.com/exdb/mnist/
*2 https://www.tensorflow.org/

4.2 単語分割タスクを含む画像生成

単語分割されていないキャプションからの生成画像例を図 2 に示す．単語分割済みのキャプションからの画像生成と比較して，単語の境界情報が失われている，つまり意味の単位の情報が欠落している点で，画像生成タスクとしてはより困難になっていると考えられるが，生成結果からキャプション内容に適合する画像を生成できていることが確認できる．



図 2: 単語分割されていないキャプションからの生成画像例

分類における評価データ上での正解率と alignDRAW による生成画像データ上での正解率を表 4 に示す．生成画像データ上での正解率が評価データ上での正解率を上回っており，alignDRAW によって生成された画像がどのキャプションに由来するかを十分に識別できる質を達成できていることが分かる．これは，生成モデル学習の結果，データセットに存在するノイズや手書き文字の個人差が吸収され，正規化された数字を生成できるようになったためと考えられる．

表 4: 評価データおよび alignDRAW による生成画像データ上での分類正解率

評価データ	生成画像データ
0.719	0.737

またテンプレートに従わないキャプションからの生成画像例を図 3 に示す．テンプレートに含まれるキャプションからの生成結果 (図 2) と比較して，描かれる数字の質が劣化している事例が見受けられるが，おおよそキャプション内容に適合する画像を生成できており，「すうじ」という言語表現の省略や主語の位置変更に対して，モデルがある程度頑健に動作していることが認められる．

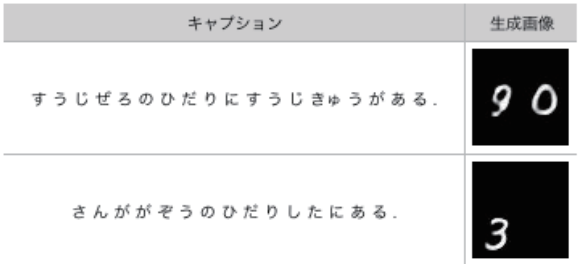


図 3: テンプレートに従わないキャプションを入力とする生成画像例

続いて，画像を生成する際の attention mechanism の挙動を図 4 に示す．図 4 上段については，「いち」という言語表現付近に attention が当たっているときに画像空間上で 1 に相当する部分の生成が進んでおり，続いて数字 2 を表す「に」という言語表現付近に attention が移って画像空間での 2 に相当する

部分の鮮明化が進んでいる様子が見てとれる．2 箇所のプレースホルダーを持つテンプレートに由来するキャプションでは，一方の数字のアイデンティティを示す言語表現およびその周囲に attention が当たっているときにそれに対応する部分が画像空間で鮮明化し，attention が他方の数字に移ると生成部位も移るという傾向が共通して見られ，数字のアイデンティティを特定する言語表現と画像空間での表現に大まかな対応がとれていることが確認された．一方で，この場合には空間を表す言語表現についてはほとんど attention が当たっていなかった．また図 4 下段については，生成画像には 3 を描くことができているが，数字のアイデンティティを表現する「さん」にはほとんど attention が当たっていない．この傾向はプレースホルダーが 1 箇所のみのテンプレートに由来するキャプションに共通して見られ，数字のアイデンティティを表す言語表現と画像空間での表現に対応関係が認められなかった．

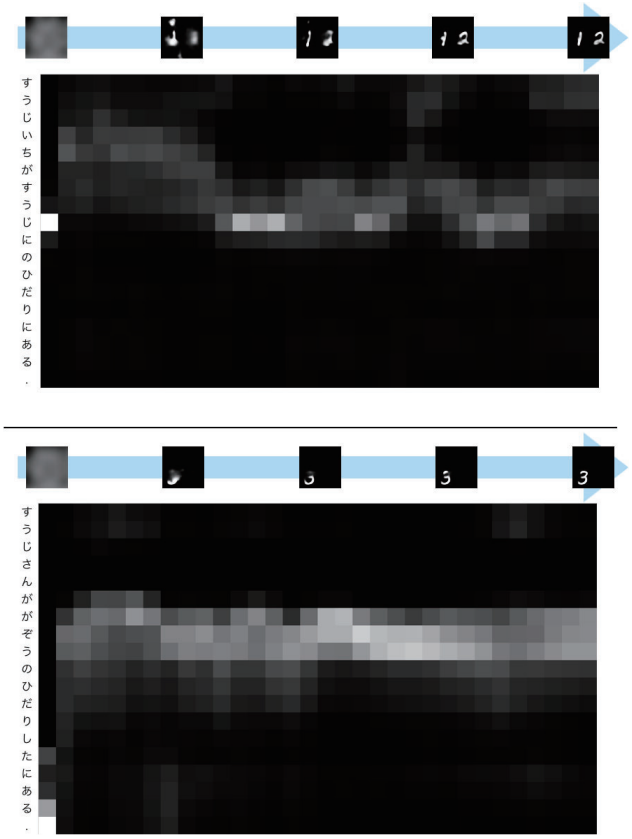


図 4: attention mechanism の挙動：左に入力キャプション，上に画像の生成過程 (左から t=0, 7, 15, 23, 31) を示す．

単語分割されていないキャプションから妥当な画像を生成できたことから，attention mechanism の挙動が意味の単位を表現していることが期待されたが，図 4 のように，本設定下ではそのような傾向は見られなかった．これは，言語エンコーダとして用いた双方向 LSTM の表現能力が高いことが一因であると考えられるため，言語エンコーダを簡素化した追加実験を行って分析を加える．本稿では系列処理を行わず，one-hot ベクトルを直接 attention mechanism の入力として画像生成を行った場合について述べる．なおこの場合，系列処理を行わないため入力の各文字は集合として扱われ，並びの順序は無視される．したがって，キャプション内の主体と対象の関係を画像空間上に適切に反映させ得ない場合があることが想定される．

キャプションの系列処理を行わない場合の生成画像例を図 5 に示す．図 5 上段のように妥当な画像を生成できる場合もある一方で，下段のように位置関係が反転する事例があることが確認された．キャプションを系列処理しなかった場合の attention mechanism の挙動を図 6 に示す．系列処理を行わない，つまりキャプションを文字の集合として扱った場合には，数字のアイデンティティと描画位置を一意に特定するために必要な言語表現に attention が集中する傾向があったが，これは必ずしも単語単位での表現とは一致しないため，attention mechanism の挙動が意味の単位を表現している様子は見られなかった．一方で，双方向 LSTM を用いた場合と比較すると，数字のアイデンティティや空間を表す言語表現の一部に確実に attention が当たっていることが確認できた．



図 5: キャプションを系列処理しない場合の生成画像例

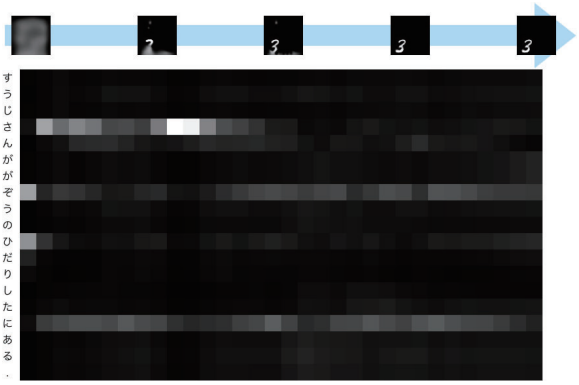


図 6: キャプションを系列処理しない場合の attention mechanism の挙動：左に入力キャプション，上に画像の生成過程 (左から t=0, 7, 15, 23, 31) を示す．

alignDRAW では画像生成過程に数字を描く順序の制約がなく自由度が高いため，このことに起因して attention の学習が困難である．また現在のモデルには，言語表現の連続したセグメントが意味の単位となり得るという情報が一切与えられていないため，attention mechanism の挙動で言語の意味の単位を表現することが困難であったと考えられる．attention mechanism で意味の単位を捉えつつ，ヒトが絵を描く過程を計算機構に反映して画像生成を行うためには，損失関数の検討を含めてモデルの拡張が必要であると考えられ，これは今後の課題の一つである．

4.3 言語の意味の構成的特性の分析

学習したモデルを用いた生成画像の例を図 7 に示す．本実験においても，キャプション内容に適合する画像が生成されていることが確認できる．

分類における評価データ上での正解率と alignDRAW による生成画像データ上での正解率を表 5 に示す．本実験では，生成画像データ上での正解率が評価データ上での正解率を下回る結果となり，学習した生成モデルがデータセットの分布を同質といえる程には近似できていなかったことが分かる．図 8 に



図 7: 構成的特性の分析を目的とした実験での生成画像例

正しく分類できなかった事例を示す．間違って分類された生成画像は，入力キャプションに含まれる数字のアイデンティティを正しく画像内に表現できていない事例が多かった．本分析では空間を意味する言語表現に着目するため，数字が描かれる位置のみを分類する，すなわち数字のアイデンティティの区別を分類の対象としない 8 クラス分類を表 3 の設定で学習した結果，評価データ上，生成画像データ上ともに分類正解率が 1.00 となり，数字を描く位置を間違えた事例はなかったと推測される．

表 5: 評価データおよび alignDRAW による生成画像データ上での分類正解率

評価データ	生成画像データ
0.985	0.882

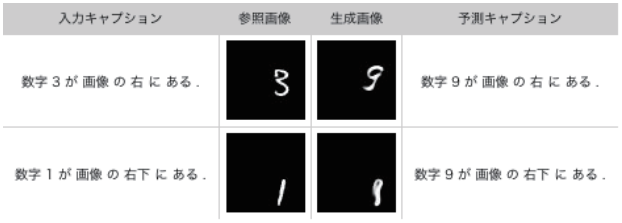


図 8: 正しく分類できなかった生成画像の例：左から生成モデルへの入力キャプション，参照画像，生成画像，分類器によって予測されたキャプションを示す．

言語の意味の構成的特性の分析では，キャプションに含まれる空間を意味する単語「左」「右」「上」「下」「左上」「左下」「右下」「右上」の 8 単語を対象とした．我々は例えば「左上」を，意味的に「左」と「上」を足したものとして解釈していると考えられる．この加法構成性を，埋め込み層の分散表現において獲得できるかを評価するため，まず学習された分散表現のうち「左」「右」「上」「下」に対応するものの和をとり，各々「左上」「左下」「右下」「右上」の推定分散表現を作成した．例えば，「左上」の推定分散表現は，「左」と「上」それぞれに対応する実分散表現の和として構成した．このようにして推定した分散表現に対して，学習で得た実分散表現それぞれとの cos 類似度を算出した結果を表 6 に示す．また，各推定分散表現と cos 類似度が高かった分散表現に対応する単語上位 5 件を表 7 に示す．本設定下では，「右上」以外の 3 単語については高い cos 類似度が得られ，表 7 においても推定分散表現と実分散表現が比較的近くに確認されることから，埋め込み空間において言語の意味の構成的特性が表現される可能性を示唆する結果を得たと言える．

表 6: 推定分散表現と実分散表現の cos 類似度

	左上	左下	右下	右上
cos 類似度	0.89	0.80	0.92	0.29

表 7: 推定分散表現との cos 類似度が高い分散表現上位 5 件

	左上	左下	右下	右上
1	左上	左	右	右
2	上	左上	1	1
3	左	左下	右下	右下
4	0	0	の	の
5	2	2	7	4

5. おわりに

本研究では，キャプションからの画像生成モデルについて，計算機構の挙動や特徴表現空間の構造の分析を行った．入力のキャプションをヒトが言語を獲得する過程を一段階遡る形で，単語分割されたキャプションから単語の境界情報の欠落したキャプションに変更した場合には，定性的にも定量的にもキャプション内容に適合する画像を生成するモデルを学習できた．しかし，その際の attention mechanism の挙動において意味の単位を獲得している様子は確認されなかった．また，特徴表現空間における言語の意味の構成的特性の分析については，埋め込み空間の分散表現について空間を意味する単語間で，意味の加法構成性を得られる可能性を示唆する結果を得た．

今後の課題としては，より精緻な分析を行うことや，ヒトの知能のメカニズムを反映して動作する生成モデルの構築が挙げられる．

参考文献

[Bahdanau 15] D. Bahdanau, K. Cho, and Y. Bengio, “Neural machine translation by jointly learning to align and translate.”, In ICLR, 2015.

[Cox 14] D. D., Cox, and T., Dean, “Neural networks and neuroscience-inspired computer vision.”, Current Biology, 24(18), R921-R929, 2014.

[Gregor 15] K. Gregor, I. Danihelka, A. Graves, D. J. Rezende, and D. Wierstra, “DRAW: A recurrent neural network for image generation.”, In ICML, 2015.

[Hochreiter 97] S. Hochreiter, and J. Schmidhuber, “Long short-term memory.”, Neural Computation, 9(8), pp. 1735-1780, 1997.

[Kingma 14a] D. P., Kingma, and M., Welling, “Auto-encoding variational bayes.”, In ICLR, 2014.

[Kingma 14b] D. P., Kingma, and J., Ba, “Adam: A method for stochastic optimization.”, arXiv preprint arXiv:1412.6980, 2014.

[Lotter 17] W., Lotter, G., Kreiman, and D., Cox, “Deep predictive coding networks for video prediction and unsupervised learning.”, In ICLR, 2017.

[Mansimov 16] E. Mansimov, E. Parisotto, J. L. Ba., and R. Salakhutdinov, “Generating images from captions with attention.”, In ICLR, 2016.

[Tieleman 12] T., Tieleman, and G., Hinton, Lecture 6.5-RMSProp, COURSERA: Neural Networks for Machine Learning. University of Toronto, Tech. Rep, 2012.

[Xu 18] T., Xu, P., Zhang, Q., Huang, H., Zhang, Z., Gan, X., Huang, and X., He, “Attngan: Fine-grained text to image generation with attentional generative adversarial networks.”, In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (pp. 1316-1324), 2018.

[Zhang 18] Z., Zhang, Y., Xie, and L., Yang, “Photographic text-to-image synthesis with a hierarchically-nested adversarial network.”, In The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

テキスト情報と画像情報を組み合わせた論理推論システムの構築

Towards Building a Logical Inference System for Text and Visual Information

鈴木 莉子 *1 Riko Suzuki　吉川 将司 *2 Masashi Yoshikawa　谷中 瞳 *3 Hitomi Yanaka　峯島 宏次 *1 Koji Mineshima　戸次 大介 *1 Daisuke Bekki

*1お茶の水女子大学 Ochanomizu University　*2奈良先端科学技術大学院大学 Nara Institute of Science and Technology　*3理化学研究所 AIP センター RIKEN Center for Advanced Intelligence Project

A large amount of research about multimodal inference across natural language and vision has been recently developed to obtain visually grounded word and sentence representations. In this paper, we use logic-based representations as unified meaning representations for texts and images and present an unsupervised inference system that can effectively prove entailment relations between them. We show that by combining semantic parsing and theorem proving, the system can handle semantically complex queries for image retrieval.

1. 本研究の背景と目的

画像、音声、テキスト等の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の推論によって新たな知識を獲得するマルチモーダル推論に関する研究が近年盛んになっている。特にテキストと画像の情報を組み合わせた推論タスクとして、画像間の含意関係を推論する Visual Entailment Task [15] や、与えられた画像とその内容に関する質問に答える Visual Question Answering [14]、画像中の物体の数量に関する複雑な質問に答える Tally QA [7] 等が存在する。

高度なマルチモーダル推論を実現するには、テキスト化された知識と画像に含まれる情報を接合する枠組みが必要である。具体例として次の画像とキャプションについて考えてみよう。



・The man is performing an accordion.
・The woman wears a pink dress.
・There is not a green parasol.

図 1: 画像とキャプションの例

この例では、「男性が女性の隣にいる」という情報は画像からしか獲得することができず、「男性がアコーディオンを演奏している」という情報はキャプションにしか書かれていない。しかし、キャプションからの情報と画像からの情報とを組み合わせることができれば、*The man playing an accordion is next to a woman.* といった新しい知識を獲得できる。

形式意味論に基づく論理的意味表現は、表現同士の推論が可能であり、含意関係認識のタスクにおいて高精度を達成しつつある [9, 3]。画像情報を自然言語の意味表現と接続可能な形式で表すことができれば、自然言語テキスト間の推論と同様の推論を、テキストデータと画像情報の間で行うことができる。

自然言語の意味表現を介してテキストデータと画像を接続することは、高精度な物体関係検出・物体検出の研究の進展と、Visual Genome [10] のような画像とテキストの統合的な大規模データセットの登場により、現実的に可能になりつつある。既存の画像中の物体とその属性、また物体間の関係を表す手法としては、グラフ表現を用いる Scene Graph が提案されている [8]。しかし、一般にグラフ表現では物体間の属性や関係に加えて、数量表現や否定といった意味的に複雑な文の意味を統一的に扱うことは困難である。そのため、グラフ表現よりも表現力の高い意味表現で画像情報を表現する手法が求められる。

[17] では、文と画像の情報を一階述語論理 (FOL) のモデルと論理式を用いて表現し、数量や否定を含む複雑な言語現象を伴う文を画像から推論するシステムを提案した。本論文では、(1) FOL モデルを論理式に変換する方法の改良、(2) キャプションの情報と画像情報の合成という 2 点に着目して、より意味的に複雑な文の処理や効率的な論理推論にも対応可能な推論システムの構築を目指す。文と画像を論理式によって統一的に表現することで、意味表現の評価は、画像情報とキャプションを表す論理式とキャプションを表す論理式間の含意関係認識のタスクの評価に帰着させることができる。評価実験により、本研究が提案する論理式による文と画像の意味表現が複雑な言語現象を伴う推論を正確かつ効率的に行うことが可能であることを示す。

2. 文と画像の意味表現

本研究では、属性・関係表現、数量表現、論理表現を伴う意味的に複雑な推論を扱うために、文と画像の意味表現として等号付き一階述語論理 (FOL) のモデルと論理式を用いる。以下で文と画像の意味表現について順に説明する。

2.1 文の意味表現

本研究では自然言語文から FOL 論理式への変換に組合せ範疇文法 (Combinatory Categorial Grammar, CCG) [5, 16] に基づく意味解析・推論システム ccg2lambda [9, 11][*1] を用いる。ccg2lambda は自然言語推論のための高階論理をサポートし、前提文から仮説文を自動推論する含意関係認識システムであるが、本研究では意味表現を FOL 論理式に制限し、また文から論理式への意味解析部のみを使用する。特に、FOL による数量表現の扱いや *part of* のような複合語の処理など意味解析の拡張を行っている。詳細は [17] を参照されたい。

2.2 一階述語論理のモデルによる画像の表現

論理推論に使うことができる画像情報の意味表現としては、一階述語論理のモデル（FOL モデル）を用いる手法がある [4]。FOL モデル $\mathcal{M}$ は、ドメイン D と解釈関数 I から定義される。ドメインは空でない集合であり、画像中に存在するエンティティの情報を表す。解釈関数は各 n 項述語を D^n の部分集合に対応づける関数であり、ドメイン中のエンティティがもつ属性と関係を表現する。例えば、図 1 の画像情報は、

- ドメイン $D = \{d_1, d_2, d_3, \ldots\}$
- 属性 $I(\mathsf{man}) = \{d_1\}$, $I(\mathsf{woman}) = \{d_2\}$, $I(\mathsf{accordion}) = \{d_3\}, \ldots$
- 関係 $I(\mathsf{play}) = \{(d_1, d_3)\}, \ldots$

*1 https://github.com/mynlp/ccg2lambda

からなるモデル $\mathcal{M} = (D, I)$ によって表現することができる [*2]。

画像情報を FOL モデルとして表現し、保持することには少なくとも 2 つの利点がある。第一に、FOL モデルによる画像情報の表現は、エンティティ・属性・関係からなるグラフによる画像の意味表現 [8, 13] と明確な対応をもち、グラフがアノテートされた大規模データセット [12] から抽出することが可能である。第二に、自然言語文 S を論理式 A に対応付けることができれば、画像を表すモデル $\mathcal{M}$ と論理式 A との間の充足関係 $\mathcal{M} \models A$ をモデル検査 [2] によりチェックすることで画像と文との対応関係を効率的に調べることができる。

2.3 論理式による画像の表現

画像と文間の含意関係だけでなく、画像と文から得られる情報を組み合わせて別の文を推論し、新たな知識を獲得するというハイブリッドな推論を実現するためには、画像とテキストが表す意味情報を何らかの仕方で結合する必要がある。そこで、画像情報を担う FOL モデルを論理式に変換し、意味的に複雑な文の処理や論理推論にも対応可能な推論システムの構築を目指す。具体的には、(i) FOL モデルを論理式に変換する方法、及び、(ii) 文を論理式に変換した後、その論理式の情報を FOL モデルに変換する方法の 2 つを検討する。以下では (i) の方法について詳述し、2.4 節では (ii) の方法について説明する。

FOL モデルを論理式に変換する方法は、(1) ドメインの変換と (2) 解釈関数の変換の 2 つのパートからなる。

(1) ドメインから論理式への変換

モデルでは、「そのドメインにはそこで記述されたエンティティ以外は存在しない」という否定的な情報が含まれる。この情報は、ドメイン $D = \{d_1, \ldots, d_n\}$ を (N1) のように原子論理式の連言に変換することで捉えることはできない。

(N1) $\mathsf{entity}(d_1) \wedge \cdots \wedge \mathsf{entity}(d_n)$

一方、D を (C1) のように変換することで「エンティティは $d_1, \ldots, d_n$ しかない」という情報が含まれるようになる。

(C1) $\forall x(\mathsf{entity}(x) \leftrightarrow x = d_1 \vee \cdots \vee x = d_n)$

(2) 解釈関数から論理式への翻訳

次に、解釈関数を論理式に変換する。ドメインの場合と同様に、例えば、$I(\mathsf{cat}) = \{d_1\}$ を $\mathsf{cat}(d_1)$ に変換するだけでは、「d_1 だけが猫である」という否定的な情報を表すことができず、そのためには、$\forall x(\mathsf{cat}(x) \leftrightarrow x = d_1)$ という複雑な翻訳が必要となる。一般に F を属性を表す 1 項述語とすると、$I(F) = \{d_1, \ldots, d_n\}$ のとき、単純な翻訳 (N2) と複雑な翻訳 (C2) の二通りの翻訳を検討する。

(N2) $F(d_1) \wedge \cdots \wedge F(d_n)$

(C2) $\forall x.(F(x) \leftrightarrow x = d_1 \vee \cdots \vee x = d_n)$

同様に関係を表す 2 項述語 R に対しても、$I(R) = \{(d_1, e_1), \ldots (d_n, e_n)\}$ のとき、以下の二通りの変換が考えられる。

(N3) $R(d_1, e_1) \wedge \cdots \wedge R(d_n, e_n)$

(C3) $\forall x \forall y(R(x, y) \leftrightarrow (x = d_1 \wedge y = e_1) \vee \cdots \vee (x = d_n \wedge y = e_n))$

以上の否定的な情報を扱う (C1)–(C3) の翻訳は、述語サーカムスクリプション (Predicate Circumscription)[6] の一種とみなせる。これは一般に、画像が伝える情報には、「〜だけがその属性（関係）を満たす」といったドメイン・属性・関係の網羅性 (exhaustivity) にかかわる情報が含まれているためである。サーカムスクリプションに基づく論理式への変換により、この情報を明示的に扱うことで、否定や選言など不確定な情報を伴う文と組み合わせた論理推論が可能になる。

*2 画像情報であるため、論理式に名前は現れないと仮定している。また、以下では $I(\mathsf{cat}) = \{d_1\}$ を $(\mathsf{cat}, \{d_1\}) \in I$ とも書く。

1. A が等式以外の原子論理式のとき、$A \in \mathcal{P}$, $\neg A \in \mathcal{N}$.
2. A が等式のとき、A, $\neg A \in \mathcal{P}$.
3. $A \in \mathcal{P}$ かつ $B \in \mathcal{P}$ のとき、$A \wedge B$, $A \vee B \in \mathcal{P}$.
4. $A \in \mathcal{N}$ または $B \in \mathcal{N}$ のとき、$A \wedge B$, $A \vee B \in \mathcal{N}$.
5. $A \in \mathcal{N}$ かつ $B \in \mathcal{P}$ のとき、$A \to B \in \mathcal{P}$.
6. $A \in \mathcal{P}$ または $B \in \mathcal{N}$ のとき、$A \to B \in \mathcal{N}$.
7. $A \in \mathcal{P}$ のとき、$\forall x A$, $\exists x A \in \mathcal{P}$.
8. $A \in \mathcal{N}$ のとき、$\forall x A$, $\exists x A \in \mathcal{N}$.

表 1: 正の論理式 ($\mathcal{P}$) と負の論理式 ($\mathcal{N}$)

ただし、(C1)–(C3) は複雑な論理式を伴うため、推論において計算コストを要する。そこで、本研究が提案するシステムでは、推論の結論に現れる論理式に応じて、二種類の翻訳を使い分ける。以下で定義する正 (positive) の論理式に対しては単純な (N1)–(N3) の翻訳を、負 (negative) の論理式に対しては、サーカムスクリプションに基づく (C1)–(C3) の翻訳を用いる。

表 1 の規則によって、各 FOL 論理式 $A \in \mathcal{L}$ を正と負の論理式に分類する。FOL 論理式の集合を $\mathcal{L}$、正の論理式の集合を $\mathcal{P}$、負の論理式の集合を $\mathcal{N}$ とすると、この定義により、$\mathcal{L}$ は $\mathcal{P}$ と $\mathcal{N}$ に分割されることがわかる。例えば、*A cat touches a dog.* と *There are two cats.* にそれぞれ対応する $\exists x \exists y\,(\mathsf{cat}(x) \wedge \mathsf{dog} \wedge \mathsf{touch}(x, y))$ と $\exists x \exists y\,(\mathsf{cat}(x) \wedge \mathsf{cat}(x) \wedge x \neq y)$ は正の論理式であり、*No cats are white.* と *All cats are white.* にそれぞれ対応する $\neg \exists x\,(\mathsf{cat}(x) \wedge \mathsf{white}(x))$ と $\forall x\,(\mathsf{cat}(x) \to \mathsf{white}(x))$ は負の論理式である。

2.4 キャプションの利用

画像の内容を表すキャプションには、視覚・空間情報だけでは判断が難しい物体の状態も記述されている。一方で、文だけでは画像の部分的な情報しか記述できず、画像に含まれる情報を網羅的に記述することは難しい。そこで、キャプションの意味情報を取り出し、FOL モデルに変換することで画像情報を拡充することを試みる。FOL モデルにキャプション情報を集約することで、物体の同一性・網羅性を反映した意味表現が得られると考えられる。

ここでは、特に存在量化と連言からなる論理式に翻訳可能なキャプションを FOL モデルに変換する方法について概略を述べる。否定的情報を含む *All men are wearing caps.* のような全称文や *There are no white mice.* のような否定文は、FOL モデルに変換せず、論理式として保持する。

キャプションから論理式への変換：まず、ccg2lambda を用いてキャプションを論理式に変換する。ccg2lambda により生成された CCG の導出木から各単語の品詞の情報を取得し、文とその単語の品詞の情報から、WordNet [1] の synset を参照して、単語の意味の曖昧性解消を行う。

モデルとキャプションの対応づけ：画像から抽出された FOL モデルにキャプションの情報を追加するには、キャプションの表現が画像中のどの物体を指しているか、その指示関係を決定する必要がある。ここでは、指示関係が一意に定まる場合にのみ新しい述語をモデルに追加する方法について述べる。以下では、(1) 新たなエンティティを導入する、(2) エンティティの状態・属性を導入する、(3) エンティティ間の関係を導入する、という 3 つのケースに分けて、具体例に基づいて説明する。

(1) エンティティの導入 キャプションが画像情報のドメイン中に含まれない新しいエンティティを導入する場合、そのエンティティをドメインに追加する。その際、キャプションに含まれる述語、またはその類義語・下位語がモデルに含まれる場合に対応する述語を解釈関数に加える。

具体例を (1) に示す。画像情報として (1a) のモデル $\mathcal{M} = (D, I)$ が与えられたとき、(1b) の論理式によって、$\mathcal{M}$ は (1c)

のモデル $\mathcal{M}' = (D', I')$ に更新される。

(1) a. $D = \{d_1, d_2\}, I = \{(\mathsf{man}, \{d_1\}), (\mathsf{street}\ \{d_2\})\}$
b. A man is playing music in the street.
$\exists x \exists y \exists z(\mathsf{man}(x) \wedge \mathsf{street}(y) \wedge \mathsf{in}(x, y) \wedge \mathsf{music}(z) \wedge \mathsf{play}(x, z))$
c. $D' := D \cup \{d_3\}, I' := I \cup \{(\mathsf{music}, \{d_3\})\}$

この例では music についてモデル $\mathcal{M}$ には記述されていないため、d_3 という新たなエンティティを割り当てる。一般に視覚的な属性は画像から抽出しやすく、非視覚的（内包的）な属性はキャプションから抽出しやすい。画像とキャプションによりモデルを構築することで、視覚的な属性と非視覚的な属性をどちらも記述することが可能となる。

(2) 属性・状態の導入 以下の (2a) のモデルでは、ドメインに 1 匹の猫が存在し、(2b) のキャプションは 1 匹の猫は白いという情報をもつ。この場合、(2c) のようにモデルを更新する。

(2) a. $D = \{d_1\}, I = \{(\mathsf{cat}, \{d_1\})\}$
b. *A cat is white.*
$\exists x(\mathsf{cat}(x) \wedge \mathsf{white}(x))$
c. $D' := D, I' := I \cup \{(\mathsf{white}, \{d_1\})\}$

猫が複数いる場合、同様の更新を行うことはできない。以下の例では、キャプションは「1 匹の猫は白い」という意味であるにもかかわらず、(3c) のモデルでは「全ての猫は白い」という情報が更新されており、不適切である。

(3) a. $D = \{d_1, d_2, d_3\}, I = \{(\mathsf{cat}, \{d_1\})\}$
b. *A cat is white.*
$\exists x(\mathsf{cat}(x) \wedge \mathsf{white}(x))$
c. $D' := D, I' := I \cup \{(\mathsf{white}, \{d_1, d_2, d_3\})\}$

(3) 関係の導入 キャプションが物体間の関係を表す 2 項述語を含む場合、その項となるエンティティがモデル中で一意に定まる場合はモデルを更新する。

(4) a. $D = \{d_1, d_2\}, I = \{(\mathsf{man}, \{d_1\}), (\mathsf{guitar}, \{d_2\})\}$
b. *A man is playing a guitar.*
$\exists x \exists y(\mathsf{man}(x) \wedge \mathsf{guitar}(y) \wedge \mathsf{play}(x, y))$
c. $D' := D, I' := I \cup \{(\mathsf{play}, \{(d_1, d_2)\})\}$

2 つの物体が一意に決まらない場合は WordNet を用いて、キャプションに現れた述語の上位語・下位語の情報を補完する関係のアブダクション [17] を行い、空間情報をもとにモデルへの 2 項述語の追加を行う。

3. 評価実験

3.1 実験設定

本研究では画像に対し、モデル、キャプション 2 文（画像に対し真、偽となる文）を付与した GRIM データセット [4] を実験に用いる。GRIM におけるモデルには物体、属性、物体間の空間情報が記述されており、空間情報を表すために touch、near、support、occlude、part_of の 5 つの関係が用いられている（図 2）。本研究では、GRIM のデータ 200 件のうち、ノイズを含む 6 件を除く 194 件を用いて実験を行う。

モデルや文から論理式への変換法、また実験設定は基本的に [17] に従う。研究 [17] では、複雑な言語現象を含む 19 文に対し、GRIM 上の画像からそれらの文が含意するか否かの情報を付与している。扱われている言語現象として、論理結合子、数詞、量化詞、空間関係の分類が設けられており、評価実験では、画像（に対応する論理式）と文（に対応する論理式）間の含意関係を判定することにより、正解画像の検索能力を F 値で報告している。表 2 に文の例と言語現象の分類を示す。本研究でも同様に、言語現象の分類に基づき F 値を報告する。本研究では研究 [17] の手法を基に、2. 節で提案したモデルの変換方法（サーカムスクリプション）や画像に付与されたキャプション情報を用いた拡張を行った場合の性能改善を評価する。

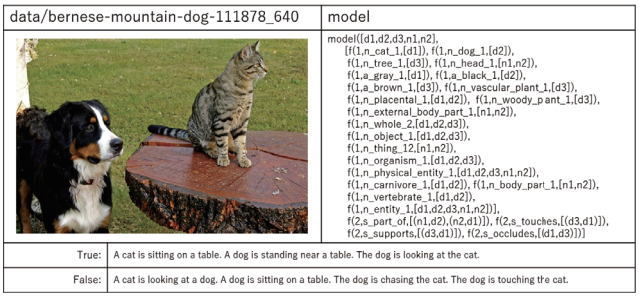


図 2: GRIM のデータ例

3.1.1 サーカムスクリプションによる解析性能の評価

2. 節で述べたサーカムスクリプションを用いて GRIM 上のモデルを論理式に変換した場合における、画像検索の精度と速度を評価する。既存研究と同様に F 値と、定理証明にかかった平均時間（秒）を報告する。

また、このときに定理証明器の選択による検索性能への影響を評価する。ベースラインとして [17] 同様に、自動証明器に Prover9[*3] を用いるが、本研究ではそれに加え、入力の定理に対する反例を探索する Mace4[*3] を同時に実行する場合を評価する。定理によっては反例を見つけるほうが容易であり、Mace4 を用いることで、画像と文が関係ない場合を高速に判断できる。本研究ではまた、高速さで知られる Vampire[*4] を用いた場合の性能も報告する。Vampire 内部では、定理証明と反例の探索が同時に行われる。

3.1.2 キャプションからモデルへの変換の評価

キャプションから FOL モデルへの変換の正しさを、GRIM のキャプションを用いた含意関係認識を行うことで評価する。具体的には、GRIM の画像に付与されている 2 つのキャプションのうち、真となる文のみを用いてモデルを拡張し、拡張されたモデルから 2 つのキャプションに対応する論理式への含意関係が成り立つかを調べ、F 値を算出する。

本研究ではさらに、キャプション情報の有用性を検証するため、3.1.1 節の実験と同様に画像検索の実験を行う。具体的に、研究 [17] 同様に、表 2 下のような文を人手で 8 件作成し、それらに対して GRIM データセットの 200 件の画像がそれぞれ含意するかをアノテートした。この新たに作成したデータセットを用いて画像検索の実験を行い、その検索性能を報告する。作成した文の特徴として、広範な種類の関係述語を含むことであり、これらの文をクエリとして画像検索を行うには、GRIM のモデルに記述された物体間の位置関係以上の情報をモデルに加える必要がある。

3.2 実験結果と考察

サーカムスクリプションによる解析性能の評価結果を表 3 に示す。サーカムスクリプションにより、特に *every* や *all* など量化を含む文による検索の精度の改善が見られた。また論理結合子のうち、*not* など否定を含む文の精度も大きく改善した。次に、定理証明器の設定による精度と速度の比較を表 4 に示す。いずれの分類においても Prover9 を単独で用いた場合と、Prover9 に Mace4 を組み合わせた場合の F1 は等しいが、速度については後者において著しく改善している。Vampire を用いた場合も同様に、反例モデルの探索により、速度の改善が見られ、特に「論理結合子」に分類される文では高速に証明が得られることがわかる。

キャプションより更新されたモデルを用いて、各画像ごとに真と偽の 2 種類のキャプションとの含意関係を判定した結果は、適合率、再現率、F1 それぞれ 0.91, 0.73, 0.81 であった。

*3 https://www.cs.unm.edu/ mccune/prover9/
*4 http://www.vprover.org/

例文	現象
There is a cat **or** dog.	論理結合子
There are **at least two** cats.	数詞
Every person is **touching** a bicycle.	量化、空間関係
A cat is **walking**.	関係一般
A person is **wearing** a hat.	関係一般

表 2: 実験で用いた文の例と言語現象の分類。前半の例は研究 [17] によるが、下 2 例は実験で用いるために本研究で GRIM 画像との含意関係を付与した。

手法	F 値 / 速度（秒）				
	論理結合子	数詞	量化	空間関係	全体
単純	0.68 / 8.9	0.81 / 8.8	0.0 / 10.4	0.73 / 9.3	0.74 / 9.0
Circum.	0.84 / 12.1	0.95 / 9.2	0.76 / 35.0	0.88 / 13.3	0.88 / 11.9

表 3: モデルの翻訳方法の比較。 Circum. はサーカムスクリプションの略。定理証明は Prover9 による。

再現率が低い原因として、式 4 のような例において、キャプションに含まれる物体が画像中のどの物体を指すかが一意に決められず、モデルの更新に失敗したケースが見られた。

関係一般を含む文による画像検索の結果を表 5 に示す。キャプション情報を用いないモデルでは空間情報しか記述されていないため、表 2 の下 2 文のような一般の関係を含むクエリ文に対する F 値は 0 になるが、キャプション情報をモデルに加えることでそのような文についても検索できるようになった。再現率が低くなった原因は次の 2 つが考えられる。

第一に、画像情報からは推測されるがキャプションに含まれていない述語は検索に用いることができなかったことが挙げられる。特に物体の状態を表す述語はキャプションにしか記述されておらず、データセットに用意されている約 3 文のキャプションでは画像情報を表現しきれていないことが分かる。今後は Visual Genome [12] のような物体の属性や状態を含む大規模なデータセットを用いた実験を検討する。

第二に、本実験ではアブダクションは行わなかったため、述語間の関係を捉えた検索できなかったことが挙げられる。例えばモデルに *man* がある場合、同時に *person* がいるという推論ができなかった。これは [17] と同様の手法で証明時にアブダクションを行うことで解決可能と考えられる。

There is a cat which is not white. と *A person is riding a bicycle.* に対するシステムの予測画像を図 3 に示す。図 3(a) は、否定表現についてシステムが正しい予測を行った例である。また図 3(b) から *ride* という物体間の関係を表す述語を正しくモデルに変換できていることが分かる。



(a) *There is a cat which is not white.*



(b) *A person is riding a bicycle.*

図 3: システムの予測画像

4. おわりに

本稿では、画像情報とテキスト情報を論理ベースの意味表現を用いて統一的に扱い、論理推論を行うシステムを提案した。

手法	速度（秒）				
	論理結合子	数詞	量化	空間関係	全体
Prover9	12.1	9.2	35.0	13.3	11.9
+ Mace4	11.0	7.8	12.3	8.4	9.7
Vampire	9.3	9.0	10.3	9.2	9.2

表 4: 定理証明器による証明速度の比較。この実験ではモデルの変換にサーカムスクリプションを用いる。F 値については定理証明器によらず等しい。

適合率	再現率	F1
0.86	0.36	0.49

表 5: キャプションを追加した場合の画像検索の性能。

このシステムは、CCG の意味解析と定理証明を組み合わせることで、文と画像に含まれる属性・関係だけでなく、否定や量化・数量表現を含む意味情報を扱うことが可能である。画像に対してエンティティ・属性・関係の情報がアノテートされたデータセットを用いて、意味的に複雑なクエリを用いた画像検索が実現可能であることを示した。また、キャプションと画像情報を合成する方法を提示した。今後はグラフ表現から FOL モデルの変換をシステムに組み込むことで、より大規模なデータセット [12] を利用したマルチモーダル推論を検討する。

謝辞 この研究は、JST CREST「ビッグデータ統合利活用のための次世代基盤技術の創出・体系化」領域「知識に基づく構造的言語処理の確立と知識インフラの構築」プロジェクトの支援を受けたものである。

参考文献

[1] Miller George A. WordNet: A Lexical Database for English. *Commun. ACM*, 1995.
[2] Patrick Blackburn and Johan Bos. *Representation and Inference for Natural Language*. CSLI, 2005.
[3] Abzianidze Lasha. LangPro: Natural Language Theorem Prover. In *EMNLP*, 2017.
[4] Hürlimann Manuela and Johan Bos. Combining Lexical and Spatial Knowledge to Predict Spatial Relations between Objects in Images. In *Vision and Language Workshop*, 2016.
[5] Steedman Mark. *The Syntactic Process*. MIT Press, 2000.
[6] John McCarthy. Applications of circumscription to formalizing common sense knowledge. *Artificial Intelligence*, 1986.
[7] Acharya Manoj *et al.* TallyQA: Answering complex counting questions. In *AAAI*, 2019.
[8] Justin Johnson *et al.* Image retrieval using scene graphs. In *CVPR*, 2015.
[9] Koji Mineshima *et al.* Higher-order logical inference with compositional semantics. In *EMNLP*, 2015.
[10] Krishna Ranjay *et al.* Visual Genome: Connecting Language and Vision Using Crowdsourced Dense Image Annotations. *Comput. Vision*, 2017.
[11] Pascual Martínez-Gómez *et al.* ccg2lambda: a compositional semantics system. In *ACL*, 2016.
[12] Ranjay Krishna *et al.* Visual Genome: Connecting Language and Vision Using Crowdsourced Dense Image Annotations. 2016.
[13] Schuster Sebastian *et al.* Generating Semantically Precise Scene Graphs from Textual Descriptions for Improved Image Retrieval. In *Vision and Language Workshop*, 2015.
[14] Stanislaw Antol *et al.* VQA: Visual Question Answering. In *ICCV*, 2015.
[15] Vu Hoa *et al.* Grounded Textual Entailment. In *COLING*, 2018.
[16] 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.
[17] 鈴木莉子, 谷中瞳, 峯島宏次, 戸次大介. CCG と定理証明器を用いた画像情報の意味表現と推論の試み. 言語処理学会第 25 回年次大会発表論文集, 2019.

[2L3-J-9] Natural language processing, information retrieval: knowledge supply

Chair:Takeshi Morita Reviewer:Jun Sugiura

Wed. Jun 5, 2019 1:20 PM - 3:00 PM Room L (203+204 Small meeting rooms)

[2L3-J-9-01] Response Generation based on Embedding Representation of Knowledge and Topics

○Jie Zeng[1], Yutaka Takase[2], Yukiko Nakano[2] (1. Graduate School of Science and Technology, Seikei University, 2. Faculty of Science and Technology, Seikei University)

1:20 PM - 1:40 PM

[2L3-J-9-02] Monotonicity Dataset Creation on Crowdsourcing

Hitomi Yanaka[1,2], ○Daisuke Bekki[2], Koji Mineshima[2], Satoshi Sekine[1], Kentaro Inui[3,1] (1. RIKEN Center for Advanced Intelligence Project, 2. Ochanomizu University, 3. Tohoku University)

1:40 PM - 2:00 PM

[2L3-J-9-03] Collecting Examples of Know-How Question Answering from Column Pages on the Web

○Tatsuya Maeda[1], Tengyang Chen[1], Yohei Ohkawa[1], Takehito Utsuro[1], Yasuhide Kawada[2] (1. University of Tsukuba, 2. Logworks Co., Ltd.)

2:00 PM - 2:20 PM

[2L3-J-9-04] V-TA: Dialogue System for Practical Training on Software Development

○Masayuki Otani[1], Taku Kawabata[2], Koji Abe[1], Hirofumi Yamamoto[1], Shiro Takata[1], Yoshihiko Akamatsu[2], Fujiko Yamamura[2] (1. Kindai University, 2. JIEC Co.,Ltd.)

2:20 PM - 2:40 PM

[2L3-J-9-05] A Comparison of Multileaving Methods on News App Personalization

○Kojiro Iizuka[1], Takeshi Yoneda[1], Yoshifumi Seki[1] (1. Gunosy Inc.)

2:40 PM - 3:00 PM

©The Japanese Society for Artificial Intelligence

知識と話題の埋め込み表現に基づく応答生成 ー料理嗜好インタビューシステムに向けてー

Response Generation based on Embedding Representation of Knowledge and Topics: Towards Food Preference Interview Systems

曽 傑[*1]
Jie Zeng

高瀬 裕[*2]
Yutaka Takase

中野 有紀子[*2]
Yukiko Nakano

[*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

This paper proposed a dialogue system that collects user's preference while providing topics related to food. First, the dialogue system generates in-depth question for user's utterance using expressions of taste and texture, and case frame. Second, the dialogue system provides topic using Freebase knowledge base and selects nearby topics from embedding of properties. Additionally, if the system fails in knowledge search, it predicts missing knowledge using knowledge graph embedding representation.

1. はじめに

近年，飲食店などで接客や案内等を行うロボットが登場し，サービス提供の一環として，ロボットの需要が高まっている．よりきめ細かい接客を実現するには，ユーザの嗜好情報を把握し，ユーザ適応した対応が望まれる．

ユーザの嗜好情報を利用した研究として，料理やレシピ推薦システムがある[Trattner 2017]．レシピ推薦システムに用いられるアルゴリズムとして，内容ベースや協調フィルタリングがあるが，どちらも推薦精度向上のためには，多くのユーザから様々な料理や特徴についての評価を集める必要がある．したがって，よりよい推薦を行うには，ユーザからより多くの情報を引き出すことが重要であるといえる．一方，ユーザから情報を引き出す対話としてインタビュー対話が存在する[Johnston 2013] [Stent 2006]．その多くはあらかじめ定義した項目についてユーザに質問を行い，肯定，否定や5段階の評価といったシンプルな回答を求めている．しかし，料理の味や食感などの好みは多様であるため，雑談のように料理に関する幅広い話題を提供する中で，ユーザの嗜好を聞き出す対話のほうがユーザ嗜好の獲得には効果的であると考えた．

そこで本研究では，料理推薦に向けて，ユーザから料理に関するより多くの情報を引き出すことを目的とし，料理に関する嗜好獲得の対話システムを提案する．その中で，ユーザの嗜好を獲得する，次の 2 つの対話戦略を実現する．

①料理や，相手の発話に対する深堀り質問
②様々な料理についての多様な話題選択

この 2 つの対話戦略を実装し，対話システムに組み込む．

2. 深堀り質問生成手法

2.1 食味表現を用いた質問

味覚表現やオノマトペを使うことで多様な好みを表現しやすいことがわかっている [Komatsu 2012]．これを応用し，食味表現を用いた質問をすることで，料理や材料の食味・食感の好みを獲得する．具体的には，料理名や材料名のキーワードに対し，それらと共起しやすい典型的な食味表現のデータベース(以下，食味表現 DB と表記)を作成する[曽 2018]．これは，キーワードを検索語とし，Twitter から最大 10000Tweet を収集する．その後，あらかじめ用意したテクスチャ表現や味覚表現を含む食味表現リスト(eg. ぷにぷに，噛み応え，甘い)に含まれる食味表現を収集した Tweet から抽出する．例えば「たこ焼き」の場合，「辛い」「甘い」「ふわふわ」などが Tweet で共起した食味表現として取得でき，キーワードとそれに対応して抽出された食味表現を食味表現 DB に保存する．これを用いて，食味表現を用いた質問はキーワードを入力とし，このキーワードを使って食味表現 DB より食味表現を2つ取得し，以下のテンプレートに当てはめ応答を生成する．

どんな${キーワード}が好きですか？${食味表現_1}，${食味表現_2}はいかがですか．

2.2 動詞の格フレームを利用した質問

ユーザ発話に対して，さらに具体的な情報を求める質問のために，「どこで」，「何を」などの疑問詞を使った質問を動詞の格フレームを使って生成する[古川 2005]．図 1 に動詞の格フレームを利用した質問生成プロセスを示した．はじめに，ユーザ入力文に対して形態素解析器 JUMAN，係り受け解析器 KNP を用いて格フレームを取得する．この入力文例では「動詞：食べる」の格要素となりうるのは，ガ格，ヲ格などであることがわかる．次に，これらの格要素に応じた疑問詞の付与を行う．そのため

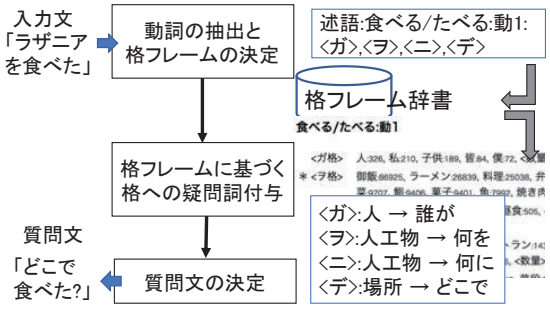


図 1 動詞の格フレームを用いた質問生成フロー

連絡先：曽傑，成蹊大学大学院理工学研究科，知的インタフェース研究室，東京都武蔵野市吉祥寺北町 3-3-1
E-mail:dm176204@cc.seikei.ac.jp

[1] 京都大学格フレーム: http://lotus.kuee.kyoto-u.ac.jp/cf-search/

に，これらの格要素が取りうる単語を格フレーム辞書 [1] より取得し，それを JUMAN カテゴリに変換することにより，当該格助詞において最頻出のカテゴリを決定する．例えば，ガ格は人カテゴリ，デ格は場所カテゴリが最頻出カテゴリである．そして，人カテゴリには「誰」，場所カテゴリには「どこ」を付与する．格要素ごとに付与した疑問詞を用いて，質問文テンプレート「疑問詞+格+動詞+?」を適用し，質問文を生成する．最後に，これらの質問文の中からランダムに1つ選択し，質問文として出力する．図 1 の場合，デ格による質問文「どこで食べた？」を出力している．

3. Freebaseを用いた関連話題の提供と遷移手法

この章では，会話に幅を持たせる話題提供を目的とし，Freebase を用いた話題選択方法について述べる．

3.1 Freebaseトリプルを使った話題の提供

本研究では，話題の提供と遷移を実現するために，大規模知識 Freebase を用いる．Freebase は主語(Subject，以降 S と表記)，述語(Predicate，以降 P と表記)，目的語(Object，以降 O と表記)のトリプル構造により知識を表現している． Freebase 上で「カルボナーラ」のようなエンティティに対してユニークな識別子(MID)として「m.0273gv」が与えられ，これを S とし，P:type.object.name の O を取得すれば日本語のラベルが取得できる．同様に，材料を示す P:food.dish.ingredients に対応する O を取得すると「パンチェッタ」や「鶏卵」を表すエンティティが取得できる．このように料理や材料を S としたトリプルを取得し，トリプルの P を話題とみなし，P に応じたテンプレート(表 1)に S や O を適用することにより応答文を生成し，話題提供を行う．例えば，S:寿司,P: food.dish.ingredients，O:米の場合，「寿司の材料は米ですが，他にどんな材料が好みですか」が生成される．

3.2 Wikipediaによる話題埋め込みの作成と利用

話題遷移の際に，現在の話題と近い話題を関連話題として提供する．そこで，(1) 話題の近さを扱うことが可能な話題埋め込みの作成方法と，(2) 話題埋め込みを用いた話題遷移の手法について述べる．

(1) Wikipediaによる話題埋め込みの作成

話題埋め込みは Wikipedia と Freebase を用いて，(a)Wikipedia 記事から述語(話題)の並びを抽出し，(b)この並びを話題遷移の流れとみなし，Skip-gram で学習を行い作成する [Lee 2015].

(a) Wikipedia 記事からの述語の並びの抽出

本研究では，話題の流れの学習に，Wikipedia のテキストを用いた． Wikipedia は英語版を使用し，かつ料理に関係する記事のみを用いた．図 2 に「カルボナーラ」の記事から P(話題)を抽出する例を示す．例えば，記事タイトル「Carbonara」を S とし，リンクを持つ本文中の単語「guanciale」，「pepper」を O とすると，Freebase から材料を示す P:food.dish.ingredients が得られる．「Rome」を O とすると，料理のジャンルを表す P:food.dish.cuisine が得られる．このように記事の段落ごとに P の並びを作成する．

(b) Word2Vec の Skip-gram による話題埋め込みの作成

Wikipedia 記事を用いて段落ごとに抽出した P(話題)の並びを，一連の話題の流れと見なし，Word2Vec の Skip-gram[Mikolov 2013]を用いて学習を行い，埋め込み表現を得る．作成した話題埋め込みにおいて，材料を示す P の最近傍 3 つを表 2 に示す．材料を表す P の近傍には，料理のタイプを示す P:food.dish.type_of_dish1 や日本料理やイタリア料理などのジャンルを示す P:food.dish.cuisine が現れている．

表 1 P とそれに対応するテンプレート例

P	トリプル(SPO)を用いた応答テンプレート
food.dish.cuisine	*S のジャンルは O ですが，他にどの O が好きですか*
food.dish.ingredients	*S の材料は O ですが，他にどんな材料が好みですか*
base.schemastaging.food_extra.broader	*S は O の 1 つですが，他に好みの O はありますか*

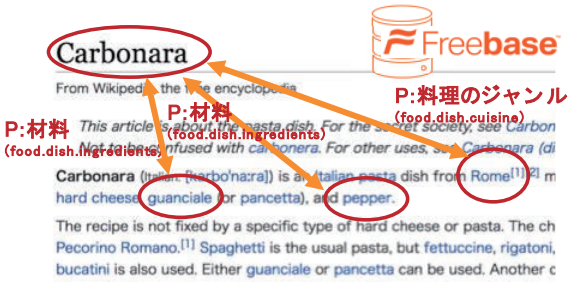


図 2「カルボナーラ」記事からの P(話題)抽出

表 2 話題埋め込みにおける P:food.dish.ingredients の最近傍上位3つ

P(話題)	food.dish.ingredients とのコサイン類似度
food.dish.type_of_dish1	0.952
food.dish.cuisine	0.894
base.schemastaging.food_extra.broader	0.638

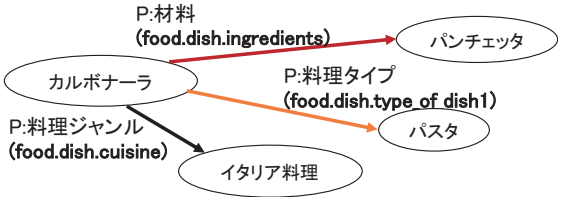


図 3 話題埋め込みを利用した「カルボナーラ」の話題遷移例

(2) 話題埋め込みを用いた話題遷移

話題埋め込みより，現在の話題である P に関連する P'を次の話題として選択することができるようになった．例えば，「カルボナーラ」について以下図 3 のような話題遷移が可能となる．例えば，赤線で示した S:カルボナーラ，P:food.dish.ingredients，O:パンチェッタの話題を提供したとする．その後，提供した話題に関連した話題を提供する際に，元の P: food.dish.ingredients に近い話題を話題埋め込みにより取得する．ここで図 3 のように話題 food.dish.ingredients と最も近い話題として橙線で示した P:food.dish.type_of_dish1 を選択し，S:カルボナーラ，P:food.dish.type_of_dish1，O:パスタを関連話題として優先的に発話することになる．

4. 知識グラフ埋め込みの作成と利用

前章では話題埋め込みによる話題遷移について述べた．しかし，関連話題として選ばれた P についての知識が必ずしも Freebase に存在するわけではない．このような知識グラフの問題

に対応する技術として，明示的に与えられていないノードやリンクについての予測を行う知識グラフ埋め込み(Knowledge Graph Embededding)がある．本研究では知識グラフ埋め込みのモデルの1つである TransE[Bordes 2013]を用いる．

4.1 食に関する知識グラフ埋め込みの作成

食に関するトリプルを TransE で学習するために，まず，Freebase 中の P:type.object.type (エンティティのカテゴリや分類を表す) を用い，そこで得られた(O)が料理や材料などの食についての分類を表す food.food を持つものを収集した．次に食に関するトリプルは，上で定義した食に関するエンティティを S または O とした時に得られるトリプルとした．この食に関するトリプルを学習データとし，TransE モデルにより学習した．

4.2 知識グラフ埋め込みを用いた予測による話題提供の拡張

3 章の話題埋め込みを用いた話題遷移時に S と関連話題 P を使い Freebase より O の取得を行うが，トリプルが存在しないため O が取得できない場合がある．例えば，S:ミートソース，関連話題 P:材料が決定した場合に，Freebase の知識にミートソースの材料についての知識が存在しないため，材料名(O)を使った発話ができない．そこで，知識グラフ埋め込みを用いることで O の予測ができ，予測したものを使用することにより応答の幅を広げることができる．O の予測は知識グラフ埋め込みに存在する S と P のベクトルを用いて，S+P によって得られる値に近いエンティティに相当する．表 3 に S:餃子，材料 P:food.dish.ingredients から Freebase に実際には存在しない O の取得結果を示す．餃子の材料の取得として材料エンティティである穀粉やタマネギを予測できている．

4.3 知識グラフ埋め込みを用いた話題遷移

知識グラフ埋め込みを予測に利用する他に，知識グラフ埋め込みでのエンティティ近傍に，エンティティが持つ複数の P の構造が似たエンティティが集まると考えることができる．「カルボナーラ」近傍エンティティを表 4 に示す．

ここで知識埋め込みにて，入力エンティティを遷移元とし，近傍エンティティからランダムに選んだエンティティを遷移先とし，以下のテンプレートに当てはめ話題遷移の応答文を生成する．

${遷移元}の他に${遷移先}はいかがですか

5. 対話システムの実装

嗜好獲得に向けた深掘り質問と関連話題の戦略に基づき，(a)食味表現を用いた質問，(b)動詞の格フレームを用いた質問，(c)Freebase のトリプルを用いた話題提供，(d)話題埋め込みを用いた話題遷移，(e)知識グラフ埋め込みを用いた話題遷移，の 5 つの応答方式を実装した対話システムを提案する．図 4 にシステム処理フローを示す．以下各構成素について説明する．

表 3 TransE による S:餃子 P: food.dish.ingredients から O の予測

エンティティのラベル(和)	類似度 sqrt(2-2*cos(u,v))
鶏卵	0.891
穀粉	0.928
魚類	0.948
タマネギ	0.949
水	0.958

表 4 知識グラフ埋め込みでの「カルボナーラ」近傍エンティティ

エンティティのラベル(和/英)	類似度 sqrt(2-2*cos(u,v))
ボンゴレ	0.694
プッタネスカ	0.729
Chicken Marengo	0.738

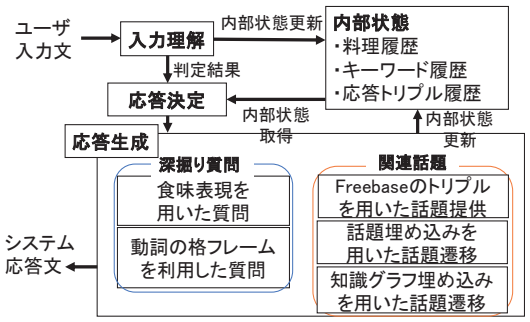


図 4 システム処理フロー

5.1 入力理解部

入力理解部では，応答生成に必要な情報をユーザ入力文から抽出する．具体的には以下の2つを行う．

①料理と材料からなるキーワードの抽出：本システムは料理や材料に関する言葉を起点に深掘りや関連話題の提供が行われる．そのために料理と材料をキーワードとして入力文から抽出する．料理と材料キーワードは，Freebase 中の P:type.object.type を用い，O に料理を示す food.dish，もしくは材料を示す food.ingredient を持つエンティティ，かつ対話システムの入力が日本語であるため，日本語ラベルを持つものとする．抽出したキーワードは内部状態のキーワード履歴に保存され．そのキーワードが料理名であれば料理履歴にも保存する．

②動詞の格フレームの存在判定：応答方式(b)で，動詞の格フレームを用いるため，2.2 節で述べた手法により動詞の抽出と格フレームの特定を行い，応答方式(b)の採用可否を応答決定部に送る．

5.2 内部状態

入力理解部で得たキーワードやシステム応答の内容を履歴として保持し，応答生成時に使用する．

キーワード履歴：入力文から抽出したキーワードや，応答方式(e)の話題遷移先キーワードを保持する．

料理履歴：関連した料理の話題に遷移するため，キーワードのうち料理名であるものを保持する．

応答トリプル履歴：応答方式(d)を適用するために，システム応答に用いた SPO トリプルを保持しておく．

5.3 応答決定部

入力理解部の出力と内部状態に基づき，応答方式(a)～(e)の 5 種類の応答の中から応答を 1 つ選択する．はじめに，それぞれの応答について，応答を生成するための条件が満たされているかどうかを確認する．なお，ユーザの発話した内容を深掘りせず，すぐに別の話題へと遷移するのは不自然と考え，得られた新規キーワードについては，深掘りの応答が可能であれば，深掘りを一度優先する．

5.4 応答生成部

応答決定部により決定された応答内容から，応答文を生成する．応答方式(d)以外の応答はすでに述べた((a):2.1 節, (b): 2.2 節, (c):3.1 節, (e):4.3 節)．ここでは応答方式(d)の応答生成について述べる．

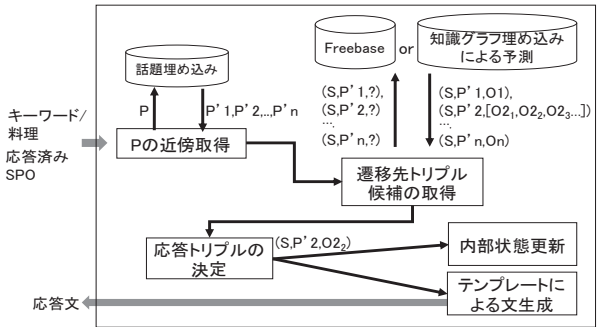


図 5 話題埋め込みを用いた話題遷移の応答プロセス

話題埋め込みを用いた話題遷移:図 5 に応答方式(d)の生成プロセスを示す. 既に話題となった話題 P を応答済み SPO から取得し, 話題埋め込みにより複数の近傍 P'を取得する. そして, 遷移先トリプルとして, キーワード S, 複数の近傍 P', 及びそれぞれに対応する O を取得する. O は Freebase から取得し, それができなければ, 知識グラフ埋め込みを用いた予測(4.2 節)により取得する. 以上により得られた遷移先トリプル候補の中から1つランダムに選択し, 表 1 のテンプレートを使い文生成する. なお, 予測した O を用いる時は,「ですが」と言い切らず,「でしょうか？」や「であると予測しますが」と不確定な表現にする.

6. 対話例

提案した対話システムによる対話例を表 5 に示す. あらかじめ用意した発話(S1)からスタートし, ユーザの回答(U1)からキーワードとして「カルボナーラ」を抽出している. システムは深掘りを優先し, 動詞の格フレームを用いた質問を生成している(S2). ユーザから場所の回答を得るが, キーワードは抽出されず, システムは「カルボナーラ」についてのトリプル(S:カルボナーラ, P:ジャンル O:イタリア料理)を Freebase から取得し, 話題提供を行なっている(S3). ユーザの回答から「ミートソース」を抽出し(U3), システムはミートソースについて食味表現を用いた深掘り質問を生成している(S4). 続けてシステムは S3 で話した P:ジャンルから話題埋め込みを用いた話題遷移により, S:ミートソース, P:材料, O:タマネギを遷移先トリプルとして利用し, これを用いて応答している. S7では知識グラフ埋め込みよりベーコンの近傍エンティティとして豚肉を選び, 話題として提供している.

表 5 提案システムによる対話例(S:システム,U:ユーザ)

	ユーザ入力文/システム応答	キーワード履歴
S1	最近食べた料理について教えてください	
U1	カルボナーラを食べた	カルボナーラ
S2	どこで食べた？	
U2	麻布のレストランでね	
S3	カルボナーラのジャンルはイタリア料理ですが, 他にどのイタリア料理が好きですか	
U3	ミートソースが好き	ミートソース
S4	どんなミートソースが好きですか？ジューシーやこってりはいかがですか	
U4	濃厚なのがいいです	
S5	ミートソースの材料はタマネギがあると予想しますが, 他にどんな材料が好みですか	
U5	ベーコン	ベーコン
S7	ベーコンの他に豚肉はいかがですか	

7. まとめ

本研究では, 料理に関するユーザの嗜好を引き出す対話システムに向けて, 深掘り質問として, 食味表現を用いた質問や動詞の格フレームを用いた質問を生成した. 関連話題を提供する手法としては, Freebase を用いた話題提供, 話題埋め込みによる関連話題への遷移, Freebase に知識が存在しない問題については知識グラフを用いた予測を行なった. さらに知識グラフ埋め込みを用いた話題遷移を提案した. 最後にこれらの手法を組み込んだ対話システムを実装した.

今後の課題として, Freebase に存在する料理に関する P が少なく, 話題遷移先のバリエーションを増やす必要がある. また, 本手法を組み込んだ対話システムの有用性を検証するために, ユーザ満足度や得られた嗜好情報の量や質に関する評価を行う必要がある.

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

[Trattner 2017] Trattner Christoph, and David Elsweiler: Food Recommender Systems: Important Contributions, Challenges and Future Research Directions, arXiv preprint arXiv:1711.02760, 2017.

[Johnston 2013] Johnston, Michael, et al.: Spoken dialog systems for automated survey interviewing, Proceedings of the SIGDIAL 2013 Conference. 2013.

[Stent 2006] Stent, Amanda, Svetlana Stenchikova, and Matthew Marge: Dialog systems for surveys: The Rate-a-Course system, Spoken Language Technology Workshop, 2006, IEEE, IEEE, 2006.

[Komatsu 2012] Komatsu, Takanori: Quantifying Japanese onomatopoeias: toward augmenting creative activities with onomatopoeias, Proceedings of the 3rd Augmented Human International Conference, ACM, 2012.

[曽 2018] 曽 傑, 高瀬 裕, 中野 有紀子: 食味表現に着目した料理嗜好対話システム, 人工知能学会全国大会論文集, 2018.

[古川 2005] 古川智雅, 吉野幸一郎, 須藤克仁, 中村哲:格フレームを用いた質問生成によって深掘りを行う対話システム, SIG-SLUD 5.02, 94-95, 2018.

[Lee 2015] Lee, Kyusong, et al.: Conversational knowledge teaching agent that uses a knowledge base, Proceedings of the 16th Annual Meeting of the Special Interest Group on Discourse and Dialogue, 2015.

[Mikolov 2013] Mikolov, Tomas, et al.: Distributed representations of words and phrases and their compositionality, Advances in neural information processing systems, 2013.

[Bordes 2013] Bordes, Antoine, et al.: Translating embeddings for modeling multi-relational data, Advances in neural information processing systems, 2013.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

クラウドソーシングによる単調推論データセットの構築

Monotonicity Dataset Creation on Crowdsourcing

谷中 瞳 *1*2 Hitomi Yanaka　戸次 大介 *2 Daisuke Bekki　峯島 宏次 *2 Koji Mineshima　関根 聡 *1 Satoshi Sekine　乾 健太郎 *1*3 Kentaro Inui

*1理化学研究所 AIP センター RIKEN Center for Advanced Intelligence Project　*2お茶の水女子大学 Ochanomizu University　*3東北大学 Tohoku University

Large crowdsourced datasets are widely used for training and evaluating neural models on recognizing textual entailment (RTE). However, it is still unclear whether neural models can capture logical inferences, including monotonicity reasoning, for which no large naturalistic dataset has yet been developed. To investigate this issue, we introduce a method of creating a dataset for monotonicity reasoning by crowdsourcing and report the result of the first run. The error analysis indicates that workers tend to provide different answers from what logical entailment defines, for some downward monotonicity reasonings involving pragmatic reasoning.

1. はじめに

含意関係認識（Recognizing Textual Entailment, RTE）[Dagan 13] とは、前提文 T が仮説文 H の意味を含むか否かを自動判定する基盤技術であり、コンピュータによる自然言語理解の実現に向けて、きわめて重要な技術である。近年、自然言語処理においては、クラウドソーシングを活用して大規模な言語資源を低コストで構築できるようになった。含意関係認識の研究においても例外ではなく、クラウドソーシングによって人手で構築された大規模な含意関係認識データセット [Bowman 15, Williams 18] から、ニューラルネットワークを用いて文の意味を学習し、高精度で含意関係認識を解く手法 [Devlin 18, Wang 18] が活発に研究されている。しかし、クラウドソーシングによって構築されたデータセットには量化や否定、比較表現、条件文といった、論理的な意味の計算を要する推論現象のデータが含まれていないことが指摘されている [Geiger 18]。そのため、ニューラル含意関係認識モデルがこれらのデータセットから論理語の意味を学習できているのかは自明ではない。

そこで [谷中 19] は、形式意味論において分析が進められている単調推論に着目して、外部辞書を用いて量化子を含む文の語彙を置き換えることで、単調推論のデータセットを自動構築する手法を提案した。この手法ではニューラル含意関係認識モデルの学習に足るデータセットが構築可能である。しかし、この手法では、意味論的推論としては妥当でも、人間の日常的な推論としては不自然な例が作られることがある。例えば、次の例のような downward monotone の推論は直観的には、人でも困難な推論とされている [Geurts 05]。

(1) T: *I saw a dog*
⇒ H: *I saw a dog or a small red cat with green eyes*

この推論は、一階述語論理の意味論においては妥当な推論であるが、人は仮説文 H から緑の目をした小さな赤い猫が存在するという前提があると読み込み、語用論的に含意しないと推論する。このように、一階述語論理の意味論において妥当な推論と、語用論的に日常的に人間が正しいと判断する推論にはギャップがあり、含意関係認識モデルの評価ではこのギャップを考慮する必要がある。

既存の単調推論を扱う評価用データセットとしては、FraCaS [Cooper 94] や GLUE diagnostic dataset [Wang 18] がある。しかし、いずれのデータセットも単調推論の問題は 80 件、56 件と非常に少なく、語彙の置き換えも辞書的な語の置き換えと修飾語の追加に限られている。語彙の置き換えはこれらのパターンに限らず、等位接続表現、to 不定詞、関係節の追加など、様々なパターンが考えられる。このような自然な置き換えパターンのバリエーションと数を担保するためには、クラウドソーシングなどの人手による構築手法が求められる。しかし、専門家ではないクラウドソーシングの作業者が推論の問題を設計することは、前述のギャップも考慮すると容易ではなく、作業内容が明快かつ単純なタスクを設定する必要がある。

本研究では、形式意味論の知見とクラウドソーシングを組み合わせることで、実テキストから単調推論の評価用データセットを構築する手法を提案する。具体的には、Combinatory Categorial Grammar (CCG) [Steedman 00] に基づく統語解析によって単調推論が関わる表現を特定し、その表現をより詳細な表現にするクラウドソーシングタスクを実施することで、単調推論が成り立つ多様な前提文と仮説文のペアを効率的に構築する。なお、構築したデータセットは研究利用が可能な形式で公開する予定である。

連絡先: 谷中瞳、理化学研究所 AIP センター、hitomi.yanaka@riken.jp

2. 単調推論

単調推論は語の置き換えに基づく推論であり、語彙知識と統語構造の統合的な理解が必要となる、重要な言語現象の一つである。この推論は、否定や一般化量化子などの表現が持つ単調性に基づいて文中の語を意味的に上位もしくは下位の表現に置き換えた文と、元の文との含意関係が成り立つという推論である [Benthem 83, Icard 14]。上位の表現への置き換えは、ある表現を辞書的に上位の表現に置き換える、修飾表現を除く、or で結ぶ等位接続表現を加える、といった操作によって可能である。同様に、下位の表現への置き換えは、辞書的に下位の表現に置き換える、修飾表現を加える、and で結ぶ等位接続表現を加える、といった操作によって可能である。

polarity は、単調性に応じて決定される、言語表現の構文木中における性質であり、↑が付与されている場合、その表現を意味的に上位の表現に置き換えても、元の文との間に含意関係が成り立つ。また、↓が付与されている場合は、その表現を意味的に下位の表現に置き換えても、元の文との間に含意関係が成り立つ。

ある表現が upward monotone である (項関係にある表現の横に “+” を付与して表す) とは、その表現と項関係にある表現の polarity を維持するという意味である。逆に、ある表現が downward monotone である（項関係にある表現の横に “–” を付与して表す）とは、その表現と項関係にある表現の polarity を反転させるという意味である。

一般化量化子は単調推論と関連が深く、一般化量化子の単調性に応じて、その一般化量化子の項となる名詞句 (NP) と動詞句 (VP) の polarity が決定する。例として、*Every spectator buys a movie ticket* という文を考えてみよう。*every* は、項にとる名詞句に対しては downward monotone であり、 動詞句に対しては upward monotone である。このため、(2) に示すように、*spectator* の polarity は↓とな

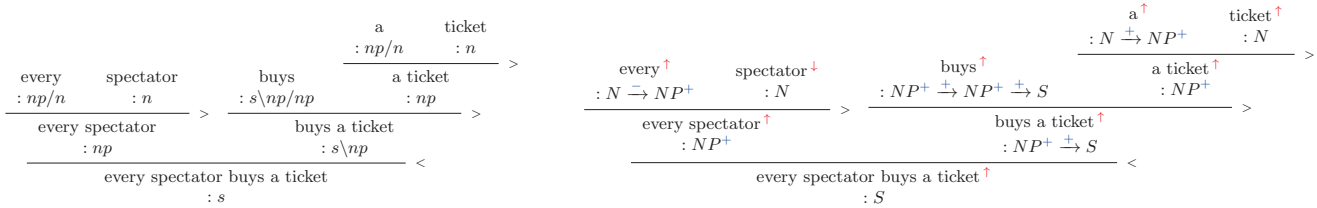


図 1: *Every spectator buys a ticket* に対する CCG の導出木（左）とそれを変換し各ノードに polarity (↑, ↓) が付与された木（右）

り、これを下位の表現に置き換えても元の文と含意関係が成り立つ。また、*buys a movie ticket* の polarity は ↑ となり、上位の表現に置き換えても、元の文と含意関係が成り立つ。

(2) *Every* [NP *spectator*↓]$^-$[VP *buys a movie ticket*↑]$^+$
⇒ *Every* [NP *female spectator*] [VP *buys a movie ticket*]
⇒ *Every* [NP *specator*] [VP *buys a ticket*]

downward monotone の表現には一般化量化子に限らず、様々な表現がある。表 1 に downward monotone の性質を持つ表現の例を示す。

表 1: downward monotone 表現の例

量化子	*every, all, any, few, no*
否定表現	*not, n't, never*
動詞	*deny, prohibit, avoid*
名詞	*absence of, lack of, prohibition*
副詞	*scarcely, hardly, rarely, seldom*
前置詞	*without, except, but*
条件節	*if, when, in case that, provided that, unless*

こうした downward monotone の性質をもつ表現が複数回埋め込まれた文では、polarity の反転が起こる。例えば、条件節のスコープ内に *every* が現れる以下の例では、polarity が以下に示すように反転する。

(3) *If* [*every* [NP *spectator*↑]$^-$[VP *buys a ticket*↓]$^+$]$^-$, [*that film will be sold out*]$^+$
⇒ *If* [*every* [NP *person*] [VP *buys a ticket*]], [*that film will be sold out*]
⇒ *If* [*every* [NP *person*] [VP *buys a movie ticket*]], [*that film will be sold out*]

このように、文の構成素の polarity を決定する上では、文の統語構造が重要な役割を果たしている。

CCG に基づく統語解析は、文の構成素を関数と項に分類する点で、polarity の計算に適した枠組みとなっている。CCG に基づいて polarity を付与するシステムとして、ccg2mono [Hu 18] がある。図 1 に、その解析例を示す。ccg2mono では、まず入力文に対して CCG に基づく統語解析を行い、CCG の導出木を得る。その上で、CCG の統語範疇 (s, n, np) を e と t を基底型とする意味論の型 *1 に変換し、*every* や *a* などの機能語がもつ monotonicity $(+, -)$ と構成素間の関数ー項の関係に着目して、最終的に各構成素の polarity (↑, ↓) が決定される。

3. 提案手法

2 節で述べたように、単調推論が成り立つ前提文と仮説文のペアをクラウドソーシングで構築するためには、語彙が持つ性質と統語構造に基づいて前提文中の表現の polarity を計算し、適切に語彙を意味的に上位・下位の表現に置き換えて仮説文を構築する必要がある。

また、既存のクラウドソーシングによる含意関係認識データセットの構築手法 [Bowman 15, Williams 18] では、否定表現を入れて矛盾となる仮説文を作成するといった、ワーカーの無意識な作業バイアスが生じてしまうという問題が指摘されている [Gururangan 18, Poliak 18, Tsuchiya 18]。既存の手法ではワーカーに前提文を提示し、前提文と含意・矛盾・非含意の関係になる仮説文を作成するというタスクを課している。しかし、このタスク設定では、ワーカーにそれぞれの意味的関係が成立する条件を指定できていないことが、作業バイアスが生じる原因の一つとして考えられる。

そこで提案手法では、まず CCG に基づく統語解析結果に基づいて各表現の polarity を計算し、upward monotone, downward monotone の性質を持つ表現を含む前提文の選定と置き換え対象の表現を特定する。そして、(i) 前提文中の置き換え対象の表現をより詳細な表現に置き換えて仮説文を作成してもらうタスクと、(ii) (i) でできた前提文と仮説文のペアの含意関係を判定してもらうタスクという 2 つのクラウドソーシングタスクを用意することで、ワーカーの作業バイアスを防ぎ、単調推論のデータセットを構築する。クラウドソーシングのプラットフォームには、figure eight を用いた。次節で各手順の詳細を述べる。

3.1 前提文の選定と置き換え対象の表現の特定

本研究ではまず、統語・意味解析情報つき多言語コーパスである Parallel Meaning Bank (PMB) [Abzianidze 17] のうち、5 トークン以上からなる平叙文約 6 万 4 千件から前提文を選定した。PMB は様々なジャンルの実テキストから構成され、語彙的・構文的に多様な文を扱っているため、多様な単調推論のデータの構築が期待できる。

ワーカーに語彙の置き換えを依頼する際に、抽象的な概念を表す表現や、*no one*, *every day* といったイディオム化された表現は、語彙の置き換えが困難であると考えられる。そこで 500 件でトライアルタスクを実施し、ワーカーが仮説文を作成できていなかった例から、置き換えが困難な表現を特定した。これらの表現を含む文は前提文として採用しないこととした。特定した語彙の置き換えが困難な表現を表 2 に示す。

表 2: 語彙の置き換えが困難な表現

one, body, person, people, human,
idea, money, thing, part, time,
day, week, month, year, ages, chance, wonder

次に、各文に対して depccg [Yoshikawa 17] を用いて CCG に基づく統語解析を行い、ccg2mono [Hu 18] を用いて CCG の導出木から文の各構成素の polarity を計算し、↑, ↓ の polarity が付与された文を選定した。この中で、upward monotone の問題と downward monotone の問題の割合を調整するため、表 1 にある downward monotone 表現を含む文を積極的に選定した。最終的に、upward monotone の表現を含む文例 1485 件, downward monotone の表現を含む文例 1982 件の合計 3467 件を前提文として選定した。

3.2 仮説文作成タスク

3.1 節で選定した文を提示し、↑ か ↓ の polarity が付与された表現をより詳細な表現に置き換えて仮説文を作成してもらうことで、単調推論が関わる前提文と仮説文のペアを収集するタスクを設計した。ワーカーはインストラクションにある回答例を参考にして回答するため、より高品質の仮説文を収集するには、わかりやすい回答例を用意することが重要である。そこで

*1 [Hu 18] に従って、t を S、$e \to t$ を N、$(e \to t) \to t$ を NP と表す

表 3: 構築した単調推論データの例

現象	前提文	仮説文	正解
upward monotone	*All men have equal rights*	*All men have equal rights to express oneself in public*	非含意
	There is a cat on the chair	*There is a cat sleeping on the chair*	非含意
	If you heard her speak English, you would take her for an American	*If you heard her speak English, you would take her for a native American*	非含意
	Dogs have all the good qualities of people without at the same time possessing their weaknesses	*Dogs and cats have all the good qualities of people without at the same time possessing their weaknesses*	非含意
	It is not tea but coffee that I want	*It is not tea but coffee with milk that I want*	非含意
downward monotone	*Tom hardly ever listens to music*	*Tom hardly ever listens to rock 'n' roll*	含意
	You don't like love stories	*You don't like love stories and sad endings*	含意
	Tom doesn't like to eat fish	*Tom doesn't like to eat fish cooked in restaurants*	含意
	I never had a girlfriend before	*I never had a girlfriend taller than me before*	含意
	Rock climbing without proper equipment is dangerous	*Rock climbing without proper equipment of security is dangerous*	含意

インストラクションには修飾表現を追加した例、and や or で結ぶ等位接続表現を追加した例、関係節を追加した例、辞書的に上位・下位の語に置き換えた例をそれぞれ提示した。本研究では多様な仮説文を収集するため、1 問あたり$5 の報酬を与えるとして、1 問あたり 3 名に、1 つの文につき 3 通りの書き換え作業を依頼した。また、低品質な回答を除くため、1 問当たり最低 200 秒以上時間をかけた回答のみを採用した。仮説文作成タスクのインタフェースを図 2 に示す。

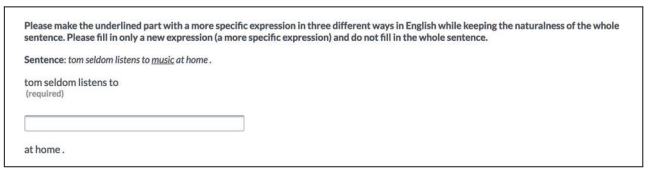


図 2: 仮説文作成タスクのインタフェース

合計 128 名のワーカーに作業を依頼し、upward monotone の推論で非含意となる例 7179 件、downward monotone の推論で含意となる例 8160 件と、合計 15339 件の仮説文を構築した。

3.3 含意関係ラベル判定タスク

ワーカーは専門家ではないため、仮説文作成のような自由記述のタスクでは、意味的に不自然な文が作成されている場合がある。意味的に不自然な文である場合、そもそも含意関係ラベルの判定が困難である。そこで作成した前提文と仮説文のペアについて、含意関係が成り立つか否かに加えて、文が自然な文か否かをチェックするタスクを用意した。

また、ワーカーに含意関係が成り立つか否かを正しく判定させるためには、含意関係の定義をワーカーに正しく理解させる必要がある。そこで 3 種類のラベル (含意、非含意、不自然) について、それぞれ次のような説明をワーカーに指示した。

1. 含意：前提が真であるどのような状況においても、結論がかならず真であるケース
2. 非含意：前提が真であったとしても、結論が常に真であるとは限らない（前提が真である特定の状況では、結論が真とならない）ケース
3. 不自然 : 文法的に、あるいは意味的に不自然であるケース

また、インストラクションには、含意、非含意、不自然の例をそれぞれ 5 件ずつ提示した。

高品質のアノテーション結果を収集するため、1 回の作業につきチェックテストを 10 問用意し、チェックテストに対して 3 割以上誤答したワーカーの回答、1 問あたりにかかった時間が 200 秒未満の回答は棄却した。1 問あたり$4 の報酬を与えるとして、3 名にアノテーション作業を依頼した。合計 1237 名のワーカーが参加し、15339 件のアノテーションを行った。

4. 構築したデータセット

4.1 データセットの例

表 3 に構築した単調推論データの例を示す。downward monotone の 1 つ目の例のような *music* と *rock'n'roll* といった辞書的な語彙の置き換えだけでなく、2 つ目の例のような等位接続表現を挿入した例、3 つ目の例のような関係節を挿入した例、4 つ目の例のような比較表現を挿入した例と、クラウドソーシングを用いることによって多様な仮説文が構築できている。

4.2 アノテーション結果の分析

ワーカーの回答の一致率を表 4 に示す。アノテーションの一致率はおよそ 40%であるが、タスクの難易度を考えると妥当な数字である。

表 4: ワーカーの回答の一致率

	一致率/%
3 人一致	40.1
2 人一致	55.7
不一致	4.2

単調推論の性質に基づき自動付与した含意関係ラベルと、ワーカーの回答した含意関係ラベルとが一致した件数と全体における割合を表 5 に示す。自動付与した含意関係ラベルとワーカー全員の回答が一致したデータの割合は全体の約 22%に留まり、構築したデータには人が判断に迷う推論のケースが含まれていることが示唆される。

表 5: 自動付与した含意関係ラベルと一致した件数と割合

	upward /件 (%)	downward /件 (%)	合計 /件 (%)
3 人一致	1069 (7.0)	2285 (14.9)	3354 (21.9)
2 人一致	1814 (11.8)	2301 (15.0)	4115 (26.8)
1 人一致	2295 (15.0)	1915 (12.5)	4210 (27.5)
不一致	1998 (27.8)	1652 (10.8)	3650 (37.8)

4.3 エラー分析

以降はワーカー全員の含意関係ラベルの回答が一致したケース 5941 件を用いて分析を行う。単調推論の性質に基づき自動付与した含意関係ラベルと、ワーカーの回答した含意関係ラベルとが一致した件数と割合を表 6 に示す。

表 6: 自動付与した含意関係ラベルとワーカーの回答との関係

	upward /件 (%)	downward /件 (%)
一致	1069 (7.0)	2285 (14.9)
不一致	1650 (10.8)	937 (6.1)

表 6 のうち、ワーカーの回答が自動付与したラベルと一致していた例は、一見すると正しく単調推論の問題が作成でき

た例であるが、実際に単調推論の問題が作成できているのか、ランダムに 300 件抽出してエラー分析を行った。エラーとしては、以下のように仮説文作成タスクで意味的に下位の表現への置き換えができていなかったケースが約 3 割含まれていた。

類義語による置き換えのケース：次の例は *kid* と *child* が類義語であるために含意関係が成り立つケースであり、意味的に下位の表現の置き換えにはなっていないため、ここで注目している単調推論の問題ではない。

(4) *T*: *Tom is no longer a kid*
⇒ *H*: *Tom is no longer a child*

構成素が異なるケース：次の例の仮説文は、もともと前提文中の *problem* をより詳細な表現に書き換えるよう指示されて作成された仮説文であるが、*at all* は副詞であり、*problem* の構成素ではない。そのため、この例も意味的に下位の表現の置き換えにはなっておらず、単調推論の問題とはみなせない。

(5) *T*: *That should be no problem*
⇒ *H*: *That should be no problem at all*

or を含む等位接続：次の例の仮説文は、前提文中の *strangers* をより詳細な表現に書き換えるよう指示されて作成された仮説文であるが、or を含む等位接続表現の導入は 2 節で述べたように意味的に上位の表現への置き換えであり、下位の表現の置き換えではない。この場合は単調推論の問題にはなっているが、含意ではなく非含意が正しい。

(6) *T*: *Tom doesn't trust strangers*
⇏ *H*: *Tom doesn't trust acquaintances or strangers*

4.4 語用論的推論の影響

表 6 のうち、ワーカーの回答が自動付与したラベルと一致しなかった例について、なぜ不一致が起こるのかランダムに 300 件を抽出し分析を行った結果、類義語による置き換えのケースに加えて、以下のような事例があることが分かった。これらは、様々な語用論的推論によって実際に人間が認識する含意関係が単調推論によって論理的に妥当と予測される含意関係とは異なるケースとみなせる。

対比：以下の例は、単調推論としては非含意と予測される例であるが、ワーカーの回答が含意であった例である。この例では、*cucumber salad without lettuce* という表現によって、*cucumber salad with lettuce* との対比が生じている。

(7) *T*: *A horse doesn't eat cucumber salad*
⇒ *H*: *A horse doesn't eat cucumber salad without lettuce*

このため、*H* は「レタスが入っていれば食べる」という語用論的な解釈が引き起こされやすく、それがワーカーの非含意の判定に影響したと考えられる。

存在の前提：以下のケースでは、仮説文中の *everyone wearing a blue hat* が存在の前提 (presupposition) をもつと解釈するのが自然である。

(8) *T*: *I can't remember everyone*
⇒ *H*: *I can't remember everyone wearing a blue hat*

この存在の前提は前提文から意味論的には導かれないため、ワーカーの判定との間にずれが生じたものと考えられる。

5. 結論

本稿では、形式意味論の知見とクラウドソーシングを組み合わせることで単調推論のデータセットを効率的に構築する手法を提案した。構築したデータセットを分析した結果、クラウドソーシングを用いることで幅広いパターンの単調推論の問題をある程度構築できることが示唆された。また、論理的に妥当な推論と語用論的に人間が正しいと判断する推論とが食い違うケースを収集することができた。今後の展望として、構築したデータセットから 4.3 節で述べたエラーを除き、評価用データセットとして精緻にした上で、含意関係認識モデルが論理語の意味を学習できるのかについて、評価と分析を進めていく。

謝辞：本研究は JST、AIP-PRISM、JPMJCR18ZM の支援を受けたものである。

参考文献

[Abzianidze 17] Abzianidze, L., Bjerva, J., Evang, K., Haagsma, H., Noord, van R., Ludmann, P., Nguyen, D.-D., and Bos, J.: The Parallel Meaning Bank: Towards a Multilingual Corpus of Translations Annotated with Compositional Meaning Representations, in *Proc. of EACL-2017*, pp. 242–247 (2017)

[Benthem 83] Benthem, J. V.: Determiners and Logic, *Linguistics and Philosophy*, Vol. 6, No. 4, pp. 447–478 (1983)

[Bowman 15] Bowman, S. R., Angeli, G., Potts, C., and Manning, C. D.: A large annotated corpus for learning natural language inference, in *Proc. of EMNLP-2015*, pp. 632–642 (2015)

[Cooper 94] Cooper, R., Crouch, R., Eijck, van J., Fox, C., Genabith, van J., Jaspers, J., Kamp, H., Pinkal, M., Poesio, M., Pulman, S., et al.: FraCaS–A Framework for Computational Semantics, in *Deliverable*, Vol. D6 (1994)

[Dagan 13] Dagan, I., Roth, D., Sammons, M., and Zanzotto, F. M.: *Recognizing Textual Entailment: Models and Applications*, Synthesis Lectures on Human Language Technologies, Morgan & Claypool Publishers (2013)

[Devlin 18] Devlin, J., Chang, M., Lee, K., and Toutanova, K.: BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding (2018)

[Geiger 18] Geiger, A., Cases, I., Karttunen, L., and Potts, C.: Stress-Testing Neural Models of Natural Language Inference with Multiply-Quantified Sentences (2018)

[Geurts 05] Geurts, B. and Slik, van der F.: Monotonicity and Processing Load, *Journal of Semantics*, Vol. 22, No. 1, pp. 97–117 (2005)

[Gururangan 18] Gururangan, S., Swayamdipta, S., Levy, O., Schwartz, R., Bowman, S., and Smith, N. A.: Annotation Artifacts in Natural Language Inference Data, in *Proc. of NAACL HLT-2018*, pp. 107–112 (2018)

[Hu 18] Hu, H. and Moss, L. S.: Polarity Computations in Flexible Categorial Grammar, in *Proc. of *SEM 2018* (2018)

[Icard 14] Icard, T. and Moss, L.: Recent Progress in Monotonicity, *LILT*, Vol. 9, No. 7, pp. 167–194 (2014)

[Poliak 18] Poliak, A., Naradowsky, J., Haldar, A., Rudinger, R., and Van Durme, B.: Hypothesis Only Baselines in Natural Language Inference, in *Proc. of *SEM 2018*, pp. 180–191 (2018)

[Steedman 00] Steedman, M.: *The Syntactic Process*, MIT Press (2000)

[Tsuchiya 18] Tsuchiya, M.: Performance Impact Caused by Hidden Bias of Training Data for Recognizing Textual Entailment, in *Proc. of LREC-2018* (2018)

[Wang 18] Wang, A., Singh, A., Michael, J., Hill, F., Levy, O., and Bowman, S. R.: GLUE: A Multi-Task Benchmark and Analysis Platform for Natural Language Understanding (2018)

[Williams 18] Williams, A., Nangia, N., and Bowman, S.: A Broad-Coverage Challenge Corpus for Sentence Understanding through Inference, in *Proc. of NAACL HLT-2018*, pp. 1112–1122 (2018)

[Yoshikawa 17] Yoshikawa, M., Noji, H., and Matsumoto, Y.: A* CCG Parsing with a Supertag and Dependency Factored Model, in *Proc. of ACL-2017*, pp. 277–287 (2017)

[谷中 19] 谷中 瞳, 峯島 宏次, 戸次 大介, 関根 聡, 乾 健太郎, Abzianidze, L., Bos, J.F ニューラル自然言語推論に向けた Monotonicity に基づく含意関係認識データセット自動構築, 言語処理学会第 25 回年次大会発表論文集 (2019)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

ウェブ上のコラムページからのノウハウ質問応答事例の収集

Collecting Examples of Know-How Question Answering from Column Pages on the Web

前田　竜治 *1　陳 騰揚 *1　大川 遥平 *1　宇津呂 武仁 *1　河田 容英 *2
Tatsuya Maeda　Tengyang Chen　Yohei Ohkawa　Takehito Utsuro　Yasuhide Kawada

*1筑波大学大学院システム情報工学研究科　*2(株) ログワークス
Grad. Sch. Sys. & Inf. Eng, Univ. of Tsukuba　Logworks Co., Ltd.

In the area of factoid question answering, it is known that the state-of-the-art technology has achieved the accuracy comparable to human. In the area of non-factoid question answering, however, there exists a small number of data set for training question answering (i.e., machine comprehension) models. Considering such a situation, within the area of the non-factoid question answering, this paper studies how to develop a data set for training Japanese know-how question answering models.

表 1: ノウハウサイト候補のドメインに対する評価基準

ノウハウサイト	ドメインそのものがクエリ・フォーカスに関するノウハウを提示する個別ページへのリンクを一覧するページである		A 群
	ドメインそのものはクエリ・フォーカスに関するノウハウを提示する個別ページへのリンクを一覧するページではないが，ノウハウを提示する個別ページへのリンクを一覧するページが存在する	ドメイントップページから容易に辿り着ける	B 群
		ドメイントップページから容易には辿り着けない	C 群
	クエリ・フォーカスを含む話題に関するノウハウを提示するページへのリンクを一覧するページ (ドメイントップページ，ドメイントップページから容易に辿り着ける，ドメイントップページから容易には辿り着けない) が存在する		D 群
非ノウハウサイト	ノウハウを提示するページが存在しない		E 群

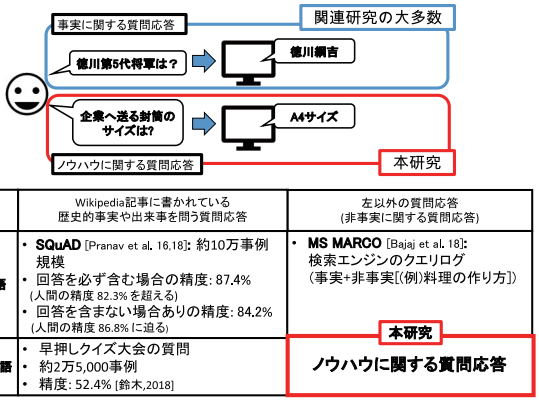


図 1: 事実に関する質問応答・非事実に関する質問応答

1. はじめに

質問応答とは，ユーザからの質問に対して，文書中から回答部分を探し出すタスクである．特に，自然言語で記述された質問文とコンテクストを与え，質問に対する回答を探すタスクを読解タスクと呼ぶ．読解タスクにおいては，近年，ニューラルネットワークを用いた読解モデルが提案され，代表的な読解タスク用データセットの一つである SQuAD [Pranav16] に対しては，人間の回答精度を上回る結果が得られることが報告されている [Devlin18]．ここで，質問応答のタスクは，固有名詞や数量等といった事実に関する内容を回答対象とする質問応答，および，目的や理由，方法等の非事実を回答対象とする質問応答の二種類に大別される (図 1)．このうち，現状の研究動向としては，例えば Wikipedia に明示的に書かれるような事実を回答対象とする研究 [Yi15, Pranav16, Pranav18] が大半を占める．そのため，非事実の典型として，ものごとのやり方を答えるノウハウや，意見を問う質問に対して的確に応答することは容易ではない．

その一方で，インターネット上には，物事のやり方に関するノウハウが多数掲載するウェブサイト (本論文では，ノウハウサイト [李 18] と呼ぶ) が多数存在し，有用なノウハウを効率よく集めることを目的として，それらのノウハウサイトを効率よく収集する手法 [李 18] も提案されている．そこで本論文では，ニューラル読解モデル (図 2) の中でも，特にノウハウに関する質問応答を対象とするニューラル読解モデル訓練のための質問応答事例データセットを作成することを目的とする．具体的には，上述のノウハウサイトにおいてノウハウが掲載されたウェブページを情報源として，ニューラル読解モデル訓練のための質問応答事例を作成する方式を提案する．特に，本論文では，ノウハウサイト中のウェブページの中でも，コラムページからのノウハウ質問応答事例作成が容易であることを示すとともに，トピックモデルを用いることにより，多様な話題のノウハウ質問応答事例を効率よく作成する方式を提案する．

連絡先: 前田 竜治，筑波大学大学院システム情報工学研究科，
〒 305-8573　茨城県つくば市天王台 1-1-1, 029-853-5427

2. ノウハウサイトの収集

本論文では，クエリ・フォーカスとして，「就活」，「結婚」，「花粉症」を対象として，[李 18] に従い，図 3 の手順に沿って，クエリ・フォーカス (図 3 の例では「就活」) に関するノウハウを多く掲載するノウハウサイトを収集する．

はじめに，Google 検索エンジンを用いて，クエリ・フォーカス「就活」についての検索エンジン・サジェストを網羅的に収集する．一文字列につき最大 10 個のサジェストが収集できること，および，一クエリ・フォーカスにつき約 100 通りの文字列 (五十音，濁点，半濁点，開やく音を含む) を指定することから，一クエリ・フォーカスあたり最大約 1,000 語のサジェストを収集できる．ウェブページ収集においては，収集したサジェストを用いて，「クエリ・フォーカス AND サジェスト」を検索

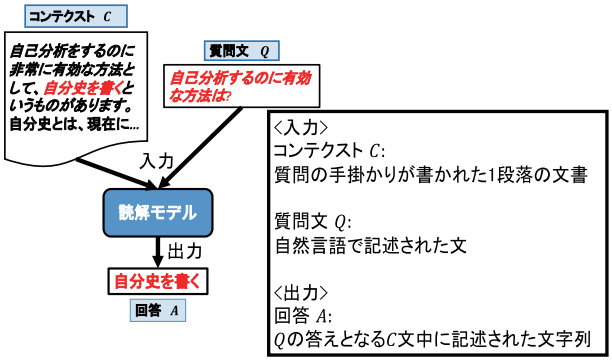


図 2: ニューラル読解モデルの概要

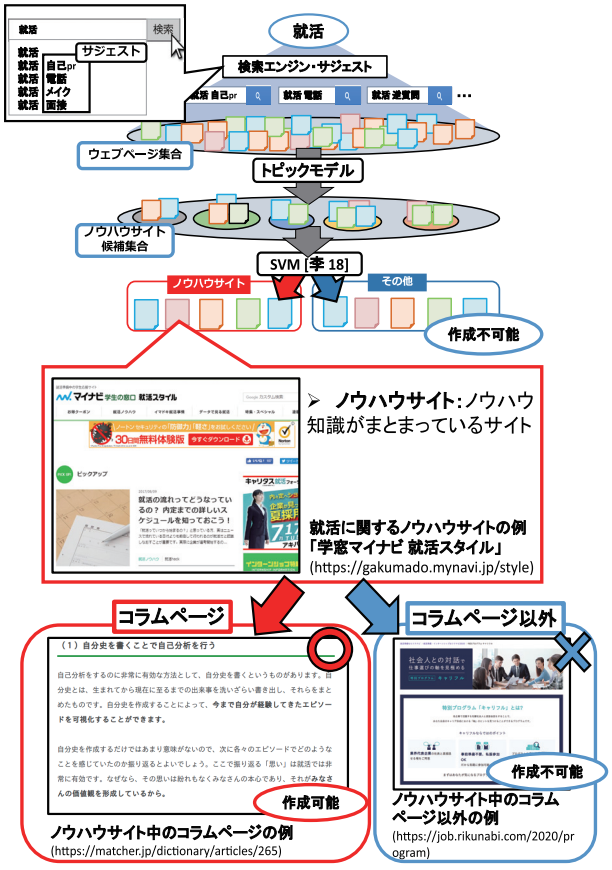


図 3: ノウハウ質問応答事例作成のためのウェブページ選定手順

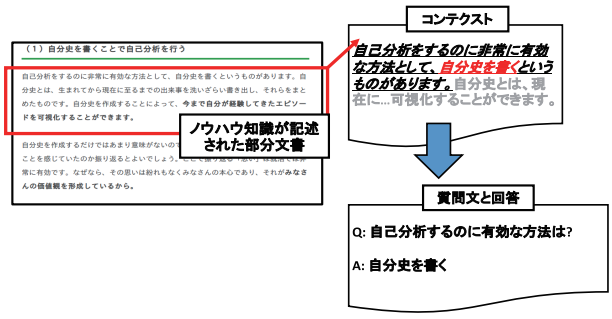


図 4: ノウハウ質問応答事例の作成例

表 2: 一ページから作成された質問応答事例数

質問応答事例数	1	2	3	4	5	計
ページ数 (%)	116 (35)	95 (28.7)	56 (16.9)	22 (6.6)	42 (12.7)	331 (100)

語とする AND 検索によって，Google Custom Search API[*1] を用いて各検索結果の上位 10 件を収集し，ウェブページ集合 D^{est} を作成する．このとき，異なるサジェストに対して検索されるウェブページが重複する際には重複を削除する [*2]．

[李 18] および本論文では，収集された各ウェブページのドメインに対して，「どの程度の数のノウハウを掲載しているか」という観点での分類を行うために，各ドメインを表 1 に示す A 群 ~E 群に分類する．表 1 の分類は，当該ドメインにおいてノウハウを一覧するページが存在するか否か，および，そのノウハウ一覧ページがドメインのトップページから容易にアクセス可能か否か，の二つの観点に基づいている．具体的には，A 群，B 群，C 群においては，ドメインのトップページからのアクセス容易性に差はあるものの，ノウハウを一覧するページが存在する点は共通している．本論文の評価においては，A 群，B 群，C 群のドメインは，ノウハウを多く掲載する「ノウハウサイト」である．一方，D 群においても，クエリ・フォーカス (図 3 の例では「就活」) そのものについてのノウハウには限定されないが，より広範囲の話題についてのノウハウを一覧するページが存在する．それらのページには，クエリ・フォーカスに関するノウハウの記述も一部含まれるため，本論文の評価においては，D 群のドメインも，ノウハウを多く掲載する「ノウハウサイト」とみなす [*3]．それに対して，「ノウハウ知識を提示するページが存在しない」E 群のサイトにおいては，本論文の評価においても，ノウハウ質問応答事例が作成できないため，「ノウハウサイト」とはみなさない [*4]．

なお，[李 18] においては，上述の A 群，B 群，C 群，(および，D 群) のノウハウサイトを効率よく収集する手法として，トピックモデルを用いてウェブページ集合の話題集約を行った結果を利用する．具体的には，まず，収集されたウェブページ集合に対して，(本論文では，トピック数 $K = 50$ として) 潜在的ディリクレ分配法 (LDA: Latent Dirichlet Allocation) [Blei03] を適用することにより，ウェブページ集合の話題集約を行う．そして，複数のトピックを横断してウェブページを持つウェブサイトに限定して，表 1 の A 群，B 群，C 群，D 群のサイトを人手で収集する．この手順をふまえて，本論文において，クエリ・フォーカス「就活」を対象とした場合には，ノウハウサイトの候補が 86 サイト得られ，そのうち，ノウハウサイトである A 群，B 群，C 群，D 群のサイト数は合計 57 サイトとなった．さらに，本論文では，以降の過程を効率的に行うため，A 群，B 群，C 群，D 群のサイトの中でも特に良質なサイトと思われるものを優先的に選定し，ノウハウ質問応答事例作成のための情報源とする．具体的には，上述の 57 サイトのうち，当該サイトのウェブページが 10 トピック以上にまたがって存在するサイトに限定した．さらにその後，以降の作業対象とするサイトを無作為に選定した結果，A 群，B 群，C 群のサイト合計 11 サイト，および，D 群のサイト 3 サイトの合計 14 サ

*1 https://developers.google.com/custom-search/

*2 「就活」に対しては，916 種類のサジェストに対して，6,762 件のウェブページが収集された．

*3 [李 18] においては，「ノウハウを掲載する個別ページは存在するものの，それらのページへのリンクを一覧するページが存在しない」ドメインを D 群と定義している．しかし，精査の結果，本論文で述べる D 群の定義がより実情に即していることが判明した．

*4 以上の議論の前提として，[李 18] では，特定のジャンルのノウハウの一覧が参照できる可能性が低いサイトとして，i) 質問回答サイト，ii) ニュースサイト，iii) 通販サイト，iv) ブログホスト中のブログサイトのウェブページ，はあらかじめ分析対象から除外しており，本論文でもこれに従う．

表 3: ノウハウ質問応答事例 (コンテクスト C・質問 Q・回答 A の組) の例

コンテクスト C	質問 Q	回答 A
履歴書に短所を書く時は前向きにまとめるようにします.「工夫して克服した」「直すように努力している」などと書けば悪いイメージの短所で好印象を与えることも可能です. 自分の短所の中で努力すれば改善しそうなものを選ぶと書きやすいでしょう.	履歴書に短所を書く時のポイントは？	前向きにまとめる
結婚式の節約術の 1 つとして，ウエディングアイテムを持ち込むという方法があります. これは，結婚式に必要なものをネットやお店で自分で探して購入したり，自分自身で手作りしたりして当日使用するということです.	結婚式の費用を節約する方法は？	ウエディングアイテムを持ち込む
そのため花粉の季節は，室内の湿度を 50〜55%ほどに保てるように加湿器を使用しましょう.	花粉の季節に保つべき室内の湿度の目安は？	50〜55%

イトを以降の作業対象のサイト集合 T とした.

3. トピックモデル訓練時に未知のウェブページのトピック分類

次に，ノウハウ質問応答事例作成の情報源として用いるサイト集合 T の各サイトに対して，そのサイト中の全ウェブページを収集し，ウェブページ集合 $D^{\mathrm{inf}}(T)$ を作成する. 次に，ウェブページ集合 $D^{\mathrm{inf}}(T)$ に対して,「検索エンジン・サジェストを用いて収集したウェブページ群によって訓練したトピックモデル」のトピック群へ分類する方式 [Blei03] を適用する. そして，各ウェブページ $d(\in D^{\mathrm{inf}}(T))$ に対して，トピックの確率分布 $P(z_n|d)$ $(n = 1, \ldots, K)$ において確率最大となるトピック z_n を割り当てることにより，トピック z_n が割り当てられたウェブページの集合を $D^{\mathrm{inf}}(z_n, T)$ とする [*5].

$$D^{\mathrm{inf}}(z_n, T) = \left\{ d \in D^{\mathrm{inf}}(T) \,\middle|\, z_n = \underset{z_u \ (u=1,\ldots,K)}{\mathrm{argmax}} P(z_u|d) \right\}$$

ここで，実際には，サイト t $(\in T)$ ごとに，確率値 $P(z_n|d)$ の上位 5 ページのみを集めた部分集合 $D^{\mathrm{inf}}(z_n, T, \text{“}\leq 5\text{”})$ を以降の作業対象とする.

4. ノウハウ質問応答事例作成の情報源としての「コラムページ」

前節までの手順においてノウハウサイト中のウェブページ集合をトピックに分類した結果を選定した. 次に，ノウハウ質問応答事例作成の情報源として有効なページ種類について分析を行った. その結果，ノウハウサイトにおけるウェブページの種類は，ノウハウが記述されたコラム，企業サイトにおける商用ページ，口コミや体験談のページに大別されるが，ノウハウ質問応答事例作成において有用なページ種類は「コラムページ」のみであることが判明した. そこで，前節において作成した $D^{\mathrm{inf}}(z_n, T, \text{“}\leq 5\text{”})$ について，要素となるウェブページを「コラムページ」のみに限定した部分集合 $D_c^{\mathrm{inf}}(z_n, T, \text{“}\leq 5\text{”})$ を作成し [*6]，この集合中の全ウェブページを以降のノウハウ質問応答事例作成の情報源として用いる.

5. ノウハウ質問応答事例の作成手順

本節では，ノウハウ質問応答事例の作成手順 (図 4) について述べる. 前節で作成したウェブページ集合 $D_c^{\mathrm{inf}}(z_n, T, \text{“}\leq 5\text{”})$ 中の全ページに対して，各ページ中の段落を対象として，以下で定義されるコンテキスト C，質問 Q，および，回答 A の組を人手で作成する.

コンテクスト C: 一段落で構成される短い部分文書であり，画像などの非テキスト情報を含まない.

質問 Q: 自然言語で記述された文.

回答 A: コンテクスト中に記述された任意の文字列.

具体的には，一ページあたり最大 5 組を上限として [*7]，ページ中の各段落に対して，コンテキスト C，質問 Q，および，回答 A の組の作成可否を判定し，作成可能な場合には，当該段落をコンテキスト C とし，質問 Q および回答 A の組とともに記録する. 一例として、ノウハウサイトの「コラムページ」 [*8] からノウハウ質問応答事例を作成する場合の模式図を図 4 に示す. この例では，コンテキスト C として

「自己分析をするのに ... 可視化することができます.」

という段落を抽出し，質問 Q として「自己分析に有効な方法は?」，Q に対する回答 A として「自分史を書く」を抽出した.

クエリ・フォーカスとして「就活」,「結婚」,「花粉症」を用いた場合のノウハウ質問応答事例各一例ずつを表 3 に示す [*9]. 表 4 に示すように，クエリ・フォーカス「就活」の場合には，ノウハウ質問応答事例作成対象となる「コラムページ」1,559 ページ中 331 ページからノウハウ質問応答事例 772 例が作成された. 一方，クエリ・フォーカス「結婚」および「花粉症」を対象としては，各 50 例のノウハウ質問応答事例を作成した.

6. トピックごとのノウハウ質問応答事例作成効率の分析

次に，クエリ・フォーカス「就活」において，3. 節の「トピックモデル訓練時に未知のウェブページのトピック分類」によってウェブページが一つ以上分類され，$|D^{\mathrm{inf}}(z_n, T)| > 0$ となった 42 トピックに対して，$D_c^{\mathrm{inf}}(z_n, T, \text{“}\leq 5\text{”})$ 中の全ページに対してノウハウ質問応答事例の作成を行い，ノウハウ質問応答事例が一つ以上作成できたページがどの程度含まれたか，を表す「ノウハウ質問応答事例作成効率」を評価する. そして，トピックごとに，この「事例作成効率」と各トピックの特徴との間の相関を分析する.

6.1 トピックごとのノウハウ質問応答事例作成効率

ウェブページ d に対して，5. 節の手順によりノウハウ質問応答事例が作成できたか否かを $qa(d) = 1$ (作成できた) または $qa(d) = 0$ (作成できなかった) によって表す. そして，$D_c^{\mathrm{inf}}(z_n, T, \text{“}\leq 5\text{”})$ 中のウェブページのうち $qa(d)=1$ (ノウハウ質問応答事例が作成できた) となるページ d のみから構成される部分集合

$$D_{qa}^{\mathrm{inf}}(z_n, T, \text{“}\leq 5\text{”}) = \left\{ d \in D_c^{\mathrm{inf}}(z_n, T, \text{“}\leq 5\text{”}) \,\middle|\, qa(d) = 1 \right\}$$

---

*5 「就活」においては，ウェブページが一つ以上分類され，$|D^{\mathrm{inf}}(z_n, T)| > 0$ となるトピックは，全 50 トピック中 42 トピックであった.

*6 「就活」において前節で $|D^{\mathrm{inf}}(z_n, T)| > 0$ となった 42 トピック中で，コラムページを含み，$|D_c^{\mathrm{inf}}(z_n, T, \text{“}\leq 5\text{”})| > 0$ となるトピックは 36 トピックであった.

*7 一ページから作成された質問応答事例数の分布を表 2 に示す.

*8 https://matcher.jp/dictionary/articles/12

*9 「就活」については，サイト集合 T に対して，3. 節の「トピックモデル訓練時に未知のウェブページのトピック分類」を経て収集しウェブページ集合 $D^{\mathrm{inf}}(T)$ を情報源として作成したノウハウ質問応答事例を示す. 一方，クエリ・フォーカス「結婚」および「花粉症」においては，本論文執筆段階では，3. 節の「トピックモデル訓練時に未知のウェブページのトピック分類」の手順が未適用であるので，本論文では，2. 節において収集したウェブページ集合 D^{est} に対してトピックモデルを適用した段階で，各トピックにおける「コラムページ」を情報源としてノウハウ質問応答事例を作成した結果を示す.

表 4: 「トピックごとのノウハウ質問応答事例作成効率」$r_{qa}^{\inf}$ の分析 (クエリ・フォーカス「就活」)

$r_{qa}^{\inf}$	トピック数	トピックの説明	質問応答事例が作成できたページ数	質問応答事例数
≥ 0.3	15	「最終面接」,「服装・髪型」,「履歴書」,「自己 PR」,「OBOG 訪問」,「面接・長所短所」,「電話マナー」,「証明写真」,「面接・逆質問・質問」,「グループディスカッション」,「ビジネスメール」,「SPI」,「封筒」,「志望動機」,「就活メイク」	818 ページ中 260 ページ	634
> 0, < 0.3	11	「選考時期・身だしなみ」,「業種紹介」,「就活情勢」,「不安・性格」,「企業選び」,「交通費」,「休暇制度」,「(特定企業の)ES 対策」,「フリーター」,「就活用語」,「人事目線の面接・体験談」	529 ページ中 54 ページ	101
	8	複数の話題が混在	212 ページ中 17 ページ	37
計	34	上記全トピック	1,559 ページ中 331 ページ	772

表 5: ノウハウ質問応答事例が作成できたトピック数 (クエリ・フォーカスごと)

クエリ・フォーカス	ノウハウ質問応答事例が作成できたトピック数 合計	個別	トピックの説明
就活	34	26	—
		8	複数の話題が混在
結婚	32	18	「婚姻届」,「ご祝儀」,「フォトウェディング」,「身内・顔合わせ」,「披露宴・ゲスト」,「結婚式・費用」,「ゲストスピーチ」,「式場選び」,「服装・身だしなみ」,「招待状・返信マナー」,「予算・時期」,「内祝い・お返し」,「海外ウェディング」,「お車代」,「結納」,「招待状」,「結婚式挨拶」,「結婚式 BGM」
		14	複数の話題が混在
花粉症	36	21	「乳酸菌・花粉症」,「抗アレルギー薬」,「お茶」,「原因と対策」,「薬の選び方」,「ヒスタミン」,「かゆみ対策・生活習慣」,「子供の花粉症治療」,「薬の副作用」,「花粉症・漢方」,「目のケア」,「咳・くしゃみ」,「仕事場でのかゆみ対策」,「飲み物」,「耳のケア」,「鼻のケア」,「病院・治療」,「注射治療」,「食べ物」,「薬の種類」,「家での対策・掃除」
		15	複数の話題が混在

を作成する．そして，次式によって「トピックごとのノウハウ質問応答事例作成効率」を定義する．

$$r_{qa}^{\inf}(z_n, T, \text{“}\leq 5\text{”}) \quad = \quad \frac{\left|D_{qa}^{\inf}(z_n, T, \text{“}\leq 5\text{”})\right|}{\left|D_{c}^{\inf}(z_n, T, \text{“}\leq 5\text{”})\right|}$$

6.2 分析結果

経験的には，$r_{qa}^{\inf} \geq 0.3$ となるか，$0 < r_{qa}^{\inf} < 0.3$ となるかによって，トピックごとの「事例作成効率」の良否の判断が分かれる．そこで，クエリ・フォーカス「就活」における分析対象の 36 トピック (実際に対象となるのは 34 トピック)[*10] を，$r_{qa}^{\inf} \geq 0.3$ となる 15 トピック，および，$0 < r_{qa}^{\inf} < 0.3$ となる 19 トピックに二分し，各トピックの特徴を列挙した結果を表 4 に示す.「ノウハウ質問応答事例作成効率」が相対的に高い 15 トピックは，いずれも,「就活」のノウハウにおいて必要不可欠であり，かつ，中心的話題として位置付けられる内容で占められている．一方,「ノウハウ質問応答事例作成効率」が相対的に低い 19 トピックは，単一の話題で占められる 11 トピック，および,「複数の話題が混在」する 8 トピックに分けられる．このうち，単一の話題で占められる 11 トピックにおいても，$r_{qa}^{\inf} \geq 0.3$ となる 15 トピックと比較すると，ノウハウとしての重要度が相対的に低いトピックが観測される．その他,「結婚」,「花粉症」に対して「ノウハウ質問応答事例が作成できたトピック数」を表 5 に示す.

7. 関連研究

本論文に関連して，事実に関する読解タスク用データセットとして，英語を対象とした SQuAD [Pranav16,Pranav18]，および，日本語を対象とした解答可能性付き読解データセット [鈴木 18] が挙げられる．SQuAD は，英語版 Wikipedia 記事中の段落をコンテクストとして，クラウドソーシングにより質問・回答を付与した約 10 万件の質問応答事例から構成される．同様に，解答可能性付き読解データセット [鈴木 18] は，日本語の早押しクイズ大会の約 12,000 件の質問文・回答に対して，回答の文字列が含まれる日本語版 Wikipedia 記事中の段落から選定したコンテクストを付与した質問応答事例から構成される．一方，[山本 19] においては，本論文において作成したノウハウ質問応答事例を訓練・評価事例として，ニューラル読解モデル [*11] への適用を行い，ノウハウ質問応答において一定レベルの性能を達成している．

8. おわりに

本論文では，ノウハウサイト中のウェブページの中でも，コラムページからのノウハウ質問応答事例作成が容易であることを示すとともに，トピックモデルを用いることにより，多様な話題のノウハウ質問応答事例を効率よく作成する方式を提案し，クエリ・フォーカス「就活」を対象として，提案方式の有効性を検証した．今後の課題としては，クエリ・フォーカスとして,「結婚」,「花粉症」を含む多様な話題を対象として大規模なノウハウ質問応答事例を作成するとともに，[山本 19] におけるノウハウ質問応答の評価を大規模化して，本論文のアプローチの有効性を検証することが挙げられる．

参考文献

[Blei03] Blei, D. M., Ng, A. Y. and Jordan, M. I.: Latent Dirichlet Allocation, *Journal of Machine Learning Research*, Vol. 3, pp. 993–1022 (2003).

[Devlin18] Devlin, J., Chang, M.-W., Lee, K. and Toutanova, K.: BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding, *CoRR*, Vol. abs/1810.04805 (2018).

[李 18] 李佳奇, 趙辰, 林友超, 丁易, 川畑修人, 宇津呂武仁, 河田容英：トピックモデルおよび分類器学習を用いたノウハウサイトの同定, 第 10 回 DEIM フォーラム論文集 (2018).

[Pranav16] Pranav, R., Jian, Z., Konstantin, L. and Percy, L.: SQuAD: 100,000+ Questions for Machine Comprehension of Text, *Proc. EMNLP*, pp. 2383–2392 (2016).

[Pranav18] Pranav, R., Robin, J. and Percy, L.: Know What You Don't Know: Unanswerable Questions for SQuAD, *Proc. 56th ACL*, pp. 784–789 (2018).

[Seo17] Seo, M. J., Kembhavi, A., Farhadi, A. and Hajishirzi, H.: Bidirectional Attention Flow for Machine Comprehension, *Proc. 5th ICLR* (2017).

[鈴木 18] 鈴木正敏, 松田耕史, 岡崎直観, 乾健太郎：読解による解答可能性を付与した質問応答データセットの構築, 言語処理学会第 24 回年次大会論文集, pp. 702–705 (2018).

[山本 19] 山本航平, 前田竜治, 陳騰揚, 川畑修人, 大川遥平, 宇津呂武仁, 河田容英：ノウハウ質問応答におけるニューラル読解モデルの評価, 言語処理学会第 25 回年次大会論文集 (2019).

[Yi15] Yi, Y., Wen-tau, Y. and Christopher, M.: WikiQA: A Challenge Dataset for Open-Domain Question Answering, *Proc. EMNLP*, pp. 2013–2018 (2015).

*10 4. 節で $|D_c^{\inf}(z_n, T, \text{“}\leq 5\text{”})| > 0$ となった 36 トピックのうち,「複数の話題が混在」する 2 トピックにおいて，結果的には「ノウハウ質問応答事例」が作成できず，$r_{qa}^{\inf} = 0$ となった.

*11 事実に関する大規模読解用訓練事例データセットである SQuAD に対する適用実績のある BiDAF [Seo17] を採用した.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

対話型実習補助システム「V-TA」

V-TA: Dialogue System for Practical Training on Software Development

大谷　雅之 *1　川端　卓 *2　阿部　孝司 *1　山本　博史 *1　高田　司郎 *1
Masayuki Otani#1　Taku Kawabata#2　Koji Abe#1　Hirofumi Yamamoto#1　Shiro Takata#1
赤松　芳彦 *2　山村　富士子 *2
Yoshihiko Akamatsu#2　Fujiko Yamamura#2

*1近畿大学　*2株式会社 JIEC
Kindai University#1　JIEC Co.,Ltd. #2

This manuscript reports the results and findings obtained by the operation of the dialogue system “V-TA” that is used in a practical training class in Kindai University “Media Informatics Project II”. Our 4 month operation revealed the following implications: (i) Cooperation between Students, TAs, and Lecturers accelerates efficient collection of dialogue corpus; (ii) V-TA plays a role as a feedback collection mechanism from students for a class; and (iii) V-TA halves the cost of QA tasks since it can correctly answer questions from students with 56% probability.

1.　はじめに

大学などで実施される実習形式の授業では，講義による座学よりも受講生自身で考えて課題に取り組むことが中心となる．授業の進め方としては，講師や TA(ティーチング・アシスタント) が，受講生一人一人の質問や相談にその都度取り組むことが一般的である．このような授業形態では，少数の受講生が対象であれば問題ないが，受講生が多数になる場合には，講師や TA の数もそれに伴って増員する必要があり，講義形式の授業に比べてコストが肥大化する．

近畿大学では，実習における講師や TA の負担を軽減するために，質問応答型の対話システムを実際の実習に適用する試みを行った．本稿では，その運用過程で得られた知見を報告する．具体的には，2018 年 10 月に近畿大学理工学部情報学科で開講された「情報メディアプロジェクト II」に，株式会社 JIEC が開発した対話システム「manaBrain*1」を授業に関する質問に答えるようカスタマイズした「V-TA」を適用した．データの収集，整備やそれを用いたシステムのチューニングを，学生，TA，講師が連携して反復実施するモデルを用いて約半年間の運用を行った．

2.　これまでの対話システム運用事例

対話システムはこれまでに様々なものが提案され，実際に商用利用されているものも多い．例えば，京都大学では，1999 年に計算機室におけるアプリケーションの初歩的な質問を受け付ける対話システムを実際に運用している [日笠 99]．一方，商用サービスでは，Apple の iPhone などに搭載されている「Siri」や，docomo の「しゃべってコンシェル」，Microsoft が開発した「りんな」などが実際に広く利用されている．これらのシステムは，適用する領域を絞り，その領域に関する専門知識のコーパスを大量に収集し，機械学習などを通して統計的に対話モデルを構築する．この場合，精度の高い対話システムを運用するには，データの質と量が重要となる．

連絡先: 大谷雅之，近畿大学理工学部情報学科，577-8502　大阪府東大阪市小若江 3-4-1，06-4307-3520，otani@info.kindai.ac.jp

*1　manaBrain 公式サイト：https://manabrain.biz/

しかし，対話システムの適用領域を絞ったとしても，事前に十分な量と質を保ったデータが得られるとは限らない．機械学習に用いるデータの不足は世界的な問題となっており，少量のデータセットによって精度の高いモデルを構築する研究も行われている [Tulsyan 2018]．少量のデータセットを用いる場合は，対話モデルがデータセットの品質に左右されるという問題がある．これに対し，本稿ではデータ収集方法に着目し，対話システムを運用しながらデータを収集するアプローチを取る．

3.　対話システムを用いた実習補佐

3.1　大学の実習における質問対応業務

実学を重視する近畿大学では実習形式の授業が多く取り入れられている．同学の理工学部情報学科では，学部 1〜3 年生の各学年で，約 100〜200 名を対象とする大規模な実習が必修科目として実施されている．これらの実習では，授業運営のために多くの専任教員と TA が動員されており，多大なコストを要している（受講生 100 名あたり合計 10 名程度）．

専任教員と TA の主な業務に，受講生からの授業に関する質問に答える「質問対応」がある．質問対応では，しばしば同じ内容の質問が発生するが，実習では各受講生の質問にその都度対応する必要があり，同じ内容の回答を繰り返すことになる．頻度が高い質問の場合は，受講生全体に向けた説明を行うことでその後の説明を省略することも可能だが，質問頻度を事前に予測することは困難である．

3.2　対話システム「V-TA」による質問応答業務の補助

近畿大学では，上記の実習における質問対応業務を軽減するため，理工学部情報学科の実習「情報メディアプロジェクト II（受講生 91 名）」において，受講生からの質問に応答する質問応答型の対話システム「V-TA」を導入し，2018 年度後期（10 月〜3 月）の授業補佐として運用した．本システムは，株式会社 JIEC が開発した「manaBrain」という対話システムをベースとして，授業に関する質問に応答するよう設計した．

対話システムの運用では，いかに学習データを収集・整備し，対話モデルを学習するか，という点が課題となる．これに対し，本システムの運用においては，(i) 受講生を利用したデータの収集，(ii)TA による収集したデータの整備，(iii) 担

当講師（教員）によるデータ収集状況の監督，という三つの役割に分け，それぞれの役割を反復的に行うモデルを採用した．本システムの全体像を図 1 に示す．

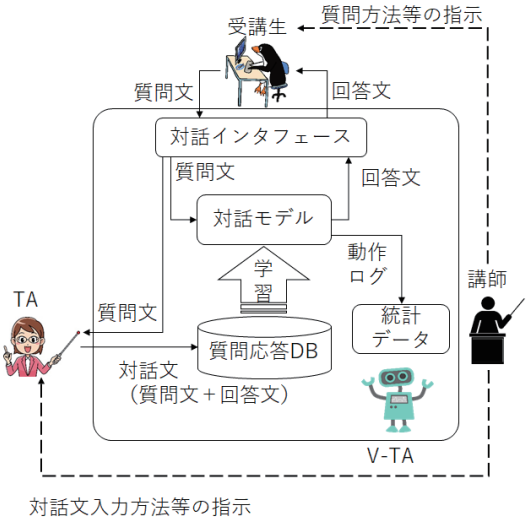


図 1: 対話システム「V-TA」の全体像

具体的には，(i) 受講生は，実習中に質問したい事柄を V-TA に入力し，疑問が解決できない場合に TA を呼ぶように指示した．また，各受講生に「授業に関して質問したいこと，疑問に思ったこと」を三件ずつ報告するよう指示した．これにより，授業に関する質問文が定期的に収集されるようにした．(ii) 収集された質問文については，対応する応答文がないため，4 名の TA が応答文の作成と質問文の整備を行い，授業終了後に V-TA に入力を行うようにした．(iii) 担当講師は，データを提供する受講生に対し，データ収集の方法を指示し，データ収集が滞りなく行われるように監督する．また，データの収集状況を確認し，頻度の高い質問については，次年度の実習資料で追加説明を行う予定である．

4. 結果・考察

4.1 収集されたデータについて

本システムの運用結果について報告する．まず，収集されたデータについては，受講生が V-TA に入力した質問文が 1589 件あった．このうち，「あ」や「ラーメン」のような質問になっていない入力や，「1+1 は？」など授業とは関係のない質問が 776 件あり，これらを無効質問と見なした．残りの 813 件の質問は V-TA の学習に利用できる有効質問と見なした．また，各回の実習で，各受講生から三件ずつ報告させた質問文が 1732 件あった．このうち有効質問と見なした 1014 件のうち，頻度の高い質問 51 件をシステムに登録した．表 1 に，実際にシステムに登録した質問文の一部を示す．一番多い質問で，36 名の受講者が同じ事項を尋ねている．本実習の受講者数は 91 名であるため，約 4 割の受講者が疑問を感じる内容であり，次年度にも同様の質問が来ることが予想される．このような頻度の高い質問に対しては，次年度の実習開講前にシステムに組み込んでおくことで，質問対応業務の軽減が期待できる．

4.2 対話システムの精度評価

次に，本システムがどの程度受講生からの質問に答えられたかを分析した．V-TA には，質問の入力を行った後に，応答文の適切さを Good と Bad の二段階で判断するための二つのボタンを実装してあり，受講者には質問入力時にどちらかのボタンを押すよう指示した．その結果，授業に関する有効質問 792 件の中で，Good の評価を得たものは 451 件であり，受講生からの約 56%の質問について回答可能であることが明らかになった．すなわち，V-TA は受講生からの質問のうち，約半数に回答可能であり，質問応答業務のコストを半減可能なシステムであると言える．

表 1: 授業後に登録された質問応答文の例

質問内容	質問者数
If bot recognizes で true を選択したとき具体的にはどのような処理になっているのでしょうか	36
Jump to を行う意味がわからないので教えてくれませんか？	35
Add node でノードの増やし方が分からなかったので質問した	9
input.txt は何を意味しているのですか？	8
intents と entities のファイルは csv でないといけないのか？	7
entity を増やすにはどうしたらいいのでしょう？	7
実際に飲食店の検索結果を表示したい場合，どうすればいいか知りたい．	5
Watson assistant には他にどのような機能がありますか？	4

4.3 対話データの収集能力について

本システムでは，無効な質問も含めて，受講者から約 1547 件の質問文をデータとして取得しているが，これは V-TA 導入以前の実習においては，本来得ることができなかったデータである．頻出している質問に対しては，そのうちのいくつかを対象として次年度実習に生かすことはできるが，全ての質問を網羅することは困難である．また，導入当初に想定していなかった講義運営に関する質問も多く，受講生が求めるものが講師の想定と異なるという気づきも得られた．したがって，本システムを授業補佐のためのシステムとして捉えると，授業に関する受講者の質問や疑問，ニーズなどのフィードバックを効率的に収集する役割を持っていると見なせる．

5. まとめ

本稿では，近畿大学の実習において授業補助を行う対話システム「V-TA」の運用を行う過程で得られた知見をまとめた．具体的には，以下の成果が得られた．(1) 対話データの収集と整備，およびデータ収集作業の監督を，受講者，TA，講師がそれぞれ行うモデルによって，効率的にデータ収集を行う仕組みを実現した．(2)V-TA は，実習に対する受講者の疑問やニーズを効率的に収集する，フィードバック機構としての役割を有することを明らかにした．(3)V-TA は学生の質問に対し 56%正しい回答を行い，質問応答業務のコストを半減することに成功した．

参考文献

[日笠 99] 日笠亘，藤井綱貴，黒橋禎夫．入力質問と知識表現の柔軟なマッチングによる対話的ヘルプシステムの構築．情報処理学会研究報告自然言語処理 (NL) 1999.95 (1999-NL-134) (1999): 101-108.

[Tulsyan 2018] Tulsyan, A., Garvin, C., and ndey, C.: “Advances in industrial biopharmaceutical batch process monitoring: Machine- learning methods for small data problems.” *Biotechnology and bioengineering*, Vol. 115, Issue 8, pp. 1915–1924, 2018.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

ニュースアプリケーションのパーソナライゼーションアルゴリズムに対するマルチリービング手法の比較

A Comparison of Multileaving Methods on News App Personalization

飯塚洸二郎　米田武　関喜史

株式会社 Gunosy

In this paper, we describe the online evaluation method for personalization. Recently, interleaving or multileaving has been recognized as an efficient method for online evaluation. We applied the multileaving method for personalized mobile news application. Experimental results showed that optimized multileaving (OM) and team draft multileaving (TDM) had an almost same efficiency and TDM was more stable. In addition, OM and TDM evaluated the personalized rankings precisely with significantly smaller sample sizes than A/B testing.

1. はじめに

ニュースアプリケーションにおいて，各ユーザーの趣向に合うニュース記事をパーソナライズして推薦することはサービスの重要な価値の一つである [3, 6]．一方で，機械学習技術の発展に伴い，パーソナライズを行うアルゴリズムは多岐にわたり，どのアルゴリズム・パラメータがサービスに適するかを正確に評価することは一般に困難を伴う [1]．また，オンライン評価を行う上で，ユーザー体験を損なわないように，いかに少ないサンプルサイズでアルゴリズムの性能の評価を行うことができるかが課題であった [10]．

その中で，マルチリービングは近年発展してきたランキング評価手法であり [9]，少ないサンプルサイズで複数のランキングアルゴリズムを効率的に評価できることが知られている [2, 5]．しかし，ニュースアプリケーションにおいて，パーソナライズされたランキングにマルチリービングを適応することは，今まで理論的に考察されたことがなかった．ニュースアプリケーションのパーソナライゼーションランキングには以下の特徴がある．

1. ランキングは時間に依存して常に変化する
2. ランキングが長い

またユーザーのリクエストに応じて即時にマルチリービングを適応することは，システム面でも負荷が大きく大規模な実験は行われていなかった．

そこで，本研究ではニュースアプリケーションにおけるパーソナライゼーションアルゴリズムについて，実システムでのオンライン実験を通して以下の 3 点を検証する．

1. 正確に性能を評価できるか．
2. 従来の A/B テストに比べ，どれほど早く結果が収束するか．どのマルチリービング手法が効率的か．
3. どれほど結果に安定性があるか．

ニュースアプリケーションランキングの特性を持つ実システム上でマルチリービングを適応した事例は本研究が初めてである．また SNS のタイムラインなど，同様の特徴を持つサービスにも本研究結果は応用できる可能性が高く，適応範囲は広い．

オンライン実験により，マルチリービングは従来の A/B テストよりも非常に少ないサンプルサイズでパーソナライゼーションアルゴリズムの性能を評価することができた．また，Team Draft Multileaving (TDM) と Optimized Multileaving (OM) では，結果の収束は同程度の早さであったが，OM ではアルゴリズムの優劣を正しく評価できないケースがあった．

Contact:
kojiro.iizuka@gunosy.com,
takeshi.yoneda@gunosy.com,
yoshifumi.seki@gunosy.com

2. マルチリービングの手法

マルチリービングは，複数のランキング集合 $\mathcal{I} = \{I_1, I_2, \ldots, I_n\}$ を入力として，混合ランキング集合 $\mathcal{O} = \{O_1, O_2, \ldots, O_m\}$ 生成し、複数のランキングを評価する手法である [4, 9]．ここで，混合ランキング O_k の各々の長さは l とする．入力ランキング I_j と出力ランキング O_j の i 番目のアイテムは $I_{j,i}$ と $O_{j,i}$ と記す．ユーザーのリクエストに応じて，出力ランキング O_k を p_k の確率で出力し，ユーザーのクリックによるフィードバックを観測する．$O_{k,i}$ がユーザーによりクリックされた際に，$\delta(O_{k,i}, I_j)$ を入力ランキング I_j に credit として与える．δ はマルチリービングの手法によって異なる．基本的には，高い credit をもつ入力ランキングが優れていると評価される．マルチリービングの各手法は，$\mathcal{I}$ から $\mathcal{O}$ を作成し，O_k を確率 p_k により出力し，credit を観測することに一般化される．以下では，TDM[9] と OM[7] の詳細について述べる．

2.1 Team Draft Multileaving

TDM は入力ランキングをランダムに選択し，まだ出力ランキングに選択されていないアイテムを出力ランキングに繰り返し追加する手法である [4]．具体的な処理は Algorithm 1 に記載する．出力ランキングに選ばれているランキングリストのアイテム数が少ないものの中からランダムに入力ランキング I_j を選択し，I_j の中で最もランキングが高いアイテムを出力ランキング O_k に追加することを繰り返し，長さ l のランキング O_k を作成する．追加されたアイテムは I_j の $team(T_{k,j})$ にも追加される．$team(T_{k,j})$ は出力ランキング O_k の入力ランキング I_j から選ばれたアイテムの集合である．TDM の credit は，クリックされたアイテムが所属するチームに加算される．$O_{k,i} \in T_{k,j}$ であれば，$\delta(O_{k,i}, I_j) = 1$ であり，そうでなければ 0 と定義する．出力確率 p_k はすべての出力ランキングに等しく $p_k = 1/m$ である．

Algorithm 1: Team Draft Multileaving

input: Input rankings I,number of output ranking m, and number of items in each output ranking l

$O = \{\}$ and **for** $k = 1, \ldots, m, j = 1, \ldots, n$ **do** $T_{k,j} = \{\}$;
for $k = 1, \ldots, m$ **do**
  for $i = 1, \ldots, l$ **do**
    Select j randomly s.t. $|T_{k,j}|$ is minimized
    $r = 1$
    while $I_{j,r} \in O_k$ **do** $r = r + 1$;
    if $r \leq |I_j|$ **then**
      $O_{k,i} = I_{j,r}$ and $T_{k,j} = T_{k,j} \cup \{I_{j,r}\}$
  end
  $O = O \cup \{O_k\}$
end
return O;

2.2 Optimized Multileaving

Algorithm 2: Optimized Multileaving

input: Input rankings I,number of output ranking m, and number of items in each output ranking l

$O = \{\}$
for $k = 1, \ldots, m$ **do**
  for $i = 1, \ldots, l$ **do**
    Select j randomly
    $r = 1$
    while $I_{j,r} \in O_k$ **do** $r = r + 1$;
    if $r \leq |I_j|$ **then** $O_{k,i} = I_{j,r}$;
  end
  $O = O \cup \{O_k\}$
end
return O;

OM は，sensitivity と bias によって定式化された最適化問題を解くことで各出力ランキングに対する出力確率を得る手法である [4]．各出力ランキング O_k は Algorithm 2 によって生成する．ここで，sensitivity とは，出力ランキングがユーザーに提示された際にどの入力ランキングが優れているかを識別できる力を表す．bias とは，ランダムクリックに対する各入力ランキングの credit の差を表す．bias が大きい場合，本来は差がないランキングにも特定のランキングに不当に高い credit が与えられてしまう．OM では，bias を抑えつつ，sensitivity を最大化することを目指す．多くの研究では，sensitivity の最大化の代わりに insensitivity(σ) の最小化によって定式化される．insensitivity は，ランキングの順位に依存した credit の和と，平均 credit である $\mu_k = \frac{1}{n}\sum_{j=1}^{n}\sum_{i=1}^{l} f(i)\delta(O_{k,i}, I_j)$ の分散によって以下のように定義される．

$$\sigma_k^2 = \sum_{j=1}^{n}\Big(\sum_{i=1}^{l} f(i)\delta(O_{k,i}, I_j) - \mu_k\Big)^2$$

最適化問題としての定式化は以下の通りである．

$$\min_{p_k} \quad \sum_{k}^{m} p_k \sigma_k^2$$

subject to

$$\sum_{k=1}^{m} p_k = 1, \quad 0 \leq p_k \leq 1 \quad (k = 1, \ldots, m)$$

$$(\forall r, j, \exists c_r) \sum_{k=1}^{m}\left(p_k \sum_{i=1}^{r}\delta(O_{k,i}, I_j)\right) = c_r$$

credit 関数は様々な種類が考案されているが，代表的なものの多くは入力ランキングの位置を用いている．例えば，入力ランキングの位置の符号を逆転させたもの $\delta(O_{k,i}, I_j) = -i$ や入力ランキングの逆数を使ったもの $\delta(O_{k,i}, I_j) = 1/i$ がある．いずれも $O_{k,i} \in I_j$ の場合であり，そうでなければ $1/(|I_j|+1)$ とする．

3. 実験

日本のニュースアプリケーションであるグノシーにおいてオンライン実験を行った．Fig1 にサービス画面を示す．グノシーでは，ユーザーのクリックログを用いてパーソナライゼーションアルゴリズムによりユーザーに記事を推薦している．



Fig 1: グノシーのサービス画面

3.1 評価手法

OM の定式化は，線形計画問題であるため解を求めることはできるが，実システム上でユーザーのリクエストのたびにこの問題を解くことは現実的でない．そこで，ニュースアプリケーションでパーソナライズする際は同じ入力ランキングはユーザーに少数回しか表示されないことを利用し，下記の定式化を提案する．

$$\arg\min_{k} \quad \alpha\sum_{r=1}^{l}\lambda_r + \sigma_k^2$$

subject to

$$(\forall r, j, j')|\sum_{i=1}^{r}\delta(O_{k,i}, I_j) - \sum_{i=1}^{r}\delta(O_{k,i}, I_{j'})| \leq \lambda_r$$

bias 項 λ を目的関数に組み込み，ハイパパラメータ α によって調整する．この式の bias の扱いは，真鍋ら [5] の定式化において，ある出力確率のみ 1 にしたものに等しい．

ニュースアプリケーションにおいて，ランキングは長いため credit 関数に入力ランキングの位置をそのまま使うとノイズが

多くなってしまう懸念がある．ランキングリストの長いニュースアプリケーションにおいて，位置の符号を逆転させた credit ではランキング上位同士の差がランキング上位と下位の差に比べて相対的に非常に小さくなる．また，位置の逆数を使ったものではランキング中盤以降の credit はほぼ 0 になってしまう．そこで，出力アイテムの入力ランキングでの順序を用いた credit を提案する．

$$\delta(O_{k,i}, I_j) = -|\{j^{'} | rank(O_{k,i}, I_{j'}) < rank(O_{k,i}, I_j)\}|$$

ここで，$rank(O_{k,i}, I_j)$ はアイテム $O_{k,i}$ のランキング I_j における位置を表し，もしアイテムがランキングに存在しなければ $|I_j|+1$ とする．

このパーソナライズされたニュースランキングに特化させた OM を OM (rank order) と呼ぶ．また 2. で紹介した位置の逆数の credit を用いた OM を OM (inverse) とよび，TDM, OM (rank order) ，OM (inverse) の効率性，安定性を比較する．

3.2 実験設定

まず bias を調整する α に関して insensitivity よりも十分に大きい $\alpha = 1000$ と bias を考慮しない $\alpha = 0$ を用いて bias と insensitivity を測定し，ハイパパラメータによる bias と insensitivity の振る舞いを観察した．ここでは，bias のスケールを揃えるため，bias を $(1/l)\sum_{r=1}^{l}(1 - \min_j \delta(O_{k,i}, I_j))/\max_{j'} \delta(O_{k,i}, I_{j'})$ として計算した．

次に，パーソナライゼーションアルゴリズムを 5 つ用意し，マルチリービングの手法ごとにパーソナライゼーションアルゴリズムの性能が評価できるか調査した．事前の A/B テストにより，各パーソナライゼーションアルゴリズムの Click Through Rate (CTR) は Table1 の通りであった．CTR はクリック数を記事表示回数で割ったものであり，CTR が高ければ高いほど記事表示回数に対してクリック数が多くなる．

Table 1: 各アルゴリズムごとの CTR の差異

Method	Difference From algo 0	algo 1	algo 2	algo 3
algo 1	0.0023			
algo 2	0.0045	0.0022		
algo 3	0.0049	0.0026	0.0004	
algo 4	0.0061	0.0038	0.0016	0.0012

例えば，Table1 の 0.0023 の値は，algo 1 から algo 0 の CTR を引いた値を表している．各アルゴリズム間の CTR の差は微小であり，アルゴリズムの優劣は algo 0 < algo 1 < algo 2 < algo 3 < algo 4 であった．

テスト期間は 2019/1/19 から 2019/1/26 の一週間で，全体から一部のユーザーを選びテストを行った．テスト期間中の総記事表示回数は 10,826,923 回であった．また，各ランキングの最大長は 120 程度であった．実験で使用したライブラリは外部に公開している [*1]．

3.3 結果

α に関する実験では，$\alpha = 1000$ と $\alpha = 0$ のいずれでも bias と insensitivity に大きな差が見られなかった．そのため，以下では簡単のため $\alpha = 0$ を用いて議論する．

Fig2 は，横軸を bias，縦軸を insensitivity としてプロットした図である．TDM に比べて OM は insensitivity が低くなっている．一方で，TDM は bias は 0.26 の定数値であり，OM の bias の分散は大きい．

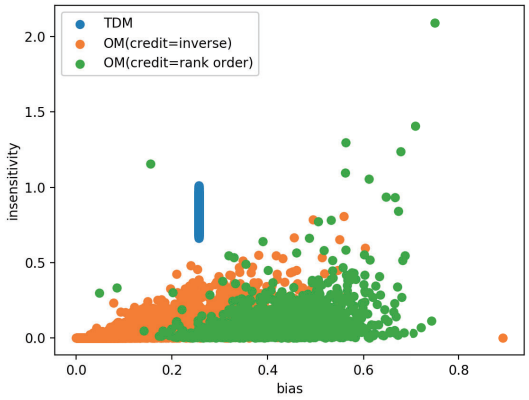


Fig 2: bias と insensitivity の散布図

Table2 は，OM と TDM の credit 総和の各アルゴリズム間の差である．TDM は，事前の CTR によるアルゴリズムの優劣と同じ結果が得られている．一方で，OM は credit によって，結果が異なっていた．出力アイテムの入力ランキングでの順序を用いた OM (rank order) は正しく性能を評価できていたが，位置の逆数を用いた OM (inverse) は正しく評価できていなかった．

Fig3 は，非復元のブートストラップ法 (標本数 50) を用いた通常の A/B テストとマルチリービングの結果の収束の早さを表している．横軸は，ユーザ数 N を表している．縦軸は OM, TDM では対応のある t 検定の p 値であり，ユーザー数 N を割り当てている．A/B テストにおいては，縦軸は対応のない t 検定の p 値（クリック数により算出）であり，比較する 2 つのアルゴリズムごとに $N/2$ のユーザを割り当てている．

3.4 考察

パーソナライズされたランキングは，ユーザに少数回しか表示されないため，bias と insensitivity がハイパパラメータによって調整しにくい性質が確認された．

A/B テストに比べ，マルチリービングは結果の収束が早いことが見て取れる．また A/B テストの algo 3 に属していたユーザーは，他のグループに比べ記事表示数自体が少なかったため相対的にクリック数も少なく，一部結果は収束しなかった．一方で，マルチリービングでは同一のユーザー群で比較実験が行えるため，ユーザー群に選ばれたユーザー固有の特性によって結果が左右されないことも長所の 1 つである．

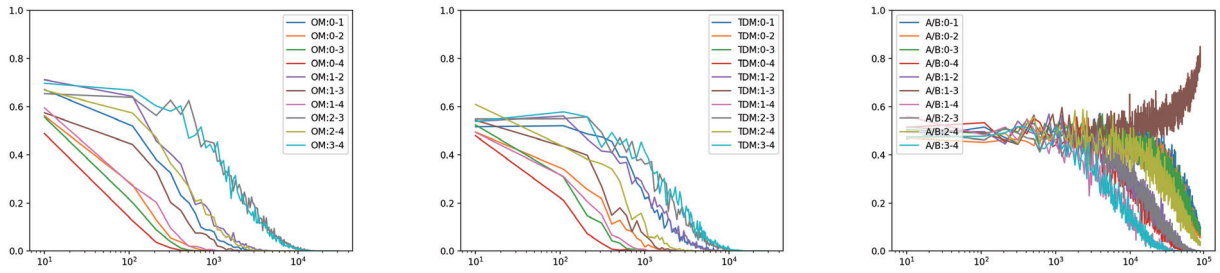
OM は TDM に比べ高い sensitiviy が得られていた．しかし，OM と TDM は同程度の効率性であった．これは TDM に比べ OM は bias の分散が大きいことが理由である．また，OM の credit 関数によっては，パーソナライゼーションアルゴリズムの優劣を正しく評価できないケースがあった．これは位置の逆数を用いた credit では，ランキングが長いケースでのノイズが大きくなったことに起因する．

*1 https://github.com/mathetake/intergo/tree/v0.1.3

Table 2: credit 総和の差: 左から OM(credit=rank order), TDM, OM(credit=inverse)

Method	algo 0	algo 1	algo 2	algo 3	algo 0	algo 1	algo 2	algo 3	algo 0	algo 1	algo 2	algo 3
algo 1	21,111				615				-14,962			
algo 2	36,561	15,450			1,259	644			-21,642	-6,680		
algo 3	44,484	23,373	7,923		1,812	1,197	553		-24,179	-9,217	-2,537	
algo 4	52,597	31,486	16,036	8,113	2,117	1,502	858	305	-5,246	9,716	16,396	18,933

Fig 3: p 値: 左から OM(credit=rank order), TDM, A/B testing



4. まとめと今後の課題

本論文では，ニュースアプリケーションにおけるパーソナライゼーションアルゴリズムのオンライン評価を行う手法について述べた．特に，マルチリービングを実システムにおいてリアルタイムに行う際の課題・解決法を示し，大規模な数値実験を行った．ニュースアプリケーションの特性をもつランキングをマルチリービングを用いて評価したのは，本実験が初めてとなる．

実システム上での大規模なオンライン実験の結果，マルチリービングはパーソナライゼーションアルゴリズムを従来の A/B テストに比べて少ないサンプルサイズで正確に評価することができた．OM では，パーソナライゼーションランキングがユーザーに少ない回数しか表示されない性質を利用した定式化を行った．さらに，新たな credit 関数を提案し有用性を確認した．また，bias と insensitivity からマルチリービングの手法ごとの効率性と安定性について議論した．今後は，より bias の分散が低くかつ高い sensitivity を持つ credit 関数を設計することが課題である．

参考文献

[1] Deepak Agarwal, Kinjal Basu, Souvik Ghosh, Ying Xuan, Yang Yang, and Liang Zhang. 2018. Online Parameter Selection for Web based Ranking Problems. In KDD. 23-32.

[2] Olivier Chapelle, Thorsten Joachims, Filip Radlinski, and Yisong Yue. 2012. Large scale Validation and Analysis of Interleaved Search Evaluation. In ACM TOIS 30, 1 (2012), 6.

[3] Abhinandan Das, Mayur Datar, Ashutosh Garg, and Shyam Rajaram. 2007. Google News Personalization: Scalable Online Collaborative Filtering. In WWW. 271-280.

[4] 加藤 誠, 山本 岳洋, 真鍋 知博, 西田 成臣, and 藤田 澄男. 2018. コミュニティQA サイトにおける質問検索システムの大規模オンライン評価. In DEIM.

[5] Tomohiro Manabe, Akiomi Nishida, Makoto P. Kato, Takehiro Yamamoto, and Sumio Fujita. 2017. A Comparative Live Evaluation of Multileaving Methods on a Commercial cQA Search. In SIGIR. 949-952

[6] Shumpei Okura, Yukihiro Tagami, Shingo Ono, and Akira Tajima. 2017. Embedding based News Recommendation for Millions of Users. In KDD. 1933-1942.

[7] Filip Radlinski and Nick Craswell. 2013. Optimized Interleaving for Online Retrieval Evaluation. In WSDM. 245-254.

[8] Anne Schuth, Robert Jan Bruintjes, Fritjof Buu ttner, Joost van Doorn, Carla Groenland, Harrie Oosterhuis, Cong Nguyen Tran, Bas Veeling, Jos van der Velde, Roger Wechsler, David Woudenberg, and Maarten de Rijke. 2015. Probabilistic Multileave for Online Retrieval Evaluation. In SIGIR. 955-958.

[9] Anne Schuth, Floor Sietsma, Shimon Whiteson, Damien Lefortier, and Maarten de Rijke. 2014. Multileaved Comparisons for Fast Online Evaluation. In CIKM. 70-80.

[10] Innovating Faster on Personalization Algorithms at Netflix Using Interleaving. https://medium.com/netflix-techblog/interleaving-in-online-experiments-at-netflix-a04ee392ec55

[2L4-J-9] Natural language processing, information retrieval: conversion and generation

Chair:Ichiro Kobayashi Reviewer:Yuzuru Okajima

Wed. Jun 5, 2019 3:20 PM - 4:40 PM Room L (203+204 Small meeting rooms)

[2L4-J-9-01] A sentence style conversion method using LSTM-RNN

○Kenta Shimoji[1], Kazuhiro Morita[1], Masao Fuketa[1] (1. Tokushima University)

3:20 PM - 3:40 PM

[2L4-J-9-02] Text simplification using newspaper articles

Naoki Koto[1], ○Hidetsugu Nanba[1], Toshiyuki Takezawa[1] (1. Hiroshima City University)

3:40 PM - 4:00 PM

[2L4-J-9-03] Keyword Conditional Variational Autoencoder for advertising headline generation

○Hiroyuki Fukuda[1] (1. DENTSU INC.)

4:00 PM - 4:20 PM

[2L4-J-9-04] Generating Emoji with Conditional Variational Autoencoders and Word Embedding

○Atsuki Yamaguchi[1], Katsuhide Fujita[1] (1. Tokyo University of Agriculture and Technology)

4:20 PM - 4:40 PM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

LSTM-RNNを用いた文体変換手法

A sentence style conversion method using LSTM-RNN

下地　健太[*1]　　森田　和宏[1]　　泓田　正雄[1]
Kenta Shimoji　　Kazuhiro Morita　　Masao Fuketa

[1] 徳島大学大学院先端技術科学教育部
Department of information Science and Intelligent Systems, Tokushima University

Abstract:　This paper describes a sentence style conversion method using recurrent neural network with long short-term memory cells (LSTM-RNN). In the proposed method, LSTM-RNN is used to learn direct style sentences vectorized by one-hot expressions. Then, the sentence end expression of the distal style sentence is removed and the vectorized one is input into the learned model. The next word is predicted until sentence ends, and the obtained word vector sequence is added to the end of the input vector sequence. A direct style sentence is converted by decoding the generated vector sequence into the form of the natural language. We experimented to evaluate the accuracy of the proposed method. As a result, it turned out that a sentence style can be converted by the method.

1. はじめに

近年，文書の電子化が進んでおり，コンピュータを使った文書作成の機会が増加している．電子媒体の文書にもアナログ媒体のものと同様にヒューマンエラーがしばしば見られる．その一つとして文体の統一に関する誤りが挙げられる．さらに，文体の統一の中でも多くの誤りが発生するのが，同一文書における常体文(「だ」・「である」調)と敬体文(「です」・「ます」調)の混在である．文書作成においてこのような誤りを訂正する作業は必要不可欠である．しかし，文書の作成者が自ら訂正作業をおこなうことは，その内容を理解しているため，客観性に欠ける．また，人手による訂正作業では文書作成と同様に一つの見落としもないという保証はなく，文書が長くなればなるほどヒューマンエラーは増えていく．そこで，コンピュータによる文体変換システムが必要とされる．本稿では LSTM-RNN を用いた文体変換手法について述べる．また，提案手法の変換精度評価のために実験をおこなう．

林らの研究[1]では，人手で作成した変換ルールを用いた手法で書き言葉から話し言葉への文体変換をおこなっている．しかし，この手法ではルールでの対応が困難な場合があり柔軟な変換がおこなえないことが問題であった．本研究ではルールでは難しい場合に対応するために，LSTM-RNN を用いることにより，それぞれの文体に特有の表現や単語の並びを学習させ，未知の入力に対し生成した学習モデルの単語予測を利用して文体の変換をおこなう．

2. LSTM-RNN

RNN(Recurrent Neural Nerwork)は時系列データの学習に特化した深層学習手法の一つである．時系列データとは，ある要素が時間的順序を追って並んでいるデータのことであり，文章，声，映像，株価情報等がこれに当たる．そのため，主に自然言語処理や音声言語処理等の分野で利用されている．内部にループ構造を持つことが特徴であり，これにより前のステップの情報を後続のステップに渡すことが可能となっている．また，本研究では RNN に加え，LSTM(Long Short-Term Memory)[2]を使用する．LSTM は学習に必要な情報の取捨選択をおこなうことにより，時系列データの長期依存性を学習することを可能にする RNN のユニットの一つである．LSTM を中間層に用いることにより，通常の RNN が持つ逆誤差伝播による学習における勾配消失に問題を解決し，より高い精度で時系列予測をおこなうことができる．本研究では，入力した文字列の次に来るであろう単語を予測するために RNN を用い，自然言語という比較的データ長の長い時系列データを扱うため，LSTM を採用する．本稿では LSTM を中間層に用いた RNN を LSTM-RNN と呼ぶこととする．

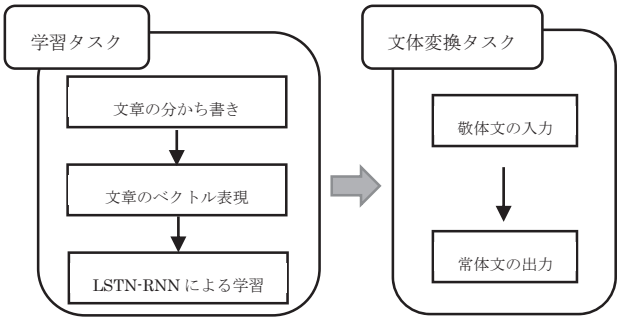


図 1:提案手法

3. 提案手法

学習データに常体文のみを使用することにより，常体文の単語の並びを予測することができるので，これを利用して敬体文を常体文に変換する．これに関する提案手法の流れを図 1 に示す．また，本章では提案手法のそれぞれのステップについて解説する．

連絡先：下地 健太，knt.smj@gmail.com

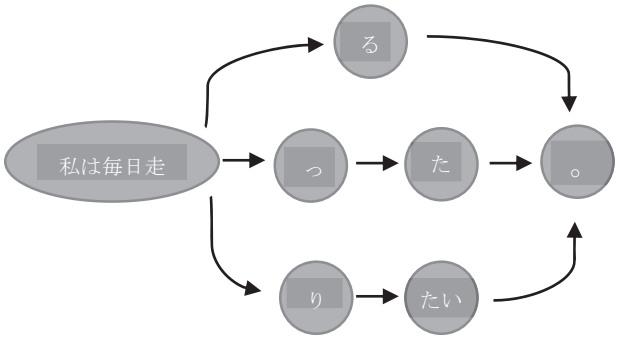


図 2:文末予測の例

3.1 学習タスク

本節では文章を学習しモデルを生成するタスクについて解説する.

まず, 学習データには常体文のみを用いるため, 常体文のみを収集する必要がある. 敬体文には助動詞「です」,「ます」のどちらかが使われることが主であるため, これらの助動詞が含まれない文という条件で常体文のみを収集した. そして, 学習に用いる文章に対し形態素解析をおこない, 分かち書きをおこなう. ここで, 動詞については,「走る」,「走り(ます)」のように同じ意味を表していても敬体文と常体文で活用が異なる場合があるため, 形態素をさらに語幹で分割する. 前述の例の場合,「走/る」,「走/り」のように分割する. 形態素解析には MeCab[3]を使用し, 語幹はその動詞の原形と前方一致する部分とする. その後, One-hot 表現を用いて単語のベクトル化をおこなう. One-hot 表現とは, 1 つのビットにだけ 1(High)を, 他のビットには 0(Low)を割り当てるベクトル表現である. これにより, 文章を単語ベクトルの集合として表現する. 最後に, ベクトル化した文章について 1 文毎に LSTM-RNN を用いて単語の順番を学習し, モデルを生成する.

3.2 文体変換タスク

本節では入力文を 3.1 節で生成した学習モデルにより文体変換をおこなうタスクについて解説する.

敬体文から常体文への変換が目的であるため, 文体変換時の入力データには敬体文を用いる. 3.1 節と同様にして入力となる敬体文に対し分かち書きをおこなった後, 文末表現を除去する. 文末表現は文の最後に現れる名詞もしくは動詞の語幹の次の文字から句点までとする. 例えば,「私は毎日走ります。」という文の文末表現は「ります。」なので, 除去後の文字列は「私は毎日走」となる. そして, これに対しベクトル化をおこない 3.1 節で生成した学習モデルに入力する. 次に来る確率の高い文末語までの単語の組み合わせを複数生成し, その中で最も文全体としての生成確率が最も高いものを出力とする. 例の場合,「私は毎日走」に続く単語の組み合わせとして,「る。」,「った。」,「りたい。」が候補となり, その中から「る。」が出力として選ばれる. (図 2 参照)これを元の入力文の末尾に追加し, できたベクトル列を自然言語の形に変換することで常体文を得る. 前述の例では「私は毎日走る。」という常体文が得られる.

表 1:実験結果

	○	△	×
分類数	23	59	18

表 2:変換例

入力文	出力文	評価
実状の説明に適しているかも知れません。	実状の説明に適しているかも知れない。	○
まじめな顔をして言いました。	まじめな顔をして言った。	○
笑わせるのには事を欠きませんでした。	笑わせるのには事を欠いた。	△
まるで見当つかないのです。	まるで見当つかないのか。	△
完全に落第でした。	完全に落第る。	×
これがまた家中の大笑いでした。	これがまた家中の大笑いがある。	×

4. 評価実験

提案手法の精度を確認するために評価実験をおこなった. 学習データには, 読売新聞記事内の常体文を 26,366 文使用した. テストデータには青空文庫[4]の作品内の敬体文を 100 文使用し, 提案手法を用いて文体変換をおこなった. 本実験では埋め込み層, 2 つの LSTM 層と全結合層からなるニューラルネットワークを使用した. LSTM 層の次元数は 200 次元とし, 損失関数には活性化関数には softmax 関数を用いた. 評価は○(正しい), △(常体に変換できているが元の敬体文の意味情報が保持されていない), ×(文の意味が通っていない)の三段階評価を人手によりおこなった.

評価実験の結果を表 1 に示す. 8 割以上が意味に破綻のない文として出力された. 本実験における変換例を表 2 に示す. 評価が△のものについて, 1 つ目の「笑わせるのには事を欠きませんでした。」は「笑わせるのには事を欠かなかった。」と変換されるべきであるが, 提案手法では学習した単語の順番を元に予測をおこなうため, 変換の過程で否定文であるという情報が失われている. また, 2 つ目についても同様に肯定文であるという情報が失われている. この問題を解決するには, 入力文の種類が何であるかを判定し, それと同様の種類の出力文を生成する必要があると考える. ×のものについては, 学習データの不足が原因であると考えられるため, 十分な量のコーパスを用意することが必要である.

5. おわりに

本稿では, LSTM-RNN を用いた文体変換手法の提案をおこなった. 100 の敬体文に対し本手法を適用することにより, 精度評価をおこなった. その結果 8 割以上が意味に破綻がない文として出力されたが, 変換の過程で入力文の意味情報が失われる場合があるという課題が明らかになった.

今後は今回の結果を踏まえ, 課題に関して改良をおこなうことで変換精度を向上させていく予定である.

参考文献

[1] 林由紀子, 松原茂樹. 自然な読み上げ音声出力のための書き言葉から話し言葉へのテキスト変換. 情報処理学会研究報告, pp. 49-54,2007

[2] Sepp Hochreiter and J¨urgen Schmidhuber. Long short-term memory. Neural computation, Vol. 9, No. 8, pp. 1735–1780, 1997.

[3] T. Kudo. Mecab : Yet another partof-speech and morphological analyzer. http://taku910.github.io/mecab/

[4] 青空文庫. https://www.aozora.gr.jp/

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

新聞記事データを用いたテキスト平易化

Text simplification using newspaper articles

小藤　直紀　Naoki KOTO
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

Automatic text simplification attempts to automatically transform complex sentences into their simpler variants without significantly changing the original meaning. Several researches on automatic text simplification have conducted based on a large-scale monolingual parallel corpus. However, it is costly to manually construct a parallel corpus for text simplification. Therefore, we investigate automatic construction of a large-scale simplified corpus for Japanese from newspaper database corpora. In this paper, we examined several methods for sentence alignment of texts with different complexity levels. Using the best of them, we sentence-align the Mainichi newspaper and Mainichi newspaper for elementary students, thus providing large training materials for automatic text simplification systems.

1. はじめに

現在，日本には 200 万人以上の在留外国人や，旅行客など多種多様な人種，国籍の外国人が日本に滞在している．近年，そのような人々に向けて「やさしい日本語」(http://human.cc.hirosaki-u.ac.jp/kokugo/EJ1a.htm)というものが考案されている．「やさしい日本語」とは，外国人にもわかりやすい日本語であり，地震などの災害が発生した際の情報伝達や，行政窓口の外国人対応など様々な状況で扱われている．難解な日本語を平易化し，情報伝達を容易にする「テキスト平易化」は，今後さらに重要なタスクになると考えられる．そこで本研究では，日本語テキストを平易化する手法を提案する．

近年，テキスト平易化を同一言語内の翻訳問題と考え，機械翻訳の枠組みで入力文から平易な同義文を生成する研究が盛んに行われている．その代表的な手法に，難解なテキストと平易なテキストからなる大規模な単言語パラレルコーパスを用いたテキスト平易化が挙げられる．しかし，その多くは英語で作成された大規模パラレルコーパスを用いた手法である．そこで，本研究では毎日新聞と毎日小学生新聞の記事データをそれぞれ難解なテキスト，平易なテキストとして対応付けを行い，大規模パラレルコーパスを作成する．それを用いて文の平易化を行うことにより，円滑な情報提供の手助けをすることが本研究の目的である．

論文の構成は以下のとおりである，2 章では関連研究を紹介する．3 章ではテキスト平易化システムの構築について述べる．4 章では評価実験とその結果，考察を述べる．5 章で本論文をまとめる．

2. 関連研究

本研究の関連研究として，2.1 節では，やさしい日本語について，2.2節では，英語のパラレルコーパスによるテキスト平易化について，2.3 節では，平易なコーパスを用いないテキスト平易化について，2.4節では，SCDVを用いた文書分類について，それぞれ述べる

2.1 やさしい日本語

近年，外国人にも理解が容易な「やさしい日本語」を用いる取り組みが盛んであり，災害時の緊急連絡や，マニュアルなどに用いることで被害の減少が見込める．原文からやさしい日本語へ変換する技術に関して，例えば梶原らが作成した語彙平易化システム[梶原　17]などが挙げられる．

Maruyama らは日本語を対象にした自動平易化に用いる言語資源が少ないことを挙げ，「やさしい日本語」という観点で日本語に関する言語資源構築を行った[Maruyama 18]．原テキストには small parallel enja: 50k En/Ja Parallel Corpus for Testing SMT Methodsが用いられている．Maruyamaらはこのコーパス内にある 5 万文すべてに対して，2,000 語の平易な語で構成される語彙集合「やさしい語彙」を用いて文単位の書き換え，やさしい語彙の追加，削除を行うことでやさしい日本語コーパスを作成した．本研究では新聞記事コーパスを用いることにより，より精度の高いパラレルコーパスの構築を目指す．

2.2 英語のパラレルコーパスによるテキスト平易化

English Wikipedia と Simple English Wikipedia をコンパラブルコーパスと考え，ここから抽出された単言語パラレルコーパスを用いたテキスト平易化手法が提案されている．Zhu らは English Wikipedia と Simple English Wikipedia から得られた大規模な並列データセットを使用した統計的機械翻訳による手法をベースとした，ツリーベースの翻訳モデル(TSM)によるテキスト平易化モデルを提案している[Zhu　10]．Zhuらは Wikipedia の言語リンクをたどり，English Wikipedia と Simple English Wikipedia から 65,133 対の対応付けを行った．その後，JWPL を用いて特定のタグを削除，両テキストからプレーンテキストを抽出した．本研究では毎日新聞および毎日小学生新聞を用いる．対応付けには記事番号や「ある」，「いる」などの特徴を得られない動詞などを除いたベクトルを作成し，コサイン類似度を用いて対応付けを行う．

2.3 平易なコーパスを用いないテキスト平易化

梶原[梶原　18]らは生コーパスのみからテキスト平易化のための疑似パラレルコーパスを自動構築するフレームワークを提案している．生コーパスから無作為に抽出した2つの文に対して

連絡先：
小藤 直紀，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
{koto, nanba, takezawa}@ls.info.hiroshima-cu.ac.jp

タスクに応じた品質推定を行い，一定以上の尤度を持つ文対を疑似パラレルコーパスとして抽出する

梶原らが，リーダビリティ推定で得た難解なサブコーパスと平易なサブコーパスを用いて文間類似度を計算し，英語のテキスト平易化のための疑似パラレルコーパスを構築した．本研究では，毎日新聞と毎日小学生新聞をそれぞれ難解なテキスト，平易なテキストとしてパラレルコーパスを構築する．毎日新聞と毎日小学生新聞で対応するテキストの難易ははっきりとしているので，リーダビリティを推定することなく，日本語の平易化のためのパラレルコーパスを作成することができる．

2.4 SCDV を用いた文書分類

Word2Vec のベクトル空間に対して GMM(Gaussian Mixture Models)でクラスタリングを行い，各単語がどのトピックに属しているのか考慮したベクトル空間に修正することで，単語ベクトルから文書ベクトルを作成する際の精度向上を目的とする手法 SCDV[Mekala 17]が他クラス文書分類問題において，他の手法と比べて優れていることが示されている．本研究でも SCDV が有効であると考え，記事間の類似度を計算する際の，特徴付きベクトルの作成に用いる．

3. テキスト平易化システムの構築

3.1 節ではテキストの平易化手順について述べる．3.2 節では，パラレルコーパスの構築手順である記事単位のアライメント取得手法について，3.3 節では，文単位のアライメント取得手法について，3,4節では，記事間の対応付けについて，3,5 節では，テキスト平易化ついて述べる

3.1 平易化手順

テキスト平易化手順として，毎日新聞および毎日小学生新聞の記事を難解なテキストおよび平易なテキストとして対応付けてパラレルコーパスを構築する．新聞記事同士を対応付けするにあたり，記事単位の対応付けをおこなった後，対応している記事内で文単位の対応付けを行い，アライメントをとる．その後，翻訳作業を行う．

3.2 記事単位の類似度判定

本研究ではコサイン類似度を用いて記事間の類似度を計算した．コサイン類似度計算に用いる各記事ベクトルは TF-IDF により取得する．また，単語の意味をベクトルとして表現する word2vec をクラスタリングし，文書の特徴を得る SCDV という手法が近年盛んに用いられる．本研究の平易化テキストに対しても，文字の一致率だけでは無く，文字の意味的特徴を考慮することが必要であると考え．SCDV を用いる．

3.3 文単位の類似度判定

難解な文と平易な文の同義性を評価し，対応付けするために本研究では，単語分散表現のアライメントに基づく，3 つの文間類似度の計算手法[Song 15]と Word Mover's Distance[Rubner 98]を本タスクに用いる．以下にそれぞれの計算手法を記載する．

(1) Average Alignment

全ての単語の組み合わせについて単語間類似度を計算，平均して文間類似度$S_{ave}(x,y)$を求める．$\Phi(x_i,y_j)$はコサイン類似度である．

$$S_{ave}(x,y)=\frac{1}{|x||y|}\sum_{i=1}^{|x|}\sum_{j=1}^{|y|}\Phi(x_i,y_j)$$

(2) Maximum Alignment

文に含まれる各単語に対して最も類似度が高い単語を選択し，それらの単語のみ計算した単語間類似度$\Phi(x_i,y_j)$を平均して$S_{asym}(x,y)$を求める．$S_{asym}(x,y)$は非対称なスコアなので，それらの平均値を用いて対象な文間類似度$S_{max}(x,y)$を計算する．

$$S_{asym}(x,y)=\frac{1}{|x|}\sum_{i=1}^{|x|}max_j\,\Phi(x_i,y_j)$$

$$S_{max}(x,y)=\frac{1}{2}\left(S_{asym}(x,y)+S_{asym}(y,x)\right)$$

(3) Hungarian Alignment

2 文を単語をノードとする 2 部グラフとして考え，一対一の単語アライメントに基づく文間類似度を定義する．文xに含まれる各単語x_iに対して Hungarian 法[Kuhn 95]によって文y中の単語$h(x_i)$を選択し，それらの$|x|$個の単語の組み合わせについて計算した単語間類似度を平均した文間類似度$S_{hun}(x,y)$を求める．

$$S_{hun}(x,y)=\frac{1}{min(|x|,|y|)}\sum_{i=1}^{|x|}\Phi(x_i,h(x_i))$$

(4) Word Mover's Distance

$\psi(x_u,y_v)$は単語x_uと単語y_vの間の単語間非類似度(距離)を表し，本研究ではユークリッド距離を用いる．またA_{uv}は文x中の単語x_uから文y中の単語y_vへの輸送量を表す行列であり，nは語彙数，$freq(x_u)$は文x中での単語x_uの出現頻度である．

$$S_{wmd}(x,y)=1-WMD(x,y)$$

$$WMD(x,y)=\min\sum_{u=1}^{n}\sum_{v=1}^{n}A_{uv}\psi(x_u,y_v)$$

$$\sum_{v=1}^{n}A_{uv}=\frac{1}{|x|}freq(x_u)$$

$$\sum_{v=1}^{n}A_{uv}=\frac{1}{|y|}freq(y_v)$$

3.4 記事間の対応付け

3.2 節で述べた記事単位の類似度を計測する際に，同じ内容の毎日新聞記事と毎日小学生新聞記事の日付に何日のずれがあるか調査した．調査の結果，前後1日より 2 日，前後 2 日より 3 日と対応している記事間の日付は近いほど対応数は増加していた．また，ある日付の毎日小学生新聞が，その日付の毎日新聞および，その日付より新しい毎日新聞と対応していることは極めて少なかった．人手による対応データは，毎日新聞から 1 日遅れで毎日小学生新聞の記事と対応している記事が記載されることが多い結果となっていた．

3.5 テキスト平易化

3.2 節および 3.3 節で提案した手法を毎日新聞および毎日小学生新聞に適用し，日本語テキスト平易化パラレルコーパスを自動構築する．構築したパラレスコーパスは，形態素解析器を用いて単語区切りを入れた後，機械翻訳システムを適用することで，日本語テキストの平易化システムを構築することができる．従来のテキスト平易化研究では，機械翻訳システムとして統計翻訳器が利用されることが多かったが，本研究でも，統計翻訳パッケージのひとつである cicada(http://att-astrec.nict.go.jp/product/cicada/)を用いる．この他，近年，機械翻訳分野で活発に研究されている seq2seq モデルをはじめとしたニューラル機械翻訳も利用して平易化システムを構築する．なお，本研究では，テキスト平易化パラレルコーパスの構築に主眼を置いているため，評価は記事単位の類似度判定および文単位の類似度判定についてのみ行う．

4. 実験

本章では，本研究で行った実験条件，実験結果，またその考察について，4.1 節では記事単位の類似度判定実験，4.2 節では文単位の類似度判定実験について述べる．

4.1 記事単位の類似度判定実験

(1) 実験条件

実験データおよび評価

毎日新聞，毎日小学生新聞ともに 2016 年の 1 年間分を使用して，人手により記事の対応付けを行い，記事単位の類似度判定実験に用いた．人手により作成された 856 対の記事単位の対応は A 評価:顕著に対応が取れる B 評価:対応を取れる という観点で対応付けが行われている． A 評価のものだけを用いて評価した場合と，A 評価と B 評価の両方を用いた場合の 2 通りで実験を行う．なお，評価には平均精度(average precision)を用いる．

比較手法

本研究では，以下の比較手法に基づき記事単位の類似度判定実験を行う．

- TF-IDF: 記事中の各単語の重み付けに TF-IDF 手法を用い，毎日小学生新聞の 1 記事に対して，その記事の日付当日および，その日付から前後 4 日分の毎日新聞の記事との類似度を計算
- SCDV: SCDV を用いてその記事の日付当日および，その日付から前後 3 日分までの毎日新聞記事との類似度を計算

(2) 実験結果

評価結果を表 1 に示す．表 1 より，対象記事に対して以前の記事だけでなく，TF-IDF を用いたアライメントの評価と SCDV を用いたアライメントの評価を比較したとき，TF-IDF を用いたアライメントのほうが優れていることがわかる．

表 1 記事単位の対応付け(平均精度)

手法	A 評価	A+B 評価
TF-IDF	0.9206	0.9042
SCDV	0.8734	0.8520

(3) 考察

本節では 4.1.2 節の実験結果に対する考察を述べる．結果より，SCDV よりも TF-IDF を用いて作成した記事ベクトルがより優れていた．正解データと比較した際に，TF-IDF は正しいアライメント結果を示し，SCDV では誤ったアライメント結果を示した例を以下に示す．正解データの毎日小学生新聞記事を図 1，SCDV のアライメント結果である毎日新聞記事を図 2 に示す．毎日小学生新聞での読み仮名は省略している．

＜毎日小学生新聞 2016 年 1 月 5 日，記事番号 7 番＞
第92回東京箱根間往復大学駅伝競走が2、3日、神奈川県箱根町―東京・大手町の往復10区間217・1キロメートルで行われ、青山学院大学が往路と復路を制して、2年連続2度目の総合優勝を果たしました。総合記録は10時間53分25秒。

図 1 毎日小学生新聞記事本文(一部抜粋)

<毎日新聞記事(2016 年 1 月 3 日，記事番号 77 番>
前回大会に続いて、トヨタ自動車が後半に実力を発揮した。群馬県の上州路を舞台に1日に行われた「ニューイヤー駅伝第60回全日本実業団対抗駅伝競走大会」。トヨタ自動車が2連覇を達成して通算優勝回数も5位タイの「3」とした。

図 2 毎日新聞記事本文(一部抜粋)

図 1 と図 2 は記事内容が異なり，チーム名などの名詞は違うが，順位の表記や記事の構成，その他の用語は正解データである毎日新聞記事(2016 年 1 月 4 日，記事番号 46 番)と非常に似ていた．SCDV の特徴および利点はテキストに対してクラスタリングを行い，各単語がどのトピックに属するかを加味したベクトル空間を作成できる点であるが，本研究で用いている新聞記事は元々各記事の内容に統一性があり，似た形式の記事が見られるため，SCDV を用いることによる利益が，充分に得られなかったことが原因と考えられる．

4.2 文単位の類似度判定

本節では，3.2 節で挙げた文単位の類似度判定実験に関する実験条件，実験結果，またその考察について述べる．

(1) 実験条件

実験データおよび評価

2016 年度の毎日新聞および毎日小学生新聞の対応している記事内で，文を人手により対応付けたものを文単位の類似度判定実験に用いた．文は句点で改行されており，先頭に記事番号と行番号が与えられ整理されている，この作業も人手により行った．人手により作成された 2,813 対の文単位の対応は A 評価:顕著に対応が取れる B 評価:対応を取れる，という観点で対応付けが行われている． A 評価のものだけを用いて評価した場合と，A 評価と B 評価の両方を用いた場合の 2 通りで実験を行う．なお，評価には平均精度(average precision)を用いる．

実験手法

本実験において，文単位のアライメントは 3.3 節で述べた単語分散表現のアライメントに基づく 4 種類の文間類似度計算手法，Average Alignment，Maximum Alignment，Hungarian Alignment，Word Mover's Distance を用いて文間の類似度を判定する．A+B 評価の正解データを用いる．

(2) 実験結果

4 種類のアライメント手法に対して. A 評価の正解データのみを用いた場合と, A 評価と B 評価の正解データ両方を用いた場合の平均精度による評価結果を以下の表 2 に示す. 今回の実験では Maximum Alignment が A 評価の正解データのみを用いた場合, A 評価と B 評価の正解データ両方を用いた場合のいずれでも最も優れた精度を示している.

表 2 文単位のアライメント評価(平均精度)

手法	平均精度	
	A 評価	A＋B 評価
Average Alignment	0.8483	0.8407
Maximum Alignment	**0.9802**	**0.9766**
Hungarian Alignment	0.9658	0.9617
Word Move's Distance	0.6109	0.5912

(3) 考察

本節では 4.2.2 節の実験結果に対する考察を述べる. 評価の結果より, Maximum Alignment が最も優れた平均精度を示している. 以下に正解データと Maximum Alignment の結果が異なっている毎日新聞および日小学生新聞の, 記事本文の抜粋を記載する. id は年月日, 記事番号, 行を表す.

＜毎日新聞＞

<id=160105178-1>東京都中央卸売市場「築地市場」(中央区)で5日、新春恒例の初競りが行われ、青森県大間産の200キロのクロマグロが、昨年の3倍超の1400万円(1キロ当たり7万円)で競り落とされた。

＜毎日小学生新聞＞

<id=S160106002-1>今年11月に移転する築地市場(東京都中央区)で5日、「最後の初競り」が行われました。

＜毎日小学生新聞＞

<id=S160106002-2>青森県大間産のクロマグロ200キログラムに、昨年の約3倍にあたる1400万円(1キログラム当たり7万円)の値段がつきました。

人手による正解データでは, <id=160105178-1>に対して <id=S160106002-2>が対応している. これは, 互いに含まれている単語と文脈を考慮して対応付けたと考えられる. 一方, Maximum Alignment のアライメント結果では <id=160105178-1>に<id=S160106002-1>が対応付けられている, Maximum Alignment が分割された文のどちらが十分に文脈を汲み取れているかの判断を誤ったことが原因と考えられる. しかし全体的には非常に高い精度を示しているのも, また事実である.

5. おわりに

本研究では, 毎日新聞と毎日小学生新聞から構築されたパラレルコーパスによるテキスト平易化手法を提案した. パラレルコーパスの構築手順である記事単位の類似度判定実験では TF-IDF による評価結果が SCDV を用いた評価結果より優れた結果となり, 文単位の類似度判定実験では. 4 つのアライメント手法のうち Maximum Alignment による評価結果が最も優れたか結果を示した. 以上のアライメント手法により 30,940 文対からなる平易化のパラレルコーパスを構築した.

参考文献

[Kuhn 95] Harold William Kuhn: The Hungarian Method for the Assignment Problem, Naval Research Logistics Quarterly,Vol.2, pp. 83-97, 1995.

[Maruyama 17] Takumi Maruyama and Kazuhide Yamamoto: Simplified Corpus with Core Vocabular, Proceedings of the 11th International Conference on Language Resources and Evaluation (LREC), 2018.

[Mekala 17] Dheeraj Mekala, Vivek Gupta, Bhargavi Paranjape, and Harish Karnick: SCDV : Sparse Composite Document Vectors Using Soft Clustering over Distributional , Representations, Proceedings of EMNLP 2017, pp. 659-669, 2017.

[Rubner 98] Yossi Rubner, Carlo Tomasi, and Leonidas Guibas: A Metric for Distributions with Applications to Image Databases, Proceedings of the 6th International Conference on Computer Vision, pp. 59-66, 1998.

[Song 15] Yangqiu Song and Dan Roth: Unsupervised Sparse Vector Densification for Short Text Similarity, Proceedings of the 2015 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, pp. 1275–1280, 2015.

[Zhu 10] Zhemin Zhu, Delphine Bernhard, and Iryna Gurevych: A Monolingual Tree-based Translation Model for Sentence Simplification, Proceedings of the 23rd International Conference on Computational Linguistics, pp.1353–1361, 2010.

[梶原 17] 梶原 智之, 小町 守: Simple PPDB: Japanese, 言語処理学会第 23 回年次大会, pp. 529-532, 2017.

[梶原 18] 梶原 智之, 小町 守: 平易なコーパスを用いないテキスト平易化, 自然言語処理, Vol.25, No.2, pp. 223-249, 2018.

キーワード条件つき変分 Autoencoder による広告文生成

Keyword Conditional Variational Autoencoder for advertising headline generation

福田 宏幸[*1]
Hiroyuki Fukuda

[*1]株式会社 電通
DENTSU INC.

Recently, fast and massive advertising headline production is highly demanded by growing number of digital ad. Many types of headline generation systems have been developed. But, most of these systems generate headlines systematically by rules and lack generation variety. On the hands, the systems which generate headlines almost randomly satisfy such variety but these headlines are not relevant to ad objective. Until now, it is still difficult to satisfy both variety and relevancy. To this end, we propose Keyword Conditional Variational Autoencoder for advertising headline generation. We regulate generation process by relevant keyword while keeping variety by randomly selected input hidden variables. In our experiment, It can generate variety of headlines and obtain headlines which include a relevant keyword.

1. 背景

近年、広告制作の実務においては、デジタル広告のシェア拡大に伴い、早く、大量に、広告文(いわゆるキャッチコピー)を制作することが求められている。デジタル広告においては、掲載単価が安いことに加え、入稿の手続きも WEB 上で簡単に出来ることから、次々と新しい広告を投入することが推奨されている。また、このように大量の広告を制作して、運用していくことで、広告の鮮度を保つことができ、同時に、どういう広告文が消費者の心を掴むのかという知見も得ることができる。結果として、制作の現場への作業負荷が増大しており、AI を活用した負荷の軽減が求められている。

これまでにも、ルールベースを中心として様々な広告文生成の手法が開発されてきた[Yamane 14 等]が、生成手法が単純である程、確実な生成が期待できる一方で、バリエーションが限られるという欠点があった。また、人間がルールを設定している為、人間の発想の範疇を超えた、セレンディピティのようなアイディアが出る可能性も少ないと考えられる。

そこで、本研究では、近年研究が盛んになってきている深層生成モデルの一種である変分 Autoencoder (VAE)を用い、バリエーションに富んだ創発的な広告文の生成を目指す。一方で、広告には商品を売るという目的があり、広告文と商品との強い関連性が求められる為、ランダムな文生成ではなく、キーワードによって条件づけられた広告文生成を提案する。

2. 関連研究

近年、深層生成モデルの研究は、深層学習の研究の中でも特に活発に研究がなされているトピックの1つである。特に変分 Autoencoder (VAE) [Kingma 13]や敵対的生成ネットワーク (GAN) [Goodfellow 14]が発表されて以来、関連論文の数が急増している。

これら生成モデルの研究は、画像の生成を対象としたものが中心で、それらが実用的な精度になりつつある一方で、短文に対する生成モデルの研究は、まだ発展途上と考えられている。手法としては、画像同様に VAE を用いたもの[Bowman 15]と、GAN を用いたものがある。GAN においては、画像に比べ、自然言語の離散的な性質から、Discriminator の勾配が逆伝播しないという課題があり、強化学習の Policy Gradient の手法を用いた SeqGAN [Yu 17]や、誤差関数に MMD による誤差を加えた TextGAN [Zhang 17]など、様々な工夫を凝らした研究がある。また、亜種としてテンプレート文を元に編集ベクトルによって文を生成するモデルも存在する[Guu 17]。

連絡先:hiroyuki.fukuda@dentsu.co.jp

3. 提案手法

広告文と商品との関連性を高める為、訴求内容(価格や機能やイメージ)や訴求ターゲットで条件づける方法が考えられるが、

本論文ではキーワード(単語)によって生成を条件づける手法を提案する。広告文のノウハウ本には、「キャッチコピーは、キーワード探し」というような記述もあり、商品特徴や伝えたいメッセージを短文に表現するために、キーとなる単語の選択が重要と考えられている。

具体的には、まずキーワードが選択され、そのキーワードを条件として広告文が生成されたと仮定し、条件つき変分 Autoencoder モデルを適応する。今回の実験では、簡便性の為、キーワードは名詞のみとした。



図 1 提案手法におけるキーワードによる条件づけ

3.1 データ

独自に収集した過去の新聞・雑誌の広告文のうち、15 単語以内の広告文およそ 30 万文を使用した。前処理として、MeCab および mecab-ipadic-NEologd を用いて形態素解析をし、id 化を行った。語彙数は 1 万語で足きりし、残りは未知語として処理した。データセットを 8:2 に分割し、8 割の訓練データで学習した後、2 割の validation データの精度(誤差)によって、ハイパーパラメータチューニングを行った。

3.2 モデル

VAE のモデルは、[Bowman 15]をベースにし、Encoder および Decoder の双方にキーワードを条件として入力した。Encoder

と Decoder は共に 1 層 LSTM を用い、隠れ層の次元は 200 に設定した。入力文および入力キーワードの単語は共に 200 次元のベクトルの埋め込み表現として入力した。

上記によるネットワークの概略図 2 に示す。推論時には、入力キーワードとランダムにサンプリングされた z を Decoder に入力することで、新たな広告文を生成した。また、ビーム探索も用いている。最適化には Adam を用い validation の精度によって、推論で使用する Epoch を決めた。

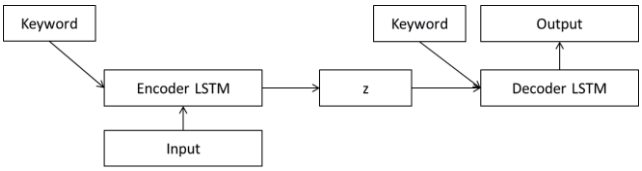


図 2 提案手法のネットワーク概略図

4. 実験

4.1 広告文生成例

前述のモデルを学習することにより、実際に得られた広告文の例を図 3 に示す。広告出稿が比較的多い業種である、トイレタリー・飲料・自動車の広告作業を想定し、「シャンプー」「ビール」「燃費」の 3 つをキーワードとして入力した。今回の実験では、各キーワードに対して 10000 文を出力した。変分 Autoencoder は、正しい文を潜在空間上に確率的にマッピングする為、比較的正しい文を生成しやすいと言われている。但し、実際には広告文になっていないものや、そもそも文として成立していないものも多く、人間が目視で選別している。一方で、「低燃費旅、妻対策」など、人間がなかなか思いつかないような言葉の組合せも出現しており、バリエーションの豊富さにも伺える。また、これらの広告文の類似表現が、元のデータに無いことも確認している。

Keyword	生成広告文
シャンプー	「時短シャンプー」そして、
	シャンプーリゾート。
	春が気持ちいいシャンプーです。
	がんばるシャンプーが、ここに。
	シャンプー0 円ライフ
ビール	ビールは、美味しく、楽しめる!
	No.1 ビールの贈り物なら
	新ブランドビールで生まれ変わりつづける
	ビールが時代の街づくりを
	春のクラシックビールはもっと楽しんで!
燃費	低燃費コンパクト
	「燃費が自由自在」をサポート!
	低燃費のヒミツ。
	低燃費旅、妻対策
	低燃費がヒロインなのに!?

図 3 生成された広告文の例

4.2 キーワード出現率

本研究のもう1つの目的は、商品との関連性の高い広告文の生成であり、その為に、キーワードによる条件付けモデルを提案した。ここでは、その結果の検証として、生成された広告文中のキーワードの出現率を計算した。結果、キーワードを入力していても、必ずしも生成文中にキーワードが出現する訳ではないが、元データにおける出現率に比べて約 50～200 倍程度の大幅な出現率の向上が確認された。

キーワード	生成文での出現率	元データでの出現率
シャンプー	8.96%	0.04%
ビール	2.88%	0.06%
燃費	3.64%	0.03%

図 4 提案手法によるキーワードの出現率の比較

5. 結論および考察

本論文では、キーワードを入力条件とした変分 Autoencoder による広告文生成を試みた。結果、元データでの出現率に比べて高い確率で、目的のキーワードが入った広告文を生成することが可能となった。また、得られる広告文にはバリエーションがあり、時には人間が思いつかないようなセレンディピティ的な広告文も生成された。

一方で、必ずしもキーワードが含まれない場合があったり、文として成立していない出力も多く存在した。通常、深層生成モデルの研究では 100 万文～1000 万文以上のデータセットが用いられるが、今回は広告文というデータの特殊性から、利用可能なデータが少なく、精度に影響したと考えられる。また、通常の条件つき変分 Autoencoder は、ユニークなクラスラベルを元に条件付けを行うが、今回の場合は1つの広告文に複数のラベルがついている状態である。結果、より複雑な構造の学習を強いることになり、今回の LSTM による学習器がその構造を十分に捉えられなかったものと思われる。

今後は、文として成立している広告文の精度を上げていくと共に、広告においては、様々なタイプの文生成が要求される為、訴求内容や訴求ターゲット等の他の条件においても効率的な広告文の生成ができるように研究を進めていきたい。

参考文献

[Yamane 14] 山根 宏彰, 萩原 将文: ウェブにおけるユーザの嗜好を反映したキャッチコピー自動生成システム, 日本感性工学会論文誌, 2014.

[Kingma 13] D. P. Kingma and M. Welling: Auto-encoding variational Bayes., arXiv, 2013.

[Goodfellow 15] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio.: Generative adversarial nets. In Advances in Neural Information Processing Systems, 2014.

[Yu 17] Yu, Lantao, Zhang, Weinan, Wang, Jun, and Yu, Yong.: Seqgan:sequence generative adversarial nets with policy gradient., In AAAI, 2017.

[Zhang 17] Yizhe Zhang, Zhe Gan, Kai Fan, Zhi Chen, Ricardo Henao, Dinghan Shen, Lawrence Carin: Adversarial Feature Matching for Text Generation, arXiv, 2017

[Bowman 13] Bowman, Samuel R., Vilnis, Luke, Vinyals, Oriol, Dai, Andrew M., Jozefowicz, Rafal, and Bengio, Samy: Generating sentences from a continuous space. CoRR,, 2015.

[Guu 17] Kelvin Guu, Tatsunori B. Hashimoto, Yonatan Oren, Percy Liang: Generating Sentences by Editing Prototypes., arXiv, 2017.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

条件付き変分オートエンコーダと単語分散表現による絵文字の生成

Gerenaring Emoji with Conditional Variational Autoencoders and Word Embedding

山口 篤季 *1　藤田 桂英 *2
Atsuki Yamaguchi　Katsuhide Fujita

*1東京農工大学工学部
Faculty of Engineering, Tokyo University of Agriculture and Technology

*2東京農工大学大学院工学研究院
Institute of Engineering, Tokyo University of Agriculture and Technology

Emoji are among the most widely used communication tools worldwide. Because the number of emoji increases every year and there are 82 face emoji, it might be difficult for users to select an appropriate emoji immediately. Moreover, it is troublesome to continue designing new emoji. Therefore, the aim of the present study is to generate an emoji based on input text automatically to facilitate easier communication and eliminate the process of designing new emoji. The proposed model employs conditional variational autoencoders (CVAE), quasi-recurrent neural networks (QRNN) as the text encoder, and the pre-trained word vector GloVe to the embedding layer connected to the text encoder. In the experiments described herein, it will be observed that the proposed method can generate an emoji that corresponds to an input caption, and output image quality is improved using GloVe.

1. はじめに

絵文字は 1999 年に日本で初めて公開され，携帯電話の普及とともに瞬く間に人気となった．2010 年代になると，世界中でスマートフォンが普及し，絵文字は Unicode によって標準化され，広く使われるようになった．絵文字には，顔型の絵文字（Smiley）から，食べ物，車両，建物に至るまで様々な種類が存在し，絵文字は我々の日常のコミュニケーション活動において重要な役割を果たしている．

絵文字が世界中で広く使われるようになるにつれて，絵文字を対象とした研究が盛んに行われるようになってきた．[1] は，Twitter 上における絵文字とテキスト間の関係性を調査し，どのような種類の絵文字がテキストベースのツイートに最も共起するかを予測した．この研究は，絵文字が世界中で広く扱われているにもかかわらず，自然言語処理の研究題材としてほとんど注目が集められてこなかったことに着目し，絵文字のもつ潜在的な意味を解析することを目的としていた．また，[3] は全ての Unicode の絵文字に関する単語分散表現を作成し，公開した．実験結果では，自然言語を対象とした単語分散表現と同様に，絵文字においても絵文字の意味の加減算が可能なことが示され，テキスト解析において絵文字を考慮することの重要性が示唆された．

一方，絵文字の数は年々増加しており，顔型の絵文字に限っても 82 種類存在することから，ユーザが適当な絵文字を即座に選択することは困難である．さらに，新たな絵文字を適宜デザインし，追加する作業は大きな労力を必要とする．敵対生成ネットワークを始めとした機械学習の生成モデル分野が発展してきていることから，入力のキャプションに対して対応する絵文字を自動生成することは，実現可能なタスクである．

本研究に応用可能な関連研究として “Text-to-image task” が有名である．これは，入力のテキストに基づいて画像を生成するタスクである．このタスクについては数多くの先行研究が存在する一方で，text-to-image synthesis task を応用した絵文字生成に関しての先行研究はほとんど存在せず，次の二つの先行研究のみが挙げられる．[8] と [6] は，深層畳み込み敵対生成ネットワーク（DCGAN）[7] を絵文字生成に活用し，入力のキャプションから絵文字を生成することに成功した．しかし，これらの先行研究は実験に使用しているデータセットに関する説明や内容が不十分であり，実装に関する記述が省かれているため，再現性に欠ける研究となっている．

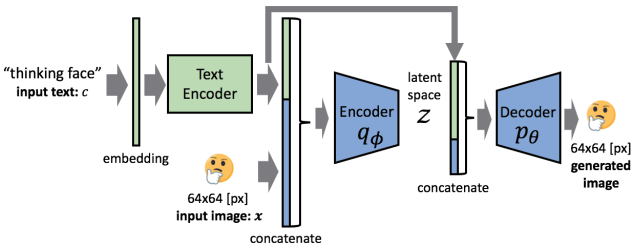


図 1: CVAE ベースの提案手法

そこで，本研究では絵文字を入力文から自動生成するモデルを提案する．これにより，ユーザのコミュニケーション活動の促進が期待されるほか，新たに絵文字をデザインする手間を省くことができる．提案手法は，CVAE [9] と事前学習済み単語ベクトル GloVe [5] を活用している．CVAE を活用することで，従来手法の GAN ベースのモデルよりも高速でかつ安定した学習を実現できる．さらに，事前学習済みの単語ベクトル GloVe を活用することで出力画像の精度に関して，定量的評価により示す．

以下に，本論文の構成を示す．まず，絵文字を入力文から自動生成するモデルを提案する．次に，ベースラインと提案手法の定性的評価の結果を示す．最後に，本論文のまとめと今後の課題を示す．

連絡先: 山口 篤季，東京農工大学工学部情報工学科，東京都小金井市中町 2-24-16，y-atsuki@st.go.tuat.ac.jp



- loudly crying face
- a sad face with tears streaming down both cheeks
- this face is distraught and inconsolable

図 2: データセットの画像とキャプションの対応の一例

2. 提案手法

図 1 は提案するモデルを示している．このモデルは，CVAE をベースモデルとして活用し，GloVe を埋め込み層に用い，さらに QRNN [2] をテキストエンコーダとして利用している．モデルは式 (1) で定義される変分下限 $\mathcal{L}$ を最大化することで学習できる．

$$\mathcal{L}(\boldsymbol{x}, c; \theta, \phi) = \mathbb{E}_{q_\phi(z|\boldsymbol{x},c)}[\log p_\theta(\boldsymbol{x}|c, z)] \\ -D_{KL}(q_\phi(z|\boldsymbol{x}, c)||p_\theta(z)) \quad (1)$$

単語分散表現

単語分散表現は自然言語処理の研究において，単語の特徴量を抽出するのに広く活用されている．提案手法は 300 次元の事前学習済み単語ベクトル GloVe [5] を活用している．事前学習済みの単語ベクトルを活用することで，モデルは入力文の意味をより効率的に捉えることができるようになり，出力画像の質が向上することが期待される．

テキストエンコーダ

テキストエンコーダには QRNN [2] を用いる．QRNN は畳み込みニューラルネットワーク (CNN) [4] をベースにしたモデルであり，再帰ニューラルネットワーク (RNN) の構造を CNN で再現したものである．RNN とは異なる特徴として，CNN をベースとしたモデルのため並列処理に特化していることが挙げられる．このため，LSTM ベースのネットワークと同等の性能を示しながらも，より高速な演算を実現している．

3. 評価実験

3.1 データセット

データセットは絵文字画像とキャプションデータで構成され，合計 260 個のキャプションデータが存在する．絵文字画像は EmojiOne から収集し，キャプションデータは，Unicode の定める CLDR Short Name と Emojipedia の対応する絵文字の説明文からなる．絵文字あたりのキャプション数は，平均値で 3.17，中央値で 3 となっている．また，一文あたりの単語数は平均値で 9.33，中央値で 8 である．図 2 に，絵文字画像データとキャプションデータの対応を示した例を示す．

3.2 実験設定

データセットの 10%をテストセットとした．提案手法は Adam にしたがって最適化され，学習率とバッチサイズはそれぞれ，0.001 と 26 に設定した．学習は 200 エポック実行した．

3.3 定量的評価

提案手法を CNN ベースの分類器 *1 による出力画像の分類精度と，Inception スコア [10] の 2 つの評価指標に基づいて定量的に評価した．各指標は 100 回ずつ計算を行った．表 1 は 3 モデル間の定量的比較結果を示している．なお，DCGAN による従来手法の実装が公開されていないため，本論文では [7] による DCGAN の実装を基に，条件付き DCGAN を実装して比較対象とした *2．

Model	Accuracy	IS	Runtime (s)
CVAE w/ GloVe	0.869	1.05	**20.2**
CVAE w/o GloVe	0.262	1.02	/
Cond-DCGAN	**0.885**	**1.32**	33.6
Dataset	/	1.38	/

表 1: 3 モデル間の定量的比較結果: “Accuracy” は CNN ベースの分類器の分類精度を示している．“IS” は Inception スコアの略である．太字は提案手法（CVAE w/ GloVe）と従来手法（Cond-DCGAN）間でマン・ホイットニーの U 検定により有意な差が認められたことを表す．($p < .05$)

提案手法における GloVe の有無が与える影響　表 1 より，二つの指標において，事前学習済みの単語ベクトルを用いたモデルは，事前学習済みの単語ベクトルを用いないモデルよりも優れていることが確認できる．CNN ベースの分類器による分類精度に着目すると，比較対象の二つのモデル間では 0.6 以上の有意な差がある．したがって，事前学習済みの単語ベクトルを用いたモデルの大半の出力画像は，入力のキャプションに従った画像を出力できている．一方，Inception スコアにおける二つのモデル間の差は 0.04 よりも小さく，データセットの値よりも 0.3 以上の差がある．これは，二つのモデルの出力画像が共に色彩面のノイズを含み，ぼやけていることが原因である．

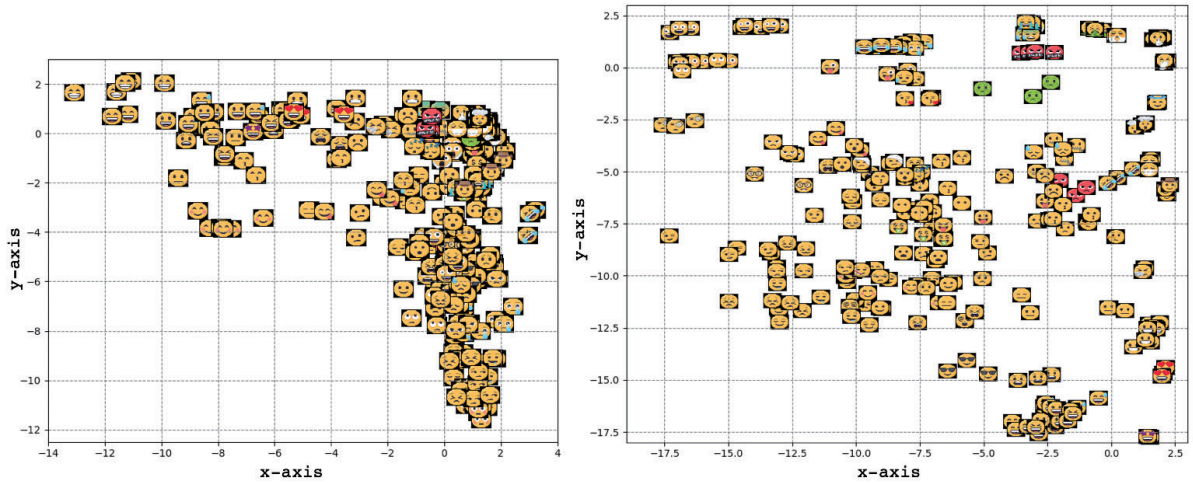
提案手法と従来手法の比較　CNN ベースの分類器による分類精度は，提案手法と従来手法で有意ではあるが 2%程度の差しか見られない．一方，従来手法の Inception スコアは，データセットのスコアとかなり近い数値を示しており，提案手法と従来手法の Inception スコアには 0.27 の大きな差が生じている．対照的に，エポック単位での実行時間に着目すると，提案手法は従来手法よりも 1.67 倍高速に動作している．また，従来手法は生成精度を最大化するのに 1400〜1500 エポック程度を要するが，提案手法は 200 エポックで十分である．以上から，提案手法は従来手法よりも画質の観点では劣るが，入力のキャプションに従った画像をより高速に生成できることが示された．

3.4 潜在表現の可視化

テキストエンコーダ (QRNN) と事前学習済み単語ベクトル GloVe を用いて条件付けられた，エンコーダネットワークがどのように入力画像を潜在変数に落とし込んでいるのかを，潜在表現を可視化することにより検証した．図 3 は，GloVe を用いて学習を行ったエンコーダモデルと，GloVe を用いないで学習をしたエンコーダモデルの出力の散布図を示している．図 3 において，同種の絵文字は，事前学習済み単語ベクトルの有無に関わらず，互いに近い位置にプロットされている．したがって，埋め込み層とテキストエンコーダは，入力のキャプションの意味を捉えて，同種の絵文字に対して似たような数値を持つベクトルを生成できている．図 3(1) にプロットされている絵文字の意味に着目をすると，x の値が小さければ小さいほど，より “positive” な絵文字がプロットされている．対照的に，y の値が小さければ小さいほど，より “negative” な絵文字が現れている．さらに，“positive” や “negative” の指標では分類の難しい絵文字は，原点: $(x, y) = (0, 0)$ 付近にプロットさ

*1　CNN ベースの分類器を実装し，82 種類の絵文字を分類できるようにデータセットで学習させた．データセットのうち 10%をテストセットとした．分類器は 20 エポックの時点で，学習用セットにおいて，0.995，テストセットにおいて，1.00 の精度を記録した．

*2　実装は `https://github.com/gucci-j/emoji-gan` に公開した．



(1) With pre-trained word vector　　(2) Without pre-trained word vector

図 3: エンコーダネットワークの出力散布図: 全データセットを学習済みのエンコーダネットワークに入力し，その出力を散布図上にプロットした．なお，マーカーを対応する入力の絵文字に置き換えた．

れている．一方，図 3(2) においては，各絵文字はカテゴリ毎に分類されているものの，図 3(1) のような大域的な絵文字の関係性を見出すのは困難である．図 3(1) と (2) の散布図における絵文字の大域的な分布の違いは，事前学習済み単語ベクトルの影響によるものが大きい．以上の実験結果より，分布が異なる絵文字間の大域的な関係性を含むときには，出力画像のノイズが軽減されるものと示唆される．

4. おわりに

本研究では，入力のキャプションに対応する絵文字を生成できる CVAE ベースのモデルを提案した．また，事前学習済みの単語ベクトル GloVe を活用することで出力画像の画質が向上することが示された．

今後の展望としては，未知のキャプションデータに対して，適切な絵文字を合成できるようにモデルを改良することが挙げられる．これにより，モデルが豊富な種類の絵文字を生成できるようになり，平文でのコミュニケーションがより促進されることが期待される．

参考文献

[1] Francesco Barbieri, Miguel Ballesteros, and Horacio Saggion. Are emojis predictable? In *Proceedings of the 15th Conference of the European Chapter of the Association for Computational Linguistics: Volume 2, Short Papers*, pp. 105–111. Association for Computational Linguistics, 2017.

[2] James Bradbury, Stephen Merity, Caiming Xiong, and Richard Socher. Quasi-recurrent neural networks. In *arXiv*, Vol. abs/1611.01576. 2016.

[3] Ben Eisner, Tim Rocktäschel, Isabelle Augenstein, Matko Bosnjak, and Sebastian Riedel. emoji2vec: Learning emoji representations from their description. In *Proceedings of The Fourth International Workshop on Natural Language Processing for Social Media*, pp. 48–54. Association for Computational Linguistics, 2016.

[4] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E Hinton. Imagenet classification with deep convolutional neural networks. In *Advances in Neural Information Processing Systems 25*, pp. 1097–1105. 2012.

[5] Jeffrey Pennington, Richard Socher, and Christopher D. Manning. Glove: Global vectors for word representation. In *Empirical Methods in Natural Language Processing (EMNLP)*, pp. 1532–1543, 2014.

[6] Marcel Puyat. Emotigan : Emoji art using generative adversarial networks. `http://cs229.stanford.edu/proj2017/final-reports/5244346.pdf`, 2017.

[7] Alec Radford, Luke Metz, and Soumith Chintala. Unsupervised representation learning with deep convolutional generative adversarial networks. In *arXiv*, Vol. abs/1511.06434. 2015.

[8] Dianna Radpour and Vivek Bheda. Conditional generative adversarial networks for emoji synthesis with word embedding manipulation. In *arXiv*, Vol. abs/1712.04421. 2017.

[9] Kihyuk Sohn, Honglak Lee, and Xinchen Yan. Learning structured output representation using deep conditional generative models. In *Advances in Neural Information Processing Systems 28*, pp. 3483–3491. 2015.

[10] Christian Szegedy, Vincent Vanhoucke, Sergey Ioffe, Jon Shlens, and Zbigniew Wojna. Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 2818–2826, 2016.

General Session | General Session | [GS] J-9 Natural language processing, information retrieval

[2L5-J-9] Natural language processing, information retrieval: data collection

Chair:Koichiro Yoshino Reviewer:Hidekazu Oiwa

Wed. Jun 5, 2019 5:20 PM - 6:20 PM Room L (203+204 Small meeting rooms)

[2L5-J-9-01] Trial production of distributed representation dictionary based on multi attributional description including common knowledge

○Hajime Murai Murai[1] （1. Future University Hakodate）

5:20 PM - 5:40 PM

[2L5-J-9-02] A Collection of Sets of Metaphorical Mappings Annotated with Story World Calls

○Suguru Matsuyoshi[1], Akira Utsumi[1] （1. The University of Electro-Communications）

5:40 PM - 6:00 PM

[2L5-J-9-03] Construction of Coherent Translation Evaluation Dataset in Machine Translation

○Kaori Abe[1], Jun Suzuki[1,2,3], Masaaki Nagata[3], Kentaro Inui[1,2] （1. Tohoku University, 2. Center for Advanced Intelligence Project (AIP), 3. NTT Communication Science Laboratories）

6:00 PM - 6:20 PM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

常識的知識を含んだ多属性記述に基づく分散表現型辞書の試作

Trial production of distributed representation dictionary based on multi attributional description including common knowledge

村井　源[*1]
Hajime Murai

[*1] はこだて未来大学
Future University Hakodate

In order to carry out detailed semantic processing for non-grammatical short sentences such as daily conversations, it is necessary to store common sense knowledge. For combining common sense to machine readable dictionary, construction method for manual distributed representation dictionary was proposed based on relationships between words that are derived from traditional ontologies. Moreover, prototype distributed representation dictionary of about 30000 words based on 37 attributes was developed. Manually described distributed representation is readable from both human and machine, and also it has both high scalability and applicability. In the future it is necessary to confirm the objectivity of description by multiple analysts.

1. 背景

自然言語処理など言語を計算機上で処理するためには機械可読な形式で記述された単語の辞書が必要となる. 機械可読な形式の単語辞書には様々な種類があり, ごく基礎的な品詞のみの情報を記したものから, 活用形や表記ゆれに対応したもの, 単語間の意味処理に利用可能な情報にまで踏み込んで記述した意味辞書などがこれまで様々に開発されてきている. 機械可読の意味辞書においては, 同義語, 類義語, 対義語,上位語, 下位語, 部分語(meronym) , 全体語(holonym)などの単語間の関係が人間可読のデータとして構造化・記号化されている場合が多い[Miller 1995]. このような意味辞書は人手によって構築されるか, 機械的に得られたデータを人手で修正して用いることが一般的である. これらの機械可読の意味辞書は存在論にあやかってオントロジーなどと呼ばれている.

一方で近年 Word2vec などのニューラルネットや機械学習を用いた意味表現の自動獲得の手法が盛んになっている[Mikolov 2013]. Word2vec などの自動的に意味表現を獲得する手法においては分散表現と呼ばれるような意味をベクトルとして表現する形式が主流である. Word2vec で得られたベクトルは意味の加法や減法の計算が可能であることから, 大きな注目を集め現在も急速に関連研究が進められている.

現在テキストマイニングなどの分野で主流になっているのは, 大規模なコーパスを対象として特定の単語を探したり数えたりするようなタスクであり, この場合には機械可読辞書は同義語や類義語がグルーピングできれば十分に実用的なレベルと言えよう. このため, 自動的に獲得された分散表現を用いて単語間の距離を計算し, マイニングを行うような実践が多数行われている.

しかし, 例えば会話文を対象として自然言語処理を行うような場合には, テキストは短文でかつ主語や述語, 目的語が頻繁に省略されるなど文法的には不整合であり, また同じ対象を指す単語が逐次言い替えによって変化する(立場による呼称の変化, 繰り返し表現を避けるための言いかえなど). 人間が会話文を理解する場合には種々の常識的知識によって省略された品詞を補ったり, 言い換えられた単語間の関係性を類推したりすることで処理を行うが, これを機械的に実現するためには, 単純な単語間の関係性のみを記した意味辞書のみでは不十分であると考えられる. なお, マイニングの対象となるようなテキストの場合にもこの種の言いかえや省略はもちろん存在しているが, 大規模なデータを収集して統計的に分析することによって, 個々のレベルの問題はノイズとして平滑化され, 全体的な傾向が抽出されるようになっている.

今後, コーパス全体ではなく特定の短いテキストの意味処理や日常会話や物語文などのくだけた口語的なテキストの意味処理を実現するためには, 従来の単語間の関係性に合わせて, 常識的な知識などの人間がテキストを理解する場合に用いる様々な知識が追加できる機械可読の辞書が必要になると考えられる. そのため, 本研究では常識的知識を含んだ分散表現型辞書を構築する手法を検討し, 辞書の試作を行った.

連絡先: h_murai@fun.ac.jp

2. オントロジーと分散表現

従来主流であった単語間の関係や構造を記号等で記述するオントロジー型の意味辞書に関しては, 生成を自動化する試みも様々になされてきているが自動生成した場合には概して精度が低く, 現段階では実用レベルで構築するためには最終的に人間による確認が必要であると言えよう. 例えば世界的に用いられている WordNet [Miller 1995]や, 日本語で頻繁に利用される分類語彙表[国立国語研究所 2004]などは基本的に人間が分類した結果に基づいて構築されている.

人手により構築されたオントロジーは, 精密に語彙の分類や関係性の抽出を行えば, 辞書編纂者によって作成された通常の類語辞書と同等の精度を持たせることが可能である. しかしその反面, 構築に多大な人的コストが必要となると考えられている. 完成したオントロジーの精度を担保するためには複数人によるチェックも必要となり, 一人で構築する場合に比べてさらに数倍のコストがかかる. なお, 複数分析者によるチェックを経ても, 語彙間の関係性や全体的構造は基本的に辞書構築者の解釈に依存するため, 類語辞典と同様に構築者によってカテゴリの種類や構成が異なりうる[山内 2010]. このように単語や意味概念の分類においては唯一絶対の分類法が存在しないという点にも留意する必要がある. つまり特定の分析者によって構築された辞書は, 辞書構築者が想定した意味分類や推論には有用性が

高いが，それ以外の様々に異なる観点から単語の意味を柔軟に比較する処理の実現にも適用可能であることは保証されない．

一方で，Word2vecなどの分散表現はベクトルで構成されるため加法や減法以外にも様々な数学的な変形や分析が可能であり，多様な類似度の計算が実現できる．

しかし，言語の性質上単に共起すれば意味が同じになるわけではなく，品詞や機能語，文法上の役割や能動態・受動態など様々な要因でテキスト中での単語が示す概念は異なりうる．実際に名詞では Word2vec から得られた分散表現は比較的高い精度を得られるものの，動詞での精度は低くなってしまっている[Schwartz 2016]．おそらく,動詞の方が能動態・受動態などの態による違いや慣用句的な複合語による意味の変化の影響を強く受けるためと推測される．また名詞の中でも文脈の類似しやすい反義語の識別に関しても脆弱である点が指摘されており，反義語識別精度の改善には単語の評価極性等を内包したオントロジー[Baccianella 2010] などが必要となるとの研究もある[Dou 2018]．

また，ニューラルネットワークを用いた分散表現で得られる類似度には多様な種類が内包されると考えられるが[Vindula 2017]，ベクトルの各次元が何を意味するかに関しては個別的にいくつかの特徴量を取り上げた考察はあるが，全体的にその構造を理解する方法は発見されていない．そのため，ある類似度の高い語彙の関係が同義語なのか上位・下位語なのかあるいは全体語・部分語なのか判別することは容易ではない．また Word2vec が出力する分散表現のベクトルは元となるコーパスだけでなく，種々のランダムなパラメータによっても構造が変化するため，既存の複数の分散表現を統合させることや，単語概念の詳細化，高度化などのための情報を事後的に追加して発展させるようなことも困難である．構造が単純で応用性が高く，コーパスさえ準備できれば人手によるコストが著しく低いというメリットの反面，ブラックボックス性が高く，追加や更新などの処理には不向きであると言えよう．

他にニューラルネットワーク等を介さずに複数文書中での単語の出現頻度や他の単語との共起頻度をベクトル化する手法も研究されてきている．この場合ベクトルの各次元が持つ意味に関しては人間可読であるが，元となるコーパスや共起単位等によって得られるベクトルが異なり，また単語間の関係性の種類の弁別も容易ではない[秋山 2010]．

3. 多属性記述に基づく分散表現

現状ではオントロジー的記述と分散表現的記述の双方にメリットデメリットがあるが，理想的には両方のメリットを合わせたような表記法が望ましい．これらの統合を図る研究には WordNet 等のカテゴリを用いて，分散表現の自動生成結果の精度を上げる試みなどが行われてきている[Vindula 2017]．また逆に分散表現の結果から語彙の上位・下位関係を抽出する試みなどもある[市瀬 2015]．

本研究では，これらに対して人間と機械双方から可読な辞書形式として，分散表現をオントロジー的知識に基づき人手で構築する方法を採用する[村井 2018]．また，常識的な知識は命題形式で，機能によって分類された動詞辞書に基づき，人手による入力を行う．

具体的にはまず，分散表現の各次元の特徴量を従来のオントロジー的な種々の属性(例えば，物質性,抽象性，生物か否か，知能を持つか否か等)に準じる形で規定してベクトルを作成する．例として鳥と飛行機の場合のオントロジー例とその分散表現への変換例をそれぞれ図 1 と表 1 に示す．図 1 では単純なオントロジーの例として is-a 関係と part-of 関係のみを示した．

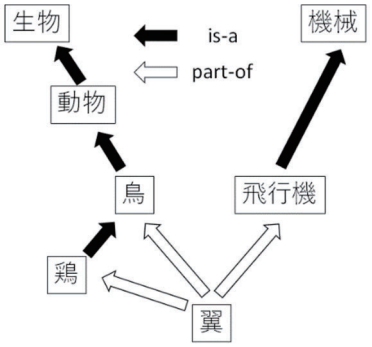


図 1　オントロジー例

表 1　分散表現例

	生物	動物	鳥	鶏	機械	飛行機
生命	1	1	1	1	0	0
能動	0	1	1	1	1	1
翼	0	0	1	1	0	1
飛行	0	0	1	0	0	1

単語の関係性から分散表現を構築する方法は無数に考えられるが，単純化のために語彙の意味的な差異の最低限の弁別ができる次元を設定する方針を採る．図 1 の場合「生物」「動物」「鳥」「鶏」と「機械」「飛行機」の群を弁別するために，「生命」のあるなしを示す次元をまず付与する．次に「生物」と「動物」「鳥」「鶏」を弁別するために「能動」性の有無を示す次元を追加する．さらに，「動物」と「鳥」「鶏」の弁別と，「機械」と「飛行機」の弁別を可能とする「翼」の有無を示す次元を追加する．最後に，「鳥」と「鶏」を弁別するために「飛行」能力を示す次元を追加すると，全単語を異なったベクトルで分散的に表現できる(表 1)．なお，「機械」と「動物」に共通して「能動」性があり，「鳥」と「飛行機」に共通して「飛行」能力があることは図 1 の関係性には含まれず，表 1 で追加されたものである．

表 1 のように分散表現を記述すると，Word2vec と同様に，

「鳥」—「生物」＋「機械」=「飛行機」

のような意味の演算処理も可能となる．

このように明示的に意味を定義された属性を次元として持つ分散表現ベクトルでは，特定の次元を複数組みあわせて(あるいは単独で)用いて距離の演算を行うことで，例えば生物全体の中での類似度や，特定の地域に存在する物の中での類似度，特定の機能の有無に合致する範囲の中での類似度など多種多様な類似度計算が実行可能である．

また各次元の意味は明示的であるため，各語彙が保持する概念の内容と，それらを用いた演算の過程及び結果は，人間の分析者にも理解可能である．そのため分析者が確認することで，誤りの発見や訂正による改善での精度向上が可能である．

表 1 のような記述は，利用者側の必要に応じて適宜新規の次元(属性)を追加して変更することが容易である．オントロジー構築で問題となる本質的な唯一の分類が存在しないという性質も，必要に応じて他の分析者が次元を併記的に追加することで実用的には回避可能である．

上記に加えて本研究ではオントロジーに基づく属性記述に合わせて，各概念に付随する一般的な常識的知識を命題的な表現形式で追加する方式を提案する．命題は分野によって異なるニュアンスを持つが，本稿では内容分析やプロトコル分析の用例に基づき，少なくとも一つの主体と言動的単語を含めた文の意味の最小単位を指すこととする[14].

例えば，「毒物」を概念として定義し記述する場合を考える．人間が道具として利用する「毒物」の機能は「殺す」ことであるが，これは動詞一つで記述可能である．これに合わせて，推理小説などで頻出する毒物を食品や飲み物に混ぜて用いるという使用方法に関する常識的知識も辞書中に含めることを考える．

命題的な表現形式を例えば，「主体:言動:対象 1:対象 2」の形式で記述するとすれば，「人が毒物を食品に入れる」は，「人:入れる:毒物:食品」のように表現できる．命題的表現は形式化された文であるため，このように 1 つの単語で表現できないような複合的な意味構造も表現することが可能である．

会話や物語文中においては特に，死などの強くネガティブなニュアンスを持つ概念は間接的に表現される傾向があり，例えば『毒物を入れられた』と書かれていれば『殺す』という単語がなくてもその可能性を類推する必要がある．単語の持つ一般的機能や常識的知識を動詞や命題の形式で辞書中に含めることで，「毒物」としか書かれていないくても「殺す」が暗示されているという情報を処理可能となる．

頻出命題の検討においては国立国語研究所によるコーパス中の係り受け関係の分析結果を公開している NINJAL-LWP for BCCWJ [国立国語研究所 2012]を参照した．また動詞の記述は機能によって分類した動詞辞書を用いて行った[村井 2017].

4. 属性記述の設計と結果

属性記述の設計にあたっては従来のオントロジー工学での比較的固定的な属性（Type 属性）と状況依存的に変化する役割的属性（Role 属性）の二種類を中心として他に文体的な属性（丁寧語，粗野語など）や各概念カテゴリに固有の属性などを必要に応じて追加して記述した．現在 37 種類の属性を規定している(表 2). Type 属性は上位下位概念や全体・部分関係，形状や色・模様の指定などは他の概念を指定する形で記述した．上位概念や全体・部分関係などは複数の概念が該当する場合があるがそれらはリストとして列挙する形で記述している．これら他の概念を参照する記述は従来のオントロジー表現に対応させることが可能である．それ以外は数値等に置き換え可能な定形表現として記述している．

辞書の作成においては，分類語彙表[国立国語研究所 2004]と日本語 WordNet[Bond 2012]所収の名詞中で現在一般的に用いられているものを中心に分類し,類似の単語をグループ化してそれぞれに属性の値を記述した．現在合計で 33013 単語を 3088 のグループに分類し，3088 グループのそれぞれに 37 種類の属性を設定している．表 2 中の「記述数」は 3088 グループ中で各属性に記述があるグループの数を示している．

実際のデータの例として，学校に所属する(part-of が「学校」)主体的な名詞（人間など言動の主体となる名詞）を抽出した場合の主な属性値記述の例を表 3 に示す．このような絞り込みは例えばテキスト中で場所が学校である場合に詳細不明の人物が出現した場合などに応用可能であると考えられる．表 3 中では分類された名詞グループが 15 種類あり，それぞれ分類名が左端に記されている．試作段階であるため各名詞のグループは比較的大きなまとまりになっているが今後より詳細に分割することも可能である．「代表的上位概念」は複数あるがいずれも人的存在か団体のいずれかの属性を有している．また年齢は「時間量」の箇所に，性別は「性」に数値ではなく文字列として記述されている．「先公」は侮蔑表現だが社会的な立場が上の対象に対する表現であるため「丁寧・粗野」が負，「社会的立場」が正の値になっている．名詞グループと関わる常識的知識は「言動」「主体的言動」に記述されている．例えば，「教える」言動を行う人物は「先生」の属性値を持ついずれかの名詞グループに属している可能性があるというような類推に利用可能である．

表 2 分散表現に用いた属性とその記述数

形式	属性名	内容	記述数
他の概念の指定	上位概念	is-aに相当する概念	3088
	被含有概念	part-ofに相当する概念	1342
	含有概念	part-ofの逆に相当する概念	1008
	構成材料	構成する物質のリスト	1344
	世界設定	特定の場所時間の指定	807
	形状	形を種類で分類	432
	色	色の指定	78
	模様	模様を種類で分類	10
数値等	全体・部分	全体か部分かの指定	480
	内部・外部	内部,境界,外部等の指定	145
	順序	前後等の指定	144
	時間前後	過去,現在,未来の指定	66
	時間指定	絶対時間か相対時間か	523
	時間量	秒,分,時等時間の単位	1477
	空間次元	1,2,3次元のいずれか	2690
	空間量	平均的なサイズの指定	1154
	三相状態	気体,液体,固体	1360
	透明	透明の場合に指定	23
	発光・光沢	発光する場合に指定	20
	位置	位置関係を示す場合に指定	80
	向き	方位等向きを示す場合に指定	74
	抽象	抽象的に用いやすい場合に指定	567
	自然	自然物の場合に指定	962
	人工	人工物の場合に指定	1019
	情報聴覚	音声を示す場合に指定	79
	情報視覚	視覚を示す場合に指定	221
	情報記号	記号を示す場合に指定	204
	情報その他	電気や熱等を示す場合に指定	83
	性	生物等の場合に性別の指定	317
	数	複数である場合の指定	583
	丁寧粗野	丁寧・粗野表現の場合に指定	158
	立場・価値	敬意や価値を含む場合に指定	195
	人称	代名詞等での人称の指定	67
命題	言動・現象	言動として用いうる場合に指定	1060
	主体言動	対象が主体の場合の頻出言動	1551
	客体言動	対象が客体の場合の頻出言動	997
	その他言動	対象がそれ以外での頻出言動	893

表 3 「学校」を被含有概念とする主体的な名詞を抽出した場合の主要な属性値の例

分類名	分類名詞	代表的上位概念						時間量	性	丁寧粗野	社会的立場	言動	主体言動
		人的存在	団体	職種	立場	先生	受講生						
教職員組合	教職員組合,日教組		1					生物_大人					A:教える
校長	校長,校長先生,学校長,学長,学部長,学科長,教頭,教頭先生,園長,学園長	1		1	1	1		生物_大人			100		A:教える,A:叱責,A:戒める
先生	先生,教授,助教授,准教授,助教,教員,教育者,教官,教諭,教師,講師	1		1	1	1		生物_大人			10	教える	A:教える,A:叱責,A:戒める
先公	先公,センコウ	1		1	1	1				-10	10	教える	A:教える,A:叱責,A:戒める
生徒会	生徒会,学級,クラス,学級会		1										A:相談
保護者会	保護者会,父母会,父兄会,PTA		1					生物_大人					A:相談
部活	部活,部活動,同好会,サークル		1										A:遊ぶ,A:スポーツ
受講者	一年生,二年生,三年生,四年生,五年生,六先生,1 年生,2 年生,3 年生,4 年生,5 年生,6 先生,塾生,予備校生,門弟,弟子,兄弟子,弟弟子,門下生,門徒,弟々子,門弟子,門人,門生,見習い,見習,学級委員,教え子,受講者,受講生	1			1		1					教わる	A:教わる,A:行く:[学校]
受験者	受験生,受験者,浪人生,浪人,一浪,二浪,三浪,仮面浪人	1			1		1	生物_青年				試験	A:合格:@[入学試験]->A:所属:C
学生	学生,大学生,学部生,院生,大学院生,修士,一回生,二回生,三回生,四回生,1 回生,2 回生,3 回生,4 回生,学徒	1			1		1	生物_青年				教わる	A:教わる,A:行く:[大学]
女学生	女学生,女子学生,女子大生	1			1		1	生物_青年	女			教わる	A:教わる,A:行く:[大学]
生徒	生徒,中学生,高校生	1			1		1	生物_小児				教わる	A:教わる,A:行く:[高校]
女子高生	女子高生	1			1		1	生物_小児	女			教わる	A:教わる,A:行く:[高校]
男子高生	男子高生	1			1		1	生物_小児	男			教わる	A:教わる,A:行く:[高校]
小学生	小学生,学童	1			1		1	生物_児童				教わる	A:教わる,A:行く:[小学校]

5. 今後の課題

本研究では常識的知識を含む，人と機械双方から可読で追加修正容易な分散表現辞書の構築手法の提案と試作を行った．

構築された辞書は種々のテキストの意味処理に利用可能と考えられるが，従来の日本語意味辞書では難しかった利用方法としては下記などがありうると思われる．

- 特定の条件下での該当単語候補の絞り込み（例：家庭にある道具，会社にいる人物）
- 常識的な知識による省略情報の類推（例：店で客にあいさつする人物がいればおそらく店員か店長）
- 特定の属性に限定した条件下での種々の類似度の計算（例：推理小説の解釈の場合に病院での犯行なら凶器に近い属性を持つものとして薬品やメスがリストアップできる）

構築された辞書の性質や有用性を確認するために今後既存のオントロジーや分散表現辞書との比較が必要であると考えている．また構築された分散表現辞書の記述は一人の分析者によるものであるため，記述の客観性を担保するためには他の分析者による確認と追記も今後の課題である．本研究の成果は内容の評価と修正後に Web 上での公開を予定している．

参考文献

[秋山 2010] 秋山哲史, 内海彰: 概念間の関係に関する単語の意味空間の性質ーコーパス，構築手法，文章単位による影響ー, 認知科学, Vol. 17, No. 1, pp. 110-128, (2010).

[Baccianella 2010] Baccianella, S., Esuli, A., Sebastiani, F.: Sentiwordnet 3.0: an enhanced lexical resource for sentiment analysis and opinion mining. In: LREC, Vol. 10, pp. 2200-2204, (2010).

[Bond 2012] Bond, F., Baldwin, T., Fothergill, R., and Uchimoto, K.: Japanese SemCor: A Sense-tagged Corpus of Japanese, The 6th International Conference of the Global WordNet Association (GWC-2012), (2012).

[Dou 2018] Dou, Z., Wei, W., and Wan, X.: Improving Word Embeddings for Antonym Detection Using Thesauri and SentiWordNet, NLPCC 2018, LNAI 11109, pp. 67–79, (2018).

[市瀬 2015] 市瀬龍太郎, 荒川直哉: 分散表象とオントロジーの関係, 第 29 回人工知能学会全国大会予稿集, 2I4-OS-17a-5, PDF, (2015).

[海保 1993] 海保 博之, 原田 悦子: プロトコル分析入門―発話データから何を読むか, 新曜社, (1993).

[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).

[国立国語研究所 2012] 国立国語研究所: NINJAL-LWP for BCCWJ, http://nlb.ninjal.ac.jp/search/, 2019/1/28 参照.

[Mikolov 2013] Mikolov, T., Sutskever, I., Chen, K., Corrado, G. S., Dean, J.: Distributed representations of words and phrases and their compositionality, In Advances in neural information processing systems, pp. 3111-3119, (2013).

[Miller 1995] Miller, G. A.: WordNet: a lexical database for English, Communications of the ACM, Vol. 38, No. 11, pp. 39-41, (1995).

[村井 2018] 村井源: 分散表現型物語機能辞書の提案と試作, 情報処理学会シンポジウムシリーズ, Vol. 2018, No. 1, pp. 47-52, (2018).

[村井 2017] 村井 源: 言動分類による物語機能辞書の汎用化に向けて, 情報処理学会シンポジウムシリーズ, Vol. 2017, No. 2, pp. 225-230, (2017).

[Schwartz 2016] Schwartz, R., Reichart, R., Rappoport, A.: Symmetric Patterns and Coordinations:Fast and Enhanced Representations of Verbs and Adjectives, Proceedings of NAACL-HLT 2016, pp. 499–505, (2016).

[Vindula 2017] Vindula, J., et al.: Deriving a representative vector for ontology classes with instance word vector embeddings, Innovative Computing Technology (INTECH), 2017 Seventh International Conference on. IEEE, pp. 79-84, (2017).

[山内 2010] 山内隆史, 楠見孝: 概念研究からみたオントロジー工学, 認知科学, Vol. 17, No. 1, pp. 54-65, (2010).

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

物語世界間のつながりが一部明示されたメタファー写像セットの構築

A Collection of Sets of Metaphorical Mappings Annotated with Story World Calls.

松吉 俊　　内海 彰
Suguru Matsuyoshi　　Akira Utsumi

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

We have proposed a novel framework for narrative generation. This framework converts a sequence of states generated by a simulator into the corresponding event sequence in a story world with metaphorical mappings. In this paper, we describe a collection of sets of metaphorical mappings for chess and maze solving. We annotated a part of them with story world calls for the purpose of using them as a training data for scoring drafts of narratives. We conclude that we have 291 sets of metaphorical mappings available for narrative generation.

1. はじめに

人工知能や認知科学の分野において、物語文章自動生成システムの研究は古くから取り組まれてきた [秋元 13, Gervás 18]。物語生成の主な流れは、物語内容 (story) の決定、物語言説 (discourse) の決定、文字列化である。

我々は、この流れを利用しない新しいパラダイムとして、シミュレーションとメタファー写像を利用するフレームワークを提案した [松吉 18a, 松吉 18b]。この手法の概要を図 1 に示す。このフレームワークでは、計算機が人間と同等以上の推論・探索能力を発揮することが期待できるシミュレーションやゲーム *1 を用いる。計算機上でこのシミュレーションを実行すると、実行に付随する「状態」や「行動」の列 (状態遷移列) が取得できる。例えば、迷路探索シミュレーションの場合、エージェントの位置座標のリストが、チェスの場合、駒の動きのリストが取得できる。このフレームワークでは、状態遷移列を比喩的に解釈することにより、物語文章を自動生成する。例えば、迷路探索は恋愛物語として比喩的に解釈可能である。「ゴールに近づく」位置変化を「楽しくデートする」イベントに写像し、「ゴールから遠ざかる」位置変化を「顔を見れない」状態に写像することが考えられる。このようなメタファー写像により自動生成された物語を図 2 に示す。同様に、チェスで「相手の駒を取る」様子を「部屋の中の物を片付ける」イベントに写像することにより、チェスの試合を部屋の片付けとして比喩的に解釈することも可能である。このようなメタファー写像により自動生成された物語を図 3 に示す。

物語の草稿を生成するにあたり、このフレームワークが入力とするものは、次の 4 つである。

シミュレーター 現実世界の一部をシミュレート [松尾 16] する

AI シミュレーションにおいて、エージェント等がどう動くかを決定するアルゴリズム

状況 シミュレーションを実行する場

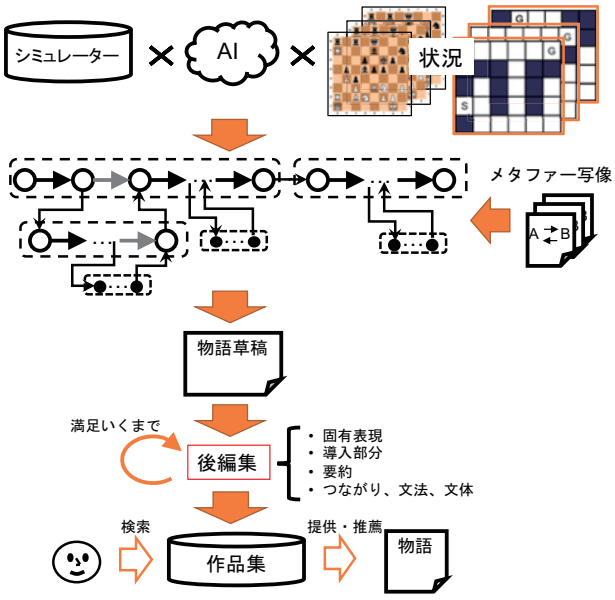


図 1: シミュレーションとメタファー写像を利用する物語文章生成フレームワーク

メタファー写像セット 状態遷移列を比喩的に解釈するために利用される

このフレームワークが生成することができる物語の本質的な異なり数は、シミュレーターを 1 つ固定するごとに、およそ「AI の異なり数」×「状況の異なり数」×「メタファー写像セットの異なり数」となる。それぞれの専門家がそれぞれを開発することにより、フレームワーク全体として生成可能な物語の数を増やすことができることは、このフレームワークの特長の 1 つである。

図 1 に示されるように、本フレームワークでは、1 つの物語を生成するにあたり、複数の様々なシミュレーションを実行することを想定している。2 つのシミュレーションを実行し、それらから生成された物語文章を直列的に繋げて、長い 1 つの物語とするだけでなく、物語文章の途中に、別のシミュレーションから生成された物語文章を埋め込むことも可能である。

連絡先: 松吉 俊、電気通信大学大学院 情報理工学研究科、東京都調布市調布ヶ丘 1-5-1 電気通信大学 西 5 号館 505 号室、042-443-5292、matuyosi@uec.ac.jp

*1 以下、シミュレーションと言った場合、ゲームを含めるものとする。

ジョンは会社員。アンは同じ会社の同僚。2 人は付き合い始めた。話が盛り上がることが数日続いた。今日は楽しくデートした。今日も楽しくデートした。今日は顔を見れない。今日は楽しくデートした。今日も楽しくデートした。話が盛り上がることが 3 日続いた。ついに結婚した。

図 2: 自動生成された物語の例: 「恋愛」

部屋の掃除を開始した。本を整理した。さらに本を整理した。掃除機をかけた。机の引き出しを整理した。また本を整理した。掃除機をかけた。本を整理した。さらに本を整理した。机の引き出しを整理した。掛け布団を干した。幼い頃から使っていたブランケットを見つけた。捨てるべきか悩ましい。悩んだ結果、ブランケットを捨てることにした。本を整理した。部屋の掃除が無事終わった。

図 3: 自動生成された物語の例: 「部屋の片付け」

先の図 3 は、チェスによって生成された片付けの文章である。この中に、「捨てるべきか悩ましい。」という文が生成されている。「実行すべきかどうか悩む」という状態において、「悩みに関する思考過程」として迷路探索を比喩的に解釈することで生成された物語文章を、サブの物語としてメインの物語の中に埋め込むことができる。実際に埋め込んだ結果を図 4 に示す。この図の下線部分が、迷路探索により生成されたサブの物語文章である。

現在、我々は、メタファー写像セットの拡充を進めている。本論文では、チェスと迷路探索に関するメタファー写像セットの構築について報告する。本フレームワークでは、大きなプログラムにおいてサブルーチンがサブルーチンを呼び出すように、物語世界が別の物語世界を呼び出す。計算機に知的にこれを実行させるための学習データとして今後利用することを想定し、物語世界と物語世界の間のつながりをアノテーションした。このアノテーション結果についても報告する。

2. 関連研究

2.1 物語文章生成

物語文章生成に関して、これまでに様々な手法が提案されている [秋元 13, Gervás 18]。その主なものは、物語文法などに基づき、独自の記法で記述されたスクリプト (事象集合のグラフ) を操作する手法 [秋元 13, Akimoto 17, Montfort 13, 佐藤 16] である。ニューラルネットワークを用いて、これまで生成した語句の列から次の語句を生成することを文の境界を越えつつ繰り返すことにより、文章を生成する手法 [浅川 15, Jain 17, Fan 18, Martin 18] も提案されている。

ゲームやシミュレーションを実行して得られた出力や実行ログの列を文字列に翻訳することにより、その世界の物語を文章として語る手法 [福田 15, 鳥海 16, 松山 17] が提案されている。我々の手法と同じようなアプローチであるが、我々の手法では、メタファー写像を利用することにより、1 つのシミュレーションから様々なジャンルの物語を生成できる点が異なる。

Gervás は、チェスの駒を単に「シミュレーション世界の人間」とみなし、少数の駒の盤上の動きから、「逆境の恋」の物語や「誘拐」の物語を生成する手法を提案している [Gervás 18]。

部屋の掃除を開始した。本を整理した。さらに本を整理した。掃除機をかけた。机の引き出しを整理した。また本を整理した。掃除機をかけた。本を整理した。さらに本を整理した。机の引き出しを整理した。掛け布団を干した。幼い頃から使っていたブランケットを見つけた。捨てるべきか悩ましい。困っており、どうするか悩む。まだ悩みたい。実行についてしっかり考える。やはり実行してしまってよいと思う。実行についてもっとしっかり考える。実行することに決めた。悩んだ結果、ブランケットを捨てることにした。本を整理した。部屋の掃除が無事終わった。

図 4: 「部屋の片付け」に「悩みに関する思考過程」を埋め込んだ物語

この手法では、独自の記法で記述された 7 つのスクリプトと、「ヒーロー」や「悪党」などの役職が与えられたチェスの駒を用いる。盤上の 1 つの駒を指定し、その駒に視界を定め、チェスを実行し、その視界内に生起したイベント集合の列を記録する。各スクリプトとイベント集合列の一致度を算出し、閾値を超えるスクリプトがあれば、スクリプト内の人名スロットを駒の名称 (例えば、「白のポーン」) で埋めることにより、物語文章を生成する。Gervás がスクリプトを利用した理由は、「目的を持ったストーリーを生成するためである」と論文中で説明されている。チェスの駒の動きを比喩的に解釈する点は我々のアプローチと同様であるが、我々のアプローチでは、理論的である一方、難解になりがちである研究者独自の内部表現を使わず、自然言語で記述することができ、共有しやすいメタファー写像セットを利用している点が異なる。

2.2 言語学におけるメタファー

認知言語学の概念メタファー理論において、メタファーは、2 つの意味領域間の連結であると捉えられる [鍋島 11, アリス 10]。メタファー写像に関して、Lakoff [Lakoff 93] は、「写像において、目標領域が課す制約が許す範囲で、根源領域の表現間の (位相) 構造は目標領域内でも保たれる。」という不変性原理を提唱した。我々の物語自動生成フレームワークは、この不変性原理から着想を得て次の 2 つの仮説を定め、それを検証するものである。

- テキストのジャンルを問わず、2 つの意味領域の間に数個のメタファー写像の存在が確認されれば、それら以外の多くのメタファー写像の対応を確認することができる
- ゲームやシミュレーター内に実装されている種々の制約や論理が、物語文章生成においても制約・論理として働くので、物語の展開において、「狭い意味でのフレーム問題」[人工知能学会 05] を回避できる

ある文章においてメタファーが用いられている場合、それと関連したメタファーも用いられていることがよくある。複数の文献 [鍋島 16, アリス 10] で指摘されているように、このようなメタファー集合の大きなデータベースは英語でも日本語でも利用可能でないため、これらに関する言語学的研究はほとんど進んでいない。現在、我々が構築を進めているメタファー写像セットは、まさにこのようなデータベースを作ることに相当する。現在は人手で書き下すことによりデータベースを拡張しているため、「天然物」とは言いにくいが、言語学的研究にも使用できるデータベースとなることも目指している。

```
[_simulator_]
name = chess
[_introduction_]
text = 部屋の掃除を開始した。
[_conclusions_]
text = 部屋の掃除が無事終わった。
else = 今日は諦めた。
[remove_p]
state = 相手のポーンが 1 つ失われる
text = 本を整理した。
[remove_b]
state = 相手のビショップが 1 つ失われる
text = 机の引き出しを整理する。
  :
```

図 5: メタファー写像セットの例: 「部屋の片付け」

```
@@@@@@@@@@          r n b q k b n r
@2220020G@          p p p p p p p p
@0@0@1011@          . . . . . . . .
@S@000111@          . . . . . . . .
@00110010@          . . . . . . . .
@@@@@@@@@@          . . . . . . . .
                    P P P P P P P P
                    R N B Q K B N R
```

図 6: 迷路探索 (左) とチェス (右) の状況の例

表 1: メタファー写像セットの数

	[松吉 18a]	本論文	計
チェス	2	100	102
迷路探索	89	100	189
合計	91	200	291

3. メタファー写像セットの構築

3.1 ファイルの記法

メタファー写像セットは、シミュレーションと物語世界のペアに対して 1 つのファイルとして記述する。メタファー写像セットの例を図 5 に示す。このファイルは、コンフィグファイル形式 (.cfg) である [*2]。アンダースコアで挟まれたセクション名は予約語であり、そうでないセクション名は写像コードである。[_simulator_] にはペアとなるシミュレーションの名前を記述する。[_introduction_] には初期状態で出力する文字列を記述する。[_conclusions_] には終状態で出力する文字列を記述する。“text” に、目標が達成できた時に出力する文字列を、“else” に、目標に至らなかった時に出力する文字列を記述する。“remove_p” や “remove_b” は、計算機が対象イベントを認識するための写像コードである。本来ならば、「相手のポーンが 1 つ失われる」という文字列を計算機が解釈し、シミュレーション世界内でシンボルグラウンディング [松尾 16] することにより、このイベントが発生したかどうかを自動認識すべきである。しかしながら、現在の自然言語処理の技術では高精度に安定してこれを実現することは困難である。それ故、あらかじめ、シミュレーターのラッパーに対して、認識すべきイベントの集合とそれらの認識規則を人手で与え、シミュレーションの実行中にイベントが認識されれば、そのイベントに対応する写像コードを出力するように設計した。現在、図 1 で示される我々のシステムは、状態遷移列を写像コードの列に変換し、その後、メタファー写像セットを用いて写像コードの列を文字列に変換する。[写像コード] の “text” に、物語世界のイベント表現を記述する。現在のところ、“state” は人間の作業者が参照するためだけのものである。

3.2 [松吉 18a] の問題点

以前の我々の研究 [松吉 18a] には次の 2 点の問題があった。

1. 迷路探索の写像コードは、xy 座標空間において上下左右に移動する [up], [down], [left], [right] のみの淡白なものであった

2. 図 1 で示される我々のシステムは、現在の状態から生成された文字列に含まれるキーワードと [_introduction_] の文字列との単純なキーワードマッチにより、埋め込むべき物語世界を探索する。これにより、多数の物語草稿が得られるが、ランキングされないため、どの草稿を優先的に次の後編集に送るべきか判断に困る

3.3 高さの概念の導入

1 つめの問題を解決するために、図 6 の左側に示すように、迷路に高さの概念を取り入れた。この図において、“S” と “G” は、それぞれスタート地点とゴール地点を表す。“0” は「平坦な道」を、“1” は「ちょっと山」を、“2” は「かなり山」を、“@” は「壁」を表すものとした。

写像コードとして、「状態 0 から状態 1 に変化した」ことを表す [01] やその仲間として [02], [12], [2G] などを追加し、さらに、「上移動により状態 0 から状態 1 に変化した」ことを表す [01up] やその仲間として [01down], [02left], [S1right] などを追加した。

3.4 呼び出す物語世界を明示

2 つめの問題を解決する手がかりとして、[写像コード] の “text” の末尾に、別のメタファー写像セットのファイル名を記述できるようにした。これにより、物語世界間のつながりを積極的に示すことができる。

3.5 構築過程

大学生 50 名に、物語文章自動生成システムを実行しながら、メタファー写像セットを人手で記述してもらった [*3]。1 人あたりチェスに関して 2 つ、迷路探索に関して 2 つの計 4 つを作成するよう依頼した。さらに、3.4 節の方法により、物語世界の呼び出しを少なくとも 1 つ記述するよう依頼した。

3.6 分析と考察

以前の研究 [松吉 18a] において構築したメタファー写像セットの数、および、本論文で新たに構築した数を表 1 に示す。現在、物語文章生成のために、291 個のメタファー写像セットが利用可能である。

認知言語学の概念メタファー理論において、よく知られているメタファーの中に〈良は上〉メタファーと〈困難は障害物〉メタファーがある [鍋島 11]。3.3 節で述べたように、高さに対して「山」という表現を使って教示したため、〈困難は障害物〉メタファーに相当するメタファー写像が多かった。今後はこのようなバイアスを避けるために中立的な表現を使用する必要がある。

*2 初心者の理解しやすさと作業しやすさを考慮してこの形式を選択した。

*3 詳細については、次の URL の資料を参照してほしい:
http://www.cl.inf.uec.ac.jp/lec/

表 2: 呼び出し元の物語世界と呼び出された物語世界の例

元 ↪ 呼び出された	数	物語世界呼び出しの例
チェス ↪ チェス	5	恋愛 ↪ 同棲生活
		仕事 ↪ 上司からのお言葉
		魔王討伐 ↪ 技の鍛錬
チェス ↪ 迷路探索	36	高校生活 ↪ 大学受験
		バンド活動 ↪ 曲作り
		料理 ↪ 訪問者の対応
迷路探索 ↪ チェス	10	販売員 ↪ 書類作成
		友達とご飯 ↪ 先輩との会話
		国の発展 ↪ 国家間交渉
迷路探索 ↪ 迷路探索	8	野球練習 ↪ スランプ
		プロゲーマー ↪ トロフィー獲得
		受験勉強 ↪ 勉強法の悩み
合計	59	

表 2 に、シミュレーションの種類ごとに物語世界の呼び出しの例を示す。「チェス ↪ 迷路探索」が一番多かったのは、教示に使用した例がこのタイプであったからであると思われる。妥当な呼び出しが設定されていることがこの表から見てとてる。本フレームワークで得られる多数の物語草稿を適切にランキングするために、学習データとしてこれらの呼び出し事例をうまく活用することは、今後の課題である。

4. おわりに

我々は、シミュレーションとメタファー写像を利用する物語文章生成システムの開発に取り組んでいる。本論文では、チェスと迷路探索に関するメタファー写像セットの構築について報告した。

今後の課題は、大きく 3 つある。1 つは、利用可能なシミュレーションを追加しながらメタファー写像セットの拡充を進めることである。もう 1 つは、生成された多数の物語草稿を適切にランキングする方法を考案することである。最後の 1 つは、冗長な部分を減らし、読みやすい文章とするために後編集システムの開発に取り組むことである。

謝辞

本研究の遂行にあたり、電気通信大学情報理工学域 I 類 (情報系) の 2018 年度『経営・社会情報学実験』履修生に感謝の意を表します。

参考文献

[秋元 13] 秋元 泰介, 小方 孝：物語生成システムにおける物語言説機構に向けて, 認知科学, Vol. 20, No. 4, pp. 396–420 (2013)

[Akimoto 17] Akimoto, T.: Computational Modeling of Narrative Structure: A Hierarchical Graph Model for Multidimensional Narrative Structure, *International Journal of Computational Linguistics Research*, Vol. 8, No. 3, pp. 92–108 (2017)

[アリス 10] アリス ダイグナン著, 渡辺 秀樹, 大森 文子, 加野 まきみ, 小塚 良孝訳：コーパスを活用した認知言語学, 大修館書店 (2010)

[浅川 15] 浅川 伸一：ニューラルネットワーク物語生成モデル, 人工知能学会第 2 種研究会ことば工学研究会資料, Vol. 49, pp. 15–21 (2015)

[Fan 18] Fan, A., Lewis, M., and Dauphin, Y.: Hierarchical Neural Story Generation, in *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, pp. 889–898 (2018)

[福田 15] 福田 清人, 森 直樹, 松本 啓之亮：既存小説に依存しない小説の自動生成に関する一考察, 言語処理学会第 21 回年次大会発表論文集, pp. 992–995 (2015)

[Gervás 18] Gervás, P.: Storifying Observed Events: Could I Dress This Up as a Story?, in *Proceedings of the 5th AISB Symposium on Computational Creativity* (2018)

[Jain 17] Jain, P., Agrawal, P., Mishra, A., Sukhwani, M., Laha, A., and Sankaranarayanan, K.: Story Generation from Sequence of Independent Short Descriptions, *CoRR*, Vol. abs/1707.05501, (2017)

[Lakoff 93] Lakoff, G.: The Contemporary Theory of Metaphor, in Ortony, A. ed., *Metaphor and Thought (2nd edition)*, Cambridge University Press (1993)

[Martin 18] Martin, L. J., Ammanabrolu, P., Wang, X., Hancock, W., Singh, S., Harrison, B., and Riedl, M. O.: Event Representations for Automated Story Generation with Deep Neural Nets, in *Proceedings of the 2018 Conference of the Association for the Advancement of Artificial Intelligence (AAAI)* (2018)

[松尾 16] 松尾 豊：Deep Learning から身体性、シンボルグラウンディングへ, 人工知能学会全国大会発表論文集 1A5-OS-27c-2 (2016)

[松山 17] 松山 諒平, 佐藤 理史, 松崎 拓也：人狼ログからの小説の自動生成, 言語処理学会第 23 回年次大会発表論文集, pp. 32–35 (2017)

[松吉 18a] 松吉 俊, 内海 彰：メタファー写像に基づく物語文章の自動生成, 言語処理学会第 24 回年次大会発表論文集, pp. 1288–1291 (2018)

[松吉 18b] 松吉 俊, 内海 彰：メタファー写像と後編集を利用する物語文章生成フレームワーク, 人工知能学会全国大会 (第 32 回) 発表論文集, 2E2-01 (2018)

[Montfort 13] Montfort, N., Pérez y Pérez, R., Harrell, D., and Campana, A.: Slant: A Blackboard System to Generate Plot, Figuration, and Narrative Discourse Aspects of Stories, in *Proceedings of the International Conference on Computational Creativity (ICCC) 2013* (2013)

[鍋島 11] 鍋島 弘治朗：日本語のメタファー, くろしお出版 (2011)

[鍋島 16] 鍋島 弘治朗:メタファーと身体性, ひつじ書房 (2016)

[佐藤 16] 佐藤 理史：コンピュータが小説を書く日, 日本経済新聞出版社 (2016)

[鳥海 16] 鳥海 不二夫, 大澤 博隆：AI 達は物語を生み出すか, 人工知能学会全国大会発表論文集 2F4-5 (2016)

[人工知能学会 05] 人工知能学会 (編)：人工知能学事典, 共立出版 (2005)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

機械翻訳における訳語一貫性評価用データセットの構築

Construction of Coherent Translation Evaluation Dataset in Machine Translation

阿部 香央莉 *1 Kaori Abe　鈴木 潤 *1*2*3 Jun Suzuki　永田 昌明 *3 Masaaki Nagata　乾 健太郎 *1*2 Kentaro Inui

*1東北大学 Tohoku University　*2理化学研究所 AIP センター Center for Advanced Intelligence Project (AIP)

*3NTT コミュニケーション科学基礎研究所 NTT Communication Science Laboratories

This paper focuses on the topic of coherent translation in the document-level Neural Machine Translation (NMT). To evaluate NMT systems whether they can maintain consistent translations or not, we construct a dataset for evaluating the coherence. We evaluate typical baseline NMT systems on our dataset and discuss a coherent problem in terms of the term selection in the existing systems.

1. はじめに

2014 年に系列変換モデル (sequence-to-sequence model)[1] が提案されて以降，深層ニューラルネットを用いた機械翻訳（以降 NMT と呼ぶ）が盛んに研究されている．特に直近数年の技術発展はめざましく，注意機構 [2, 3]，サブワード [4]，逆翻訳による擬似データ作成 [5]，Transformer モデル [6] といった翻訳品質を大幅に向上させる革新的な方法論が次々に考案されている．これらの技術により，現在では非常に良好な翻訳結果が得られるようになりつつある．

しかし，これらの技術は，一文単位での翻訳を行う方法論としての研究成果である．よって，文章単位での翻訳を考えた場合に，文脈に依存した訳語選択，代名詞／ゼロ照応補完，訳語 *1 の一貫性といった，文章全体として自然な翻訳を実現するという観点では，まだ十分対応できているとは言えない．実際に，今年度開催予定の WMT2019*2 のシェアードタスクでは，文章単位の翻訳（Document-level MT）のデータが新たに追加される．また，文章単位，あるいは，連続する複数文を考慮して翻訳を行う方法論に関する研究成果も徐々に報告されるようになってきた [7, 8] このように，NMT の研究は，一文単位の翻訳から文章単位の翻訳へと研究の焦点が移動する転換期にさしかかっていると考えられる．このような背景から，本稿では，文章単位の翻訳を考えた際に解決すべき課題の一つとなる「訳語の一貫性」に焦点を当てる．

訳語の一貫性には様々なパターンが考えられる．例えば，表 1 中の例 1 のように，英語の文章における “our company” に対して，日本語では「我が社」「当社」「弊社」などの様々な訳語が許容できる場合がある．これは，書き手と読み手の関係性や状況などに応じて適切な訳語を使い分ける必要がある例である．また，表 1 中の例 2 では，日本語の文章中では「時計」と表現される対象について，英語では掛け時計を “clock”，腕時計を “watch” と呼び分けるため，文脈に応じて正しい訳語に統一する必要がある．これは言語間で，単語の内包する概念が一部異なるため，訳し分けが必要な例といえる．

一般論として，同一文章内で「同じもの（名詞・名詞句）」や「同じ行為（動詞・動詞句）」を指すとき,「同じ表現」であることが望ましい．特に，マニュアルや論文などの事実を読み手に正確に伝える必要のある文章では，同一文章内で同じものを異なる表現で表すと，読み手に同一のものを指していることが伝わらず，混乱を招く要因となり得る．よって，NMT の能力向上の一つとして，ある文章中で訳語の一貫性を考慮できる方法論の研究を推進したいと考える．しかし，現実的には訳語の一貫性の方法論の研究を行うには大きな課題が存在する．それは，現状の翻訳の評価用データが一貫性を評価できる作りになっていない点，および，BLEU 等の翻訳で使われる標準的な自動評価指標では，訳語の一貫性を正当に評価することが難しい点である．そこで本研究では，方法論作成の前段階として，まずは訳語の一貫性を評価できるデータセットを構築することに取り組む．

表 1: 一貫性がない翻訳の例

	例 1：日本語側に一貫性がない例
Japanese	我が社は赤字続きだ.
English	**Our company** has been in the red.
Japanese	当社は人材紹介会社である.
English	**Our company** is a staff agency.
Japanese	弊社の西側のオフィス
English	**our company**’s western office
	例 2：英語側に一貫性がない例
Japanese	いい時計ですね.
	この時計は父の形見なんです.
English	it’s a nice **clock**.
	this **watch** is a memento of my father.

表 2: 評価用データセットの統計値

	日英-英	日英-日	英日-英	英日-日
一貫性訳語種類数		31		125
行数		415		418
全語彙数	2947	2962	3137	2796
平均文長数（文字単位）	200.3	97.99	169.5	86.82
平均文長数（トークン単位）	36.93	41．03	28.84	34.29

2. NMT の学習・評価用データセット

2.1 現状

前述したように，NMT では，これまで一文単位で独立に翻訳を行う方法論が主流であったため，文章単位での訳語の一貫性に関しては考慮されてこなかった．そのため，NMT で用いられる学習および評価用データセットも，基本的に訳語の一貫性を評価するようには設計されていない．つまり，NMT で用いられる学習および評価用データセットでは,「同じもの・行為」を表すのが同じ表現で統一されているとは限らない．特に，NMT では，より多くの対訳データを用いるとより翻訳品質が高くなるという性質が観測されているため，基本的に様々な文章から対訳データを収集して学習用データとして用いている．

連絡先: 阿部　香央莉 (Kaori Abe)　東北大学大学院 情報科学研究科　乾・鈴木研究室
〒 980-8579 宮城県仙台市青葉区荒巻字青葉 6-6-05 東北大学工学研究科 電子情報システム・応物系 1 号館 6 階
E-mail: abe-k(at)ecei.tohoku.ac.jp
TEL: 022-795-7091

*1　ここでは「訳語」という用語を用いるが，一単語である場合だけでなく，複数の語の並び（句）の場合も含むこととする．

*2　http://www.statmt.org/wmt19/

よって，学習用データでは訳語の一貫性が担保されるような状況にはなっていないと容易に推測できる．よって，そのデータを用いて学習された NMT モデルでは訳語を統一することは基本的にはあまり考慮されていない．同様に，評価用データに関しても，複数の文章から収集してきたものを一つの評価データとして用いることが多いため，相対的に量は少なくても学習用データと同様に，ある語（または句）に対して複数の訳語が割り当てられている状況となっていることが多い．

2.2 訳語の一貫性評価の要件

本稿では，議論を明確にするために，以降は日英・英日翻訳に限定して議論を進める．

本研究では，前述のように複数の訳語が考えられる状況において，文章中で訳語が一貫しているかを評価できるデータセットの構築が目的である．その要件として，複数の訳語が考えられる翻訳元の語（または句）を訳語との対応付きで抽出し，抽出された語に対して同一の語（または句）に関しては，同じ訳語が割り当てられるかを評価することで訳語の一貫性の評価をすることを考える．例えば，“our company” に対して「我が社」「当社」「弊社」という 3 種類の訳語を含む文が存在する評価データがある場合，全ての “our company” に対して「我が社」「当社」「弊社」のいずれか一つを一貫して訳語として選択できたかで訳語の一貫性を評価する．この時，本研究では「我が社」「当社」「弊社」の 3 種類のどれを選んでも一貫性が保たれていれば正解とみなす．或いは，どれか一つの訳語を利用者が事前に決定し，その訳語を選択できたかを評価する方法でもよい．よって，例えば，対象とする訳語がきちんと翻訳文に出現したかの割合（正解率）で訳語の一貫性を評価することができる．或いは，より詳細に翻訳元の文と翻訳先の文で一貫性を担保したい語と訳語の語句対がきちんと対応がとれて翻訳されているかを評価することで，一貫性の評価を行うことができる．

よって，訳語一貫性評価用データセットとして，ある対訳データのある翻訳方向において，翻訳元の文のある語句の翻訳として十分に尤もらしい複数の翻訳先の訳語が存在するような語句対と文対を抽出する．つまり，訳語一貫性評価用データセットの構成要素は，1:対訳データ，2:翻訳方向，3:語句対（一つの語に複数の訳語を許容する），4: 文対 (入力文と参照訳) となる．このような要件を満たす評価用データの作成方法を次節で述べる．

3. データセット作成手順

本節では，訳語の一貫性を評価する評価用データセットの構築方法を述べる．図 1 にデータセット構築方法の概略を示す．まず，基本的な考え方として，データを最初から人手にて作成するのではなく，既存の評価用データセットを改変して訳語の一貫性を評価できるようにする．

訳語の一貫性を評価する評価用データセットを構築する概略は以下の通りである．

1. 単語アライメントから語句対の辞書取得
2. 語句対を自動或いは人手フィルタリングし，ある翻訳元の語から複数の訳語が存在する語句対を抽出
3. 元データセット中から，2 で抽出された語句対が含まれる文を抽出
4. 抽出された文に対し，自動・手動で 2 で抽出した語句対の訳語候補を人手で最終チェック

本研究では，日英翻訳の評価用データセットとして KFTT（京都翻訳フリータスク）コーパス [9][*3]，英日翻訳の評価用データセットとして ASPEC（Asian Scientific Paper Excerpt Corpus）[10][*4] を取り上げ，これらを基にして訳語の一貫性評価用データセットを構築する．表 2 に，作成した評価用データセットの統計値を示す．表 2 における一貫性訳語種類数と行数は，それぞれデータセットの対訳文中で訳語が統一されている語句対の種類数，データセット中における対訳文数を表す．また，その他の統計値として，各データセットにおける全語彙数，平均文長数をそれぞれ示す．

以下に，それぞれのデータセットの詳細な作成方法を述べる．

3.1 日英翻訳用データセット (KFTT)

KFTT は，京都関連の Wikipedia 記事から作成されたデータセットであり，日本の文化・歴史などが主に記述されている．このデータセット中には日本独自の概念（地名・人名などの固有名詞含む）が多く含まれているため，英語に翻訳する場合にその概念を表現する方法が異なる場合がある．例えば，固有名詞の日本語における読みをそのままローマ字で記述することもあれば，その名詞の概念そのものを英語で説明した句で置き換える例がみられる．具体的には，「源氏」という日本語が「genji」と「minamoto clan」という 2 通りの英語表現に訳されている．日本語話者にとって，この 2 つの英語表現が完全に同じ「源氏」という概念を表すことはほぼ自明であると思われるが，英語話者が日本の歴史を勉強しようとしてこの 2 文に遭遇した場合，これらは違うものではないかと疑問を抱く恐れがある．このように，KFTT は，前述の訳語の一貫性を考慮した評価用データを作成するのに適した要件を満たしている．

まず，前述の 1 の処理として，KFTT のチューニングセットに付加されている人手アライメントを利用し，語句対の辞書を取得する．次に，2 の処理として，一般的な頻出単語ではないが KFTT に頻出する単語を取得する．本研究では，OpenSubtitles[11][*5] という映画字幕コーパスの単語分布を一般的な頻出単語分布とみなし，「KFTT に出現するが Opensubtitles には出現しない単語」を抽出する．先ほどアライメントで得られた単語ペア辞書のうち，KFTT 頻出単語に該当する単語ペアのみを抽出する [*6]．3 の処理として，抽出された語句対が含まれる対訳文対を，元の KFTT のチューニングセットから抽出する．最後に 4 の処理として，人手で語句対と対訳文対の対応確認を行う．またその際に，対応する箇所を句単位に伸ばすことができる場合，手作業で句単位に拡張する．

3.2 英日翻訳用データセット (ASPEC)

ASPEC は，科学技術系論文から作成されたデータセットである．科学技術分野では，専門用語に相当する表現を日本語に訳す際，その訳語は翻訳者あるいは翻訳した時期によって変化することがあると考えられる．具体例として，「Faraday's law」の「Faraday」をそのままアルファベット表記で記述したり，カタカナに置き換えて記述したりする例が見られる．また，この「ファラデーの法則」自体が，元々は「電気分解の法則」と「電磁誘導の法則」の 2 種類を表す句であり，上記の例を厳密に記述する場合は「Faraday の電気分解の法則」と記述される場合もある．上記実例以外にも，訳語の一貫性がとれていない同様の状況が散見される．ASPEC も KFTT 同様に訳語の一貫性を評価するのに適した要件を満たしていると考えられる．

まず，ASPEC の評価データに対し GIZA++で自動アライメントを行い，単語ペア辞書を取得する．この時，GIZA++の学習は ASPEC の整理済み学習データを用いる．次に，得られた単語ペア辞書の中から「ASPEC 学習セット内では訳語の揺れがあるが，ASPEC 評価セット内では訳語がほぼ 1 つに定まる単語ペア」のみを抽出する．訳語揺れの基準は，出現頻度 3 回以上の訳し先が 3 つ以上ある場合とする．ここで ASPEC 評価セットの訳し先が複数ある場合には，アライメントが間違っていないことが判断でき，かつ最も高頻度な訳し先を人手で 1 つ選び単語ペアとして抽出する．抽出された単語ペアが含まれる対訳文対を ASPEC 評価セットから抽出し，人手で単語ペアと対訳文対の対応確認を行う．対応する箇所を句単位に伸ばすことができる場合，句単位に拡張する．また，文

*3 http://www.phontron.com/kftt/index-ja.html
*4 http://lotus.kuee.kyoto-u.ac.jp/ASPEC/
*5 http://opus.nlpl.eu/OpenSubtitles2018.php
*6 抽出の際，訳語が 2 種類以上 10 種類未満，訳語の 1 つが少なくとも 5 回以上出現している，複数の訳語の回数が異なっているといった制約を付加した．

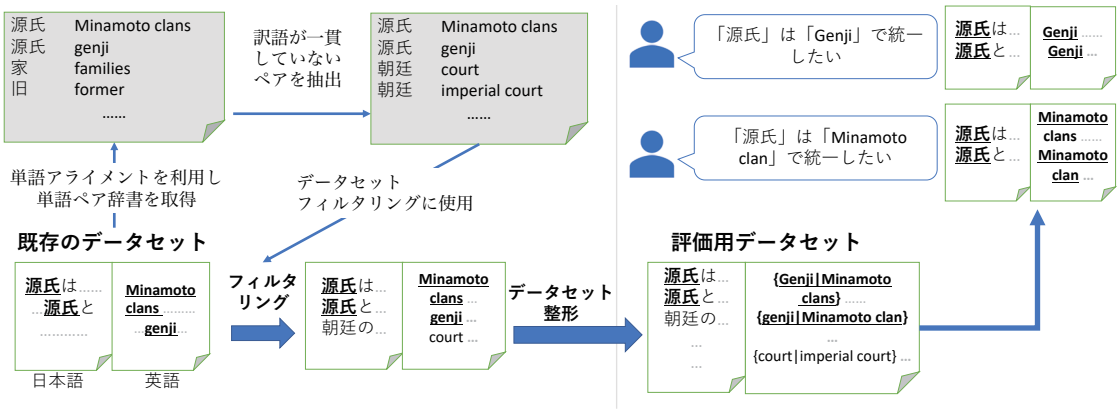


図 1: データセット構築手順（図中の例は KFTT のデータの例.）

表 3: 実験におけるハイパーパラメタ等の設定

前処理	BPE サブワード分割 [4]	8000 マージ
学習時	エポック数	13
	ミニバッチサイズ	64
	単語埋め込み次元数	512
	隠れ層次元数	512
	LSTM レイヤー数	2
	勾配正規化 (grad_norm)	5
	ドロップアウト率	0.3
	初期学習率	1.0
	学習率更新	9 エポック後から毎エポック 0.5 倍
デコード時	ビームサイズ	5

によって訳語が統一されていない場合は，統一する訳語を仮に 1 つ定め，訳語統一を行う．このような手順を経て最終的にできたものを，英日翻訳の評価用データとする．

4. 実験

4.1 実験設定

作成した評価用データセットを用いて，既存の NMT を評価する．本稿での実験の目的は，既存の NMT の翻訳結果が，訳語の一貫性の観点でどの程度妥当かを評価することである．

本研究の実験では，典型的な NMT モデルとして，これまでに広く用いられてきた文献 [12] で用いられている注意機構付き RNN 符号化復号化器を使用する．以下本手法を「ベースライン手法」と呼ぶ．また，訳語の一貫性を検証する上で有効な方法論となりえる制約付きデコーディング [13] も合わせて比較実験を行う．以下，本手法を「制約付きデコーディング手法」と呼ぶ．ただし，制約付きデコーディングに関しては，評価データ中の各文に対して一貫性のある訳語を制約として与えてデコーディングをする．つまり，訳語の一部が事前に与えられることに相当するため，通常の翻訳よりも有利な条件で翻訳していることになる．

翻訳モデル学習の際は，作成した評価用データに合わせて，英日翻訳モデルに対しては ASPEC，日英翻訳モデルに対しては KFTT の学習・開発セットを用いて学習を行った．本実験で用いた具体的なハイパーパラメタ等の設定を表 3 に記す．

評価指標には翻訳タスクにおいて一般的な自動評価尺度とされる BLEU を用いる．ただし，BLEU では「語彙の一貫性」を評価することはできない．そこで，BLEU 以外の評価指標として，暫定的に「訳語を統一した語句が出力文に含まれているどうか」を完全一致で判定し，含まれていれば正解としてその正解率を測る．

4.2 実験結果

表 4 に，日英および英日翻訳評価用データセットでの評価結果を示す．表中の一貫性訳語の出現率とは，翻訳先に一貫性の評価するための訳語が出現した場合に 1，しなかった場合に 0 とし，評価データ全体の出現率を計算した結果である．また，一貫性訳語の正解率とは，翻訳元の文と翻訳先の訳語の対応を求め，対応する翻訳元の単語の訳語となっている場合にのみ正解と考えた場合の正解率である．ただし，翻訳先と翻訳元の単語対応を求めるために TER[14] を用いた．

表 4: 評価用データセットにおける BLEU スコア

	BLEU		一貫性訳語の出現率		一貫性訳語の正解率	
	baseline	制約付き	baseline	制約付き	baseline	制約付き
KFTT	14.32	14.10	67.77	93.77	73.32	91.40
ASPEC	35.11	35.98	63.43	99.58	66.39	74.52

ベースライン手法と制約付きデコーディング手法を比較すると，日英翻訳 (KFTT) においては，ベースライン手法の方が制約付きモデルよりも BLEU スコアは高い．しかし，正解率の観点で見ると，ベースライン手法は 67.77 とだいぶ低い値となっている．先述のように，制約付きデコーディング手法では，一貫性に関する正解の訳語が与えられている状態で翻訳を行なっているため，本来 BLEU スコアも高くなって良いはずである．このように BLEU スコアが低くなる要因として，訳語の一貫性を強制するために，学習した翻訳モデルが破綻をきたし，一貫性に関連しない訳語の選択精度が劣化したことが考えられる．

また，英日翻訳 (ASPEC) においては．想定通り BLEU スコアも正解率も制約付きデコーディング手法が上回った．これは日英翻訳 (KFTT) と比較して，BLEU スコアが相対的にだいぶ高いため，一貫性の訳語を強制的に選択しても他の訳語選択の破綻が起きにくかったことに起因していると考えられる．ただし，この結果をもって制約付きデコーディング手法で訳語の一貫性の問題が解決したわけではない．今回の実験においては，一貫性の評価に用いられる訳語を事前に全て教えるという方法を用いているので，最も有利な状況での結果となっている．今後は，一貫性を評価する訳語も適切に選択する部分も含めて方法論を構築する必要がある．

ここで注意として，制約付きデコーディング手法では，訳語の一貫性ん評価対象の語の事前に与えているため理論上正解率は 100%になるはずである．本実験において，正解率が 100%になっていない理由として，訳語の一貫性を評価する対象の語が，学習データに出現しない未知語（厳密には未知 BPE サブワードを含む語）となるためである *7．

5. 考察

表 5 に，各手法による実際の翻訳例を示す．例 1 および例 2 では日英翻訳の例，例 3 および例 4 では英日翻訳の例をそれぞれ示している．

例 1 では，ベースライン手法のままでは,「南朝」を表す別の表現である “southern court” と翻訳されている．しかし，デコーディングで制約を付加したことにより，制約付きモデルではデータセット中で統一された訳語である “nancho” に正しく翻訳できている．しかし，例 2 においては，制約付きモデルは

*7 未知語以外の語に関しては，全て正解となっていることを確認した．

表 5: 実際の翻訳例

	例 1　一貫性訳語の種類 : (南朝, nancho)
入力文	また 南朝 最大 の 勢力 圏 で あ っ た 九州 に 今川 貞世 （ 了俊 ） ・ 大内 義弘 を 派遣 し て ， [**南朝**] 勢力 を 弱体 化 さ せ 幕府 権力 を 固め る ．
参照文	he also dispatched sadayo (ryoshun) imagawa and yoshihiro ouchi to kyushu , where [**nancho**] dominated , to debilitate its influence and consolidate the power of the bakufu . ”
baseline	in kyushu , he dispatched sadayo (ryoshun) and yoshihiro ouchi to kyushu , and strengthened the power of the **southern court** power . ”
制約付き	in kyushu , he dispatched sadayo (ryoshun) and yoshihiro ouchi to kyushu , and strengthened the power of the [**nancho**] power .
	例 2　一貫性訳語の種類 : (足利, ashikaga)
入力文	足利 尊氏 の 死 から 丁度 100 日 目 の こと で あ る ．
参照文	it fell precisely on the 100th day after the death of takauji [**ashikaga**] .
baseline	it was the 100th day after takauji [**ashikaga**] ’s death .
制約付き	[**ashikaga**] was the 100th day after takauji [**ashikaga**] ’s death .
	例 3 一貫性訳語の種類 : (標記, above)
入力文	”In the paper , an explanation is given on the [**above**] problem .”
参照文	本文 は [**標記**] 問題 の 解説 記事 で あ る 。
baseline	本稿 で は ， この 問題 に つ い て 解説 し た 。
制約付き	本稿 で は ， [**標記**] 問題 に つ い て 解説 し た 。
	例 4 一貫性訳語の種類 : (通信 事業 者, carrier)
入力文	”In the future of IP / IMS (IP multi - media subsystem) , the carrier networks remarkably convert .”
参照文	ＩＰ / ＩＭＳ (ＩＰ マルチメディア サブ システム) の 将来 に お い て ， [通信 事業 者] ネットワーク は 著し く 転換 する 。
baseline	ＩＰ / ＩＭＳ (ＩＰ マルチメディア サブ システム) の 将来 に お い て は ， キャリア ネットワーク が 著し く 転換 し て い る 。
制約付き	ＩＰ / ＩＭＳ (ＩＰ マルチメディア サブ システム) の 将来 に お い て は ， 通信 網 が 著し く 転換 し て い る 。

指定した訳語である “ashikaga” を過剰に出力してしまい，結果として意味が通らないような文を出力してしまっている．このエラーの理由としては，デコーディングの制約により強引に特定の単語を出力させたことで，本来は正しい出力を行うことができる言語モデルに悪影響を及ぼした可能性が高い．このように，単純な制約付きデコーディングを行うと，却って NMT が持つ翻訳能力を損なう場合があると考えられる．

例 3 では，制約付きデコーディングによって “above” に対応する「標記」という単語を正しく出力できている．このような例は英日翻訳では多く見られ，結果として BLEU スコアの向上に繋がったと考えられる．しかし，現状の制約付きデコーディングでは限界もある．例 4 では，デコーディングに制約を加えてもなお句である「通信事業者」が出現しなかった．これは,「通信事業者」という句が，学習データに出現しない未知語を含む句であるためである．このように，現状の NMT による方法では，完全に訳語の一貫性を保つことは難しいということが判明した．

6. おわりに

本稿では，文章単位の NMT を実現する上で課題の一つとなる「訳語の一貫性」に焦点を当て，訳語の一貫性を評価するための日英および英日翻訳評価用データセットを構築した．また，構築した評価用データセットを用いて，現状の典型的な NMT の手法を評価し，現状の翻訳器による出力の問題点を考察した．今後の課題としては，現状の NMT の翻訳品質を保ったまま，訳語の一貫性を実現する方法論を考案する．

参考文献

[1] Ilya Sutskever, Oriol Vinyals, and Quoc V Le. Sequence to sequence learning with neural networks. In Z. Ghahramani, M. Welling, C. Cortes, N. D. Lawrence, and K. Q. Weinberger, editors, *Advances in Neural Information Processing Systems 27*, pp. 3104–3112. Curran Associates, Inc., 2014.

[2] Dzmitry Bahdanau, Kyunghyun Cho, and Yoshua Bengio. Neural machine translation by jointly learning to align and translate. *arXiv e-prints*, Vol. abs/1409.0473, , September 2014.

[3] Thang Luong, Hieu Pham, and Christopher D. Manning. Effective approaches to attention-based neural machine translation. In *Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing*, pp. 1412–1421. Association for Computational Linguistics, 2015.

[4] Rico Sennrich, Barry Haddow, and Alexandra Birch. Neural Machine Translation of Rare Words with Subword Units. In *Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (ACL 2016)*, pp. 1715–1725, 2016.

[5] Sergey Edunov, Myle Ott, Michael Auli, and David Grangier. Understanding back-translation at scale. In *Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing*, pp. 489–500. Association for Computational Linguistics, 2018.

[6] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez, ￥L ukaszKaiser, Illia Polosukhin. Attention is all you need. In I. Guyon, U. V. Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, and R. Garnett, editors, *Advances in Neural Information Processing Systems 30*, pp. 5998–6008. Curran Associates, Inc., 2017.

[7] Rachel Bawden, Rico Sennrich, Alexandra Birch, and Barry Haddow. Evaluating discourse phenomena in neural machine translation. In *Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long Papers)*, pp. 1304–1313, New Orleans, Louisiana, June 2018. Association for Computational Linguistics.

[8] Jörg Tiedemann and Yves Scherrer. Neural machine translation with extended context. In *Proceedings of the Third Workshop on Discourse in Machine Translation*, pp. 82–92, Copenhagen, Denmark, September 2017. Association for Computational Linguistics.

[9] Graham Neubig. The Kyoto free translation task. http://www.phontron.com/kftt, 2011.

[10] Toshiaki Nakazawa, Manabu Yaguchi, Kiyotaka Uchimoto, Masao Utiyama, Eiichiro Sumita, Sadao Kurohashi, and Hitoshi Isahara. Aspec: Asian scientific paper excerpt corpus. In Nicoletta Calzolari (Conference Chair), Khalid Choukri, Thierry Declerck, Marko Grobelnik, Bente Maegaard, Joseph Mariani, Asuncion Moreno, Jan Odijk, and Stelios Piperidis, editors, *Proceedings of the Ninth International Conference on Language Resources and Evaluation (LREC 2016)*, pp. 2204–2208, Portoro, Slovenia, may 2016. European Language Resources Association (ELRA).

[11] Pierre Lison, Jörg Tiedemann, and Milen Kouylekov. Opensubtitles2018: Statistical rescoring of sentence alignments in large, noisy parallel corpora. In *Proceedings of the Eleventh International Conference on Language Resources and Evaluation (LREC-2018)*. European Language Resource Association, 2018.

[12] Thang Luong, Hieu Pham, and Christopher D. Manning. Effective approaches to attention-based neural machine translation. In *Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing*, pp. 1412–1421, Lisbon, Portugal, September 2015. Association for Computational Linguistics.

[13] Chris Hokamp and Qun Liu. Lexically constrained decoding for sequence generation using grid beam search. In *Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, pp. 1535–1546. Association for Computational Linguistics, 2017.

[14] Matthew Snover, Bonnie Dorr, Richard Schwartz, Linnea Micciulla, and John Makhoul. A study of translation edit rate with targeted human annotation. In *Proceedings of Association for Machine Translation in the Americas*, pp. 223–231, 2006.

General Session | General Session | [GS] J-10 Vision, speech

[2M5-J-10] Vision, speech: movement of bodies and objects

Chair:Eiki Ishidera Reviewer:Yoko Nishihara

Wed. Jun 5, 2019 5:20 PM - 7:00 PM Room M (Front-right room of 1F Exhibition hall)

[2M5-J-10-01] Improving object detection performance using objects' relative positions

○Yuichi Sasaki[1] (1. Fashion Pocket, Inc.)

5:20 PM - 5:40 PM

[2M5-J-10-02] Large-Scale Performance Evaluation Experiments on Name and Location Prediction of Spatial Concept Transfer Leaning Model

○Keishiro Taguchi[1], Kazuya Asada[1], Satoshi Ishibushi[1], Yoshinobu Hagiwara[1], Tadahiro Taniguchi[1] (1. Ritsumeikan University)

5:40 PM - 6:00 PM

[2M5-J-10-03] Evaluation of bidirectional method between motion and context for human motion recognition

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

6:00 PM - 6:20 PM

[2M5-J-10-04] A Study on Evaluation Model on Stroke Order Similarity

○Ryoske Fujii[1], Naoki Mori[1], Makoto Okada[1] (1. Graduate School of Engineering, Osaka Prefecture University)

6:20 PM - 6:40 PM

[2M5-J-10-05] Gesture Recognition by Multi-task Learning using Parallel Residual Adapters

○Noeru Suzuki[1], Kosuke Kikui[2], Yuta Itoh[3], Hisashi Kashima[1], Makoto Yamada[1] (1. Kyoto University, 2. Keio University, 3. Tokyo Institute of Technology)

6:40 PM - 7:00 PM

©The Japanese Society for Artificial Intelligence

相対的な位置関係を考慮した一般物体検出の改良

Improving object detection performance using objects' relative positions

佐々木雄一[*1]

[*1] ファッションポケット株式会社
Fashion Pocket Inc.

We introduce a new post-processing method to improve general deep-learning object detectors. In this method, a simple inference model is inserted just before Non-Maximum suppression to update the predicted confidence levels using objects' relative positions. We show it improves the robustness of detections by reviving the items missed by the object detectors.

1. はじめに

一般物体検出では、SSD[Liu 2016]や YOLO[Redmon 2017]などといった手法が広く用いられている。これら手法では Neural Network 部によって候補領域を提案し、その中から妥当性の高い領域を Non-Maximum Suppression (NMS)、および、しきい値処理といった後処理によって抽出し、最終的な検出結果を bounding box として得る。NMS は、単一対象に対して複数の候補領域が提案されるケースに対して、ルールに基づいた機械的な重複除去を実施する。しきい値処理は、信頼度 (confidence level) がしきい値以下の候補領域を落とすという簡潔なルールである。これらを組み合わせた後処理は、一般的に非常に良い性能を達成することが知られているものの、特定の用途においては、さらなる工夫の余地が見受けられる。特に、人間が写った写真から、複数のファッションアイテム (shoes、skirt、tops、等) を検出させるようなタスクの場合には、各アイテム相互の位置関係を踏まえたアルゴリズムを構築することにより、より頑健な物体検出を行うことが可能である。

例えば、図 1 のようなケースを考える。tops や outer、shoes は十分な confidence level にて認識をされており、明確に bounding box が提案をされている。一方で、pants の confidence level は低くなっており、しきい値処理の後に bounding box として提示されていない。結果として、tops、outer、shoes のみが検出され、pants を履いていないという結果が認識結果として提示される。しかしながらこれは常識的に考えてありえない組合せであり、人間が写真を判断する場合、tops と shoes に間に pants もしくは skirt があると推測した上で、その付近を積極的に検索し、confidence level が低い候補領域であっても、最終的な bounding box として提示するのが普通である。

本提案では、neural network 部が提案する候補領域群の相対的な位置関係を学習させることで、常識的に考えづらい不検出に対する頑健性を持つ後処理手法を提案する。この手法は、neural network 部と NMS の間に、小規模な機械学習モデルを導入し、候補領域の confidence level を修正することによって実装されるため、SSD や YOLO などの従来手法に対して簡便に精度向上の手段を提供する。

尚、SSD や YOLO などの neural network には、本来、物体間の相対位置を考慮する仕組みが獲得されている。しかしながら、それによる頑健性の程度は限定的で、しばしば不十分であり、前述のような常識的に考えてありえない組み合わせの bounding box が出力されることは多い。ここでは、その弱点を明示的に解決する手法を提案する。

連絡先：y_sasaki@fashionpocket.jp



図 1　本提案で解決を目指す問題の事例。tops や outer、shoes が検出されているにも関わらず、パンツが検出されていないといった常識的には考えづらい組み合わせが出力されている検出結果

2. 関連研究

SSD と YOLO などから提案される候補領域に対し、続く後処理の改善によって、全体の検出率を改善しようとする試みは多い[Rothe 2014, Mrowca 2015, Bodla 2017, Hosang 2017]。特に、[Hosang 2017] で提案されている GossipNet は、候補領域対に対して機械学習を適用し、相互の重複量・位置関係・カテゴリ種別などに基づき、confidence level を更新する手法を提案している。本提案も同様の考え方に基づいているものの、候補領域対に替わり、3 つの候補領域間の位置情報等に基づき confidence level を更新する手法を採用しており、より相対的な位置関係に感度の高い手法となっている。

機械学習モデルについては、小規模な neural network を用いる。この network 構造については、3 つの候補領域の情報の情報を入力として用いつつも、更に写真全体に渡る特徴量を捉えた分析を行うため、PointNet[X]で用いられた考え方を援用している。PointNet では、点群の情報を小規模な network により個別に要約した後に、全点群からの要約情報を MaxPooling に入れることで、点群全体の特徴を抽出している。それを再度点群情報に足し合わせて再度 Neural Network による処理を行うことで、全体の特徴を取り入れた分析を可能にしている。本提案においては、MaxPooling に代わり AvgPooling を用い、候補領域群全体から抽出した全体特徴量を、再度候補領域の要約情報に足し合わせることで、性能をさらに向上させている。

3. 提案手法

前述のように、本手法は 3 つの候補領域を組として入力する neural network モデルを核としている。以下では、3 つの候補領

域より入力バッチを構成する方法と、それを分析し新しい confidence level を出力する network 構造との 2 つに分けて説明を行う。

まず、入力バッチの構成について述べる。SSD や YOLO などにより提案された候補領域を、confidence level が高い順にソートし、そのうち上位 N_0 件を Box0 として選択する。各 Box0 に対し、それらの周囲に存在する候補領域を 2 つ選び、Box1, Box2 とする。この 2 つの候補領域は、confidence level が N_1 位までの間で、重複を許さないよう選定され、合計 N_1 $(N_1\text{-}1)/2$ 組が作られる。つまり、一枚の写真について、$N_0 \times N_1$ $(N_1\text{-}1)/2$ 個の組が準備される。最後に、それぞれの候補領域の組に対し、特徴量を計算する。この特徴量は、以下で挙げる数値を並べたものである:

- Box0, Box1, Box2 の confidence level
- Box0, Box1, Box2 の面積比
- Box0 に対する, Box1, Box2 の中心位置のユークリッド距離の比および、角度
- Box0, Box1, Box2 のカテゴリを示す one-hot vectors

上記で準備された入力ベクトルの次元数が k 次元、写真が N_p 枚ある場合、最終的に構築される要素の数は $N_p \times N_0 \times N_1$ $(N_1\text{-}1)/2 \times$ k 個となるが、これを、$[N_p \times N_0, N_1 (N_1\text{-}1)/2, k]$ へと形状変換し、$N_p \times N_0$ 件のバッチとして取り扱う。

他方、出力結果と比較される正解ラベルは、$[N_p \times N_0, 2]$の形状を持ったベクトルとする。2 次元目は、最終的な bounding box として残す/残さないに対応する one-hot vector であり、それを $N_p \times N_0$ 件の候補領域について準備する。

次いで、上記入力に対して学習・推論を行う network 構造について説明する。図 2 にあるように、network は 3 つの block を繰り返す構造としている。一つの block は、まず Box0, Box1, Box2 の情報から構成される k 次元の入力ベクトルを、kernel_size=1 の conv1d にて抽象化する。次いで、global average pooling を適用し、図中の他の Box1, Box2 の情報も含めて特徴量を抽出した後、full connect 層によって、入力と同じ k 次元に戻す。この k 次元情報の中には、Box0 を中心として、その周囲にある Box1, Box2 の情報も含めた全体的な特徴が抽出されている。最後に、その情報を、同じく k 次元の入力に加え合わせることによって、全体的な特徴を踏まえつつ、個別の Box0, Box1, Box2 に関する特徴量も保持した処理を可能としている。

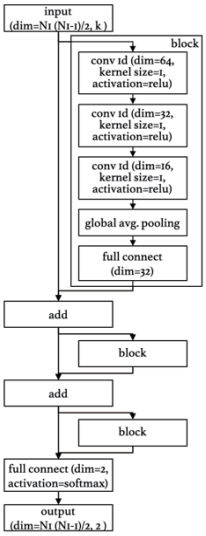


図 2　ネットワーク構造。"block"の構造は 3 回繰り返される。

上記を 1 つの block として、3block 分同様の処理を行った後、full connect 層および softmax にて、正解ラベルと比較される 2 次元の one-hot vector としている。推論の際には、このうちの片方を抽出し、更新された confidence level として扱う。

4. 実験

相対的な位置関係が重要となる問題設定として、今回は、写真の中からファッションアイテムを検出するタスクにおいて、本手法を評価する。

4.1 データ

本実験では、2 種類のデータを使用している。

一つは、独自に収集した画像に、ファッションアイテムの位置・カテゴリについてのアノテーションを行ったものである。基本的に日本人男女の全身写真となっており、日常の背景にて撮影されたものが大半を占める。カテゴリは、outer, tops, pants, skirt, onepiece, shoes, hat, bag の 8 種類とした。今回は、32k 件を母集団とし、8 割を学習用データ、1 割を学習の進捗監視とパラメータ最適化に利用し、1 割を定量評価用のデータとした。

二つ目は、DeepFashion データセット[Z. Liu 2016]であり、これは主に外国人の男女を対象とした全身写真である。本評価では、ここから抽出した数件の画像を用いて定性的な評価を行っている。

4.2 学習

Network は、SSD などが提示する候補領域を入力し、そのうちいずれを残す/残さないようにするかを推定させるよう学習させる。そのため、まず候補領域を準備する必要があり、別途ファッションアイテムの学習をさせた SSD において、NMS やしきい値処理を掛ける前の候補領域を抽出して用いる。

次いで、各候補領域に、最終的な bounding box として残すべきか否かを示す正解ラベルを準備する。これは、アノテーション結果の bounding box と最大の Intersection-over-Union (IoU)を示す候補領域を採ることによって行う。本来、confidence level に関わらず IoU 最大の候補領域を正解としてラベルを作成するべきであるが、本実験においては confidence level 順の上位 N_0 のみが学習に寄与するため、ある程度のしきい値を confidence level に対して要求し、それを満たす候補領域の中で IoU が最大になるものに限って正解ラベルを作成することとする。今回用いた学習データおよび SSD の場合、confidence level>0.05 の候補領域を対象とすることで、N_0=32 の中に、ほぼ 100%の正解ラベルを含めることができる。

Network は、一部候補領域の検出が上手くいかず confidence level が低くなっている場合にも頑健性を持つよう学習を行う。そのような状況を想定した下記のデータ水増しを適用し、データ量を 5 倍に増加させて学習を行う:

- 各画像において、confidence level 順で上位 1 位の候補領域の confidence level に対し、[0.3, 0.8]から乱択される係数を乗算する
- 上位 2 位の候補領域に対して同じ処理を行う
- 上位 3 位の候補領域に対して同じ処理を行う
- 上位 4 位の候補領域に対して同じ処理を行う
- 各画像において、confidence level 順で上位 1, 2, 3 位の候補領域の confidence level に対し、それぞれ [0.3, 0.8] から乱択される係数を乗算する

その他のパラメータについては、右の値を用いた: $N_0 = 32$, $N_1 = 5$, $k = 32$, NMS 後の confidence level しきい値 = 0.6。

Network の学習には Adam を使用した。学習の進捗監視データに対する loss の低減が十分に落ち着くまで約 700epochs 程度の学習を行い、以降の評価をしている。

4.3 評価

まず、mean Average Precision (mAP)による定量評価について述べる。図 3 に、各実験条件で得られた mAP の比較をまとめる。”SSD Output” (灰色) は、SSD から出力された候補領域に対して、通常の NMS およびしきい値処理を行った結果である。”SSD w/ Revive” (オレンジ) は、NMS の直前に本提案手法を挿入した場合を示す。mAP で 3.4%分の精度向上となっており、本提案手法にて狙う SSD の性能向上を実現している。それより下側に続く “Degraded 1st / 2nd / 3rd BB w/o Revive” (青) および、”Degraded 1st / 2nd / 3rd BB w/ Revive” (オレンジ) は、SSD が出力する候補領域の confidence level に 0.5 を乗算し、人工的に悪化させた場合と、それを本手法で回復させた場合の mAP を比較している。いずれの場合も悪化させた分の mAP 低下を回復させ、ほぼ”SSD w/ Revive”に匹敵する水準まで引き戻しており、SSD の不検出に対して頑健な性能を実現していることが分かる。

”SSD Original”と”SSD w/ Revive”を比較した際の、各カテゴリの AP 変化を図 4 にまとめた。特に、Shoes、Hat, Bag など、小さく隠れがちであり、SSD でも検出率が低くなりやすいアイテムに対して、大きく検出率が向上している。

図 5 に、DeepFashion の画像に対して本手法を適用した場合の定性的な結果を示す。DeepFashion は外国人のファッションが主な対象であり、SSD の学習を行った日本人を中心としたデータセットとはドメインを異にしているため、Pants などのアイテムについても SSD での検出が難しい場合がある (左列)。それらについても、本手法を適用することで回復されていることが分かる (右列)。

5. 結論

一般物体認識における後処理の一つとして、3 つの候補領域の相対的な位置関係を学習し、改善する手法を提案した。これは特に、ファッションアイテムの認識など、常識的な組み合わせがある程度固定されている条件で、mAP の向上に寄与することを示した。

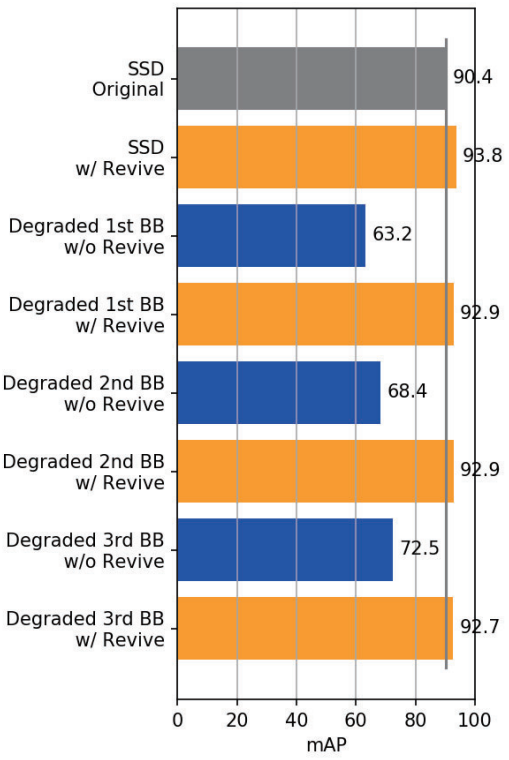


図 3　各実験条件で得られた mAP の比較。最上部 (SSD Original) が SSD の出力そのものでの mAP であり、その一つ下 (SSD w/ Revive) が提案手法を適用した場合。それより下側は、1, 2, 3 位の候補領域の confidence level を 0.5 倍することにより人工的に検出失敗を再現した場合の結果 (w/o Revive)と、提案手法を適用した場合の結果 (w/ Revive)。

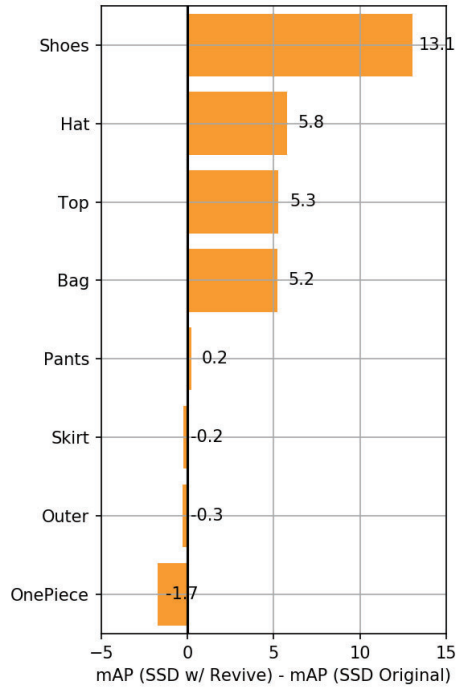


図 4　カテゴリ毎で見た時の、”SSD Original”と”SSD w/ Revive”における AP の差。

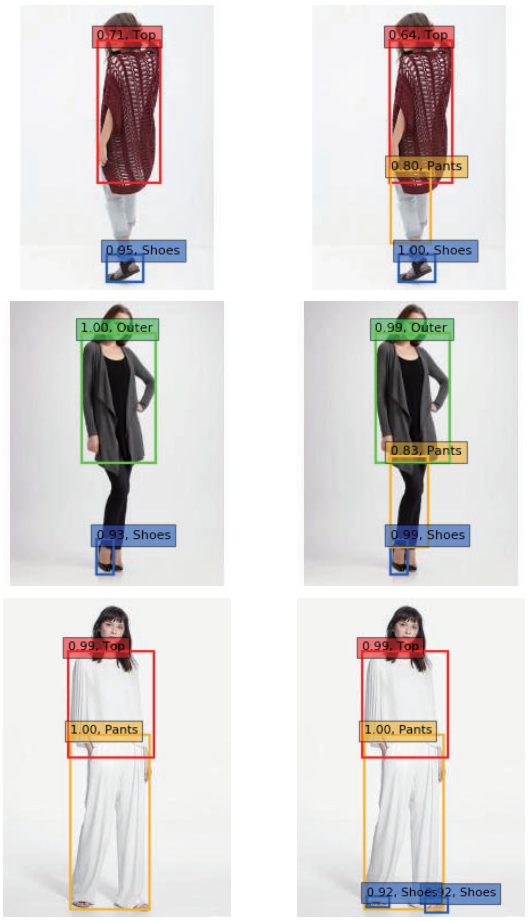


図 5　DeepFashion 画像に対して SSD を適用した結果 (左列)と、検出できなかった bounding box を、提案手法にて回復した例 (右列)

参考文献

[Liu 2016]　W. Liu, et.al., “SSD: Single Shot MultiBox Detector”, ECCV2016

[Redmon 2017]　J. Redmon and A. Farhadi, “YOLO9000: Better, Faster, Stronger”, CVPR2017

[Rothe 2014] R. Rothe, et.al., “Non-Maximum Suppression for Object Detection by Passing Messages between Windows”, ACCV2014

[Mrowca 2015] D. Mrowca, et.al., “Spatial Semantic Regularisation for Large Scale Object Detection”, ICCV2015

[Bodla 2017] N. Bodla, et.al., “Soft-NMS: Improving Object Detection With One Line of Code”, ICCV2017

[Hosang 2017] J. Hosang, et.al., “Learning non-maximum suppression”, CVPR2017

[Z. Liu 2016] Z. Liu, et.al., “DeepFashion: Powering Robust Clothes, CVPR2016

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

場所概念転移学習モデルの名前・位置予測における大規模性能評価実験

Large-Scale Performance Evaluation Experiments on Name and Location Prediction of Spatial Concept Transfer Learning Model

田口慶志郎 Keishiro Taguchi　浅田和弥 Kazuya Asada　石伏智 Satoshi Ishibushi　萩原良信 Yoshinobu Hagiwara　谷口忠大 Tadahiro Taniguchi

立命館大学
Ritsumeikan university

Spatial concept transfer learning model was first for the purpose of transferring the knowledge of places acquired in learning environments when the robot moves to new environments. However, in previous studies, this model has not proven to be effective for transferring the knowledge of places to new environments. Therefore, in this paper, we conduct large-scale performance evaluation experiments on name and localization prediction of this model in new environments and we verify whether this model is effective for transferring knowledge of places to a new environment. The experiment results on a larger scale showed that the model has a effectively a high prediction performance of name and location in new environments, and can indeed transfer the knowledge of prior places.

1. はじめに

新規環境で動作するロボットが予め一般的な場所の知識を保持していることで，ユーザはロボットにその場所に関する知識を少量与えるだけで良く，場所の名前を教示するといった負担を減らすことに繋がる．近年，サービスロボットや家庭内ロボットといった人と共同で生活するロボットの需要が高まっている．このようなロボットが人間からの「キッチンからお皿を持ってきて」というような指示を遂行するためには，キッチンという単語からキッチンを表す座標や空間を推定できることが必要である．

ロボットに場所の知識を獲得させる研究として，ナビゲーションの分野で場所の認識を行う手法 [Kostavelis 13] や場所の名前や場所の空間的領域を場所概念と捉え，ロボットに場所概念を形成させる手法 [Taniguchi 16] [Ishibushi 16a] が提案されている．これらの手法の問題点として，形成した場所概念を新規環境に転移することができず，環境が変わるごとにデータを観測し，改めて場所概念を形成する必要があり，学習面で非効率であることが挙げられる．そこで，石伏はある場所で形成した場所概念を新規環境における場所概念の形成に転移するモデルを提案した [Ishibushi 16b]．しかし，石伏の実験では実環境でロボットに場所概念を学習させているため，4 環境での転移学習にとどまっていた．そこで，浅田は仮想環境として SIGVerse [Inamura 10] を用いて，クラウド概念学習システムを構築した [Asada 16]．

そこで，本研究では，クラウド仮想環境を用いた場所概念転移学習モデルによる大規模な性能評価実験を場所の名前と位置の予測において実施する．図 1 は，本研究の概要図である．大規模な環境で形成した場所概念を新規環境に転移することで，ロボットは新規環境において観測情報から場所の名前を予測したり，人間から与えられた場所の名前からのその場所の位置を予測する．

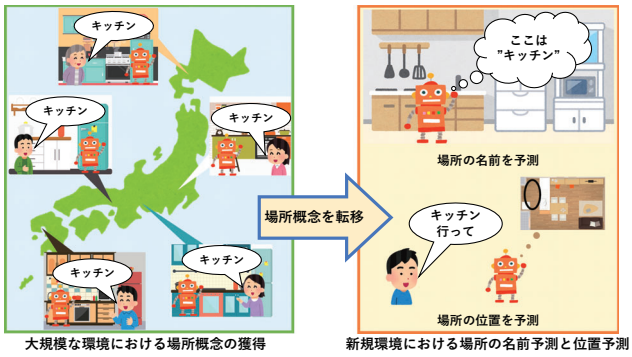


図 1: 本研究の概要図

2. 手法

2.1 場所概念転移学習モデルの概要

図 2 に場所概念転移学習モデルのグラフィカルモデルを，表 1 にグラフィカルモデルの各変数の定義を示す．このモデルは，ある環境でロボットが学習した場所概念を新規環境の学習に用いることができないことが学習面で非効率であり，ユーザが場所の名前などを最初から全て教示しなければならないという問題を解決するために提案されたものである．また，このモデルでは，学習環境と新規環境に共通したパラメータ ϕ^v, ϕ^n を有することで，新規環境に学習環境で形成した場所概念を転移することができる．

2.2 観測情報の取得

場所概念転移学習モデルは，観測情報として画像情報 v_t，場所の名前情報 n_t，自己位置情報 x_t を取得する．画像情報は，ロボットが取得した画像を Convolutional Neural Network のフレームワークの 1 つである Caffe [Jia 14] に入力し，Softmax 関数からの出力を 1000 次元の画像特徴ベクトルとして取得する．Caffe のパラメータは，事前に ImageNet Large Scale Visual Recognition Challenge 2012 のデータセットを使用し

連絡先: 田口慶志郎，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，taguchi.keishiro@em.ci.ritsumei.ac.jp

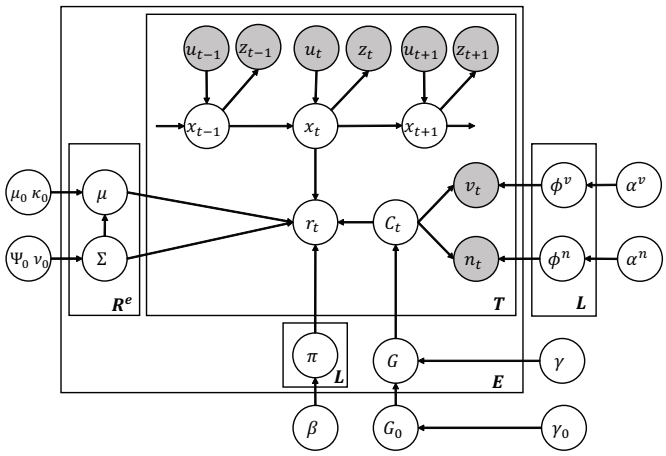


図 2: 場所概念転移学習モデルのグラフィカルモデル

て学習されている [*1]．場所の名前情報は，人間から与えられる場所に関する発話文に含まれる語彙を Bag-of-Feature として取得する．自己位置情報は，Monte Carlo Localization によって取得する．ただし，本実験では，クラウド仮想環境から取得されるオドメトリ情報から自己位置を推定した．

2.3 パラメータの推定

場所概念転移学習モデルにおけるパラメータ $r_t, C_t, \mu, \Sigma, \pi, G, \phi^v, \phi^n, G_0$ は，以下のようにギブスサンプリングによって推定する．このようなサンプリングを予め決められた回数だけ，イテレーションを行う．

$$r_t^e \sim p(r_t^e = k | x_t^e, C_t^e = l, \boldsymbol{\mu}^e, \boldsymbol{\Sigma}^e, \boldsymbol{\pi}^e) \tag{1}$$
$$\propto \mathcal{N}(x_t^e | \mu_k^e, \Sigma_k^e) \mathrm{Mult}(r_t^e = k | \pi_l^e) \tag{2}$$
$$C_t^e \sim p(C_t^e = l | x_t^e, v_t^e, n_t^e, r_t^e = k, \boldsymbol{\mu}^e, \boldsymbol{\Sigma}^e, \boldsymbol{\phi}^v, \boldsymbol{\phi}^n, G^e) \tag{3}$$
$$\propto \mathrm{Mult}(v_t^e | \phi_l^v) \mathrm{Mult}(n_t^e | \phi_l^n) \times \mathcal{N}(x_t^e | \mu_k^e, \Sigma_k^e) \mathrm{Mult}(C_t^e = l | G^e) \tag{4}$$
$$\mu_k^e, \Sigma_k^e \sim p(\mu_k^e, \Sigma_k^e | r_t^e = k, \boldsymbol{X}^e, \mu_0, \kappa_0, \Psi_0, \nu_0) \tag{5}$$
$$\propto \mathcal{NIW}(\mu_k^e, \Sigma_k^e | \mu_{n_k}, \kappa_{n_k}, \Psi_{n_k}, \nu_{n_k}) \tag{6}$$
$$\pi_l^e \sim p(\pi_l^e | \boldsymbol{r}^e, \boldsymbol{C_l^e}, \boldsymbol{X}^e, \boldsymbol{\mu}^e, \boldsymbol{\Sigma}^e, \beta) \tag{7}$$
$$\propto \mathrm{Dir}(\pi_l^e | \beta_{new}) \tag{8}$$
$$G^e \sim p(G^e | \boldsymbol{C}^e, G_0, \gamma) \tag{9}$$
$$\propto \mathrm{Dir}(G^e | \gamma_{new} G_0) \tag{10}$$
$$\phi_l^v \sim p(\phi_l^v | \boldsymbol{C_l}, \boldsymbol{V}, \alpha^v) \tag{11}$$
$$\propto \mathrm{Dir}(\phi_l^v | \alpha_{new}^v) \tag{12}$$
$$\phi_l^n \sim p(\phi_l^n | \boldsymbol{C_l}, \boldsymbol{N}, \alpha^n) \tag{13}$$
$$\propto \mathrm{Dir}(\phi_l^n | \alpha_{new}^n) \tag{14}$$
$$G_0 \sim p(G_0 | \boldsymbol{G}, \gamma, \gamma_0) \tag{15}$$
$$\propto \mathrm{Dir}(G_0 | \gamma_{0,new}) \tag{16}$$

*1 ILSVRC2012:http://www.image-net.org/challenges/LSVRC/2012/

表 1: グラフィカルモデルの各変数の定義

x_t	ロボットの自己位置
z_t	距離センサからの観測情報
u_t	制御情報
v_t	観測した画像情報
n_t	観測した場所の名前情報
r_t	位置分布のインデックス
C_t	場所概念のインデックス
μ, Σ	位置分布パラメータ (平均ベクトル，共分散行列)
ϕ^v	画像情報の多項分布のパラメータ
ϕ^n	場所の名前情報の多項分布のパラメータ
π	r_t の多項分布のパラメータ
G, G_0	C_t の多項分布のパラメータ
α^v	ϕ^v のディリクレ事前分布のハイパーパラメータ
α^n	ϕ^n のディリクレ事前分布のハイパーパラメータ
β	π のディリクレ事前分布のハイパーパラメータ
μ_0, κ_0 Ψ_0, ν_0	ガウス・逆ウィシャート分布のハイパーパラメータ
γ, γ_0	G のディリクレ事前分布のパラメータ
$\boldsymbol{R^e}$	環境 e における位置分布の数
$\boldsymbol{L}$	場所概念の数
$\boldsymbol{E}$	ロボットがデータを収集した環境の数
$\boldsymbol{T}$	各環境においてデータの収集を実施した数

ただし，$\boldsymbol{\mu}^e, \boldsymbol{\Sigma}^e, \boldsymbol{\pi}^e, \boldsymbol{X}^e, \boldsymbol{r}^e, \boldsymbol{C}^e$ は，それぞれ環境 e における $\mu, \Sigma, \pi, x_t, r_t, C_t$ の集合，$\boldsymbol{\phi}^v, \boldsymbol{\phi}^n, \boldsymbol{V}, \boldsymbol{N}, \boldsymbol{G}$ は，それぞれ $\phi^v, \phi^n, v_t, n_t, G$ の全体集合を表す．$\boldsymbol{C_l^e}$ は環境 e において，$\boldsymbol{C_l}$ は全環境において，$C_t = l$ となる C_t の集合を表す．$\mu_{n_k}, \kappa_{n_k}, \Psi_{n_k}, \nu_{n_k}, \beta_{new}, \gamma_{new}, \alpha_{new}^v, \alpha_{new}^n, \gamma_{0,new}$ は，それぞれ事後パラメータを表す．

3. 実験

複数のトレーニング用環境で収集されたマルチモーダル情報を用いて事前に場所概念を形成し，形成した場所概念をテスト用環境の場所概念形成に転移する．この時，テスト用環境では，ユーザからの名前の教示はデータに対して 0%から 21%しか与えられない．これにより，ユーザからの少ない教示のみでロボットが場所の名前や位置を予測する性能を評価する．

3.1 データ取得方法及びデータ取得環境

データの取得は，クラウド仮想環境である SIGVerse を用いて，ロボットを被験者が操作し，画像と自己位置の取得する．場所の名前は，テキストインプットにより与えた．

データの取得を行った環境としては，4 種類の間取り (1DK, 1LDK, 2LDK, 3LDK) を各 10 環境ずつ，合計 40 環境を準備した．各間取りにおいて，8 環境をトレーニング用，1 環境をバリデーション用，1 環境をテスト用とした．各環境では，形状やテクスチャが類似する物体が異なるレイアウトで配置されている．

3.2 場所概念の転移学習モデルの設定

画像情報と場所の名前情報のディリクレ事前分布のハイパーパラメータは $\alpha_v = 1, \alpha_n = 0.01$ とした．位置分布の事前分布であるガウス・逆ウィシャート分布のハイパーパラメータは $\kappa_0 = 0.03, \Psi_0 = \mathrm{diag}[0.05, 0.05, 5, 5], \nu_0 = 5$ とし，μ_0 は各環境の中心座標とした． 多項分布 G のディリクレ事前分布

のハイパーパラメータは $\gamma = 10, \gamma_0 = 10$ とした．多項分布 π のディリクレ事前分布のハイパーパラメータは $\beta = 0.06$ とした．画像情報と場所の名前情報のインクリメントパラメータは $S_v = 1, S_n = 5$ とした．ギブスサンプリングのイテレーションは 100 とした．

3.3 名前予測実験

3.3.1 実験目的

場所概念転移学習モデルがトレーニング用環境で形成した場所概念をもとに，テスト用環境において場所の名前の教示回数が少ない場合でも，自己位置と画像情報から概念を通して場所の名前を予測できるかを検証する．

3.3.2 実験条件

名前予測実験では，新規環境においてどの程度名前を付与することで有効に名前予測ができるのかを確認するため，テスト用環境の名前情報の付与率を 0%, 7%, 14%, 21%と変化させ学習を行う．各名前の付与率に対して，事前に 0 環境，2 環境，4 環境，8 環境，16 環境，32 環境のトレーニング環境で学習した場所概念転移学習モデルのほか，non-parametric Bayesian spatial concept aqiuisition method (SpCoA) [Taniguchi 16] を用いて名前予測結果の比較を行う．

3.3.3 名前の予測方法

テスト用環境 e において観測された画像情報 v_t^e と推定された自己位置情報 x_t^e から場所の名前情報 n_t^e を以下のように予測する．このとき，確率 $p(n_t^e|x_t^e, v_t^e)$ が最も高くなる名前を予測した名前とする．

$$p(n_t^e|x_t^e, v_t^e) \propto \Big\{\sum_{C_t^e} p(n_t^e|C_t^e)p(C_t^e|x_t^e, v_t^e)\Big\} \times I(n_t^e; C_t^e|\Theta) \tag{17}$$

$$\propto \Big\{\sum_{C_t^e} p(n_t^e|C_t^e)p(x_t^e, v_t^e|C_t^e)p(C_t^e|G^e)\Big\} \times I(n_t^e; C_t^e|\Theta) \tag{18}$$

$$= \Big\{\sum_{C_t^e}\sum_{r_t^e} p(n_t^e|C_t^e)p(v_t^e|C_t^e)p(C_t^e|G^e) \times p(x_t^e|r_t^e)p(r_t^e|C_t^e)\Big\} \times I(n_t^e; C_t^e|\Theta) \tag{19}$$

$$= \Big\{\sum_{C_t^e}\sum_{r_t^e} p(n_t^e|\phi^n_{C_t^e})p(v_t^e|\phi^v_{C_t^e})p(C_t^e|G^e) \times p(x_t^e|\mu_{r_t^e}, \Sigma_{r_t^e})p(r_t^e|\pi^e_{C_t^e})\Big\} \times I(n_t^e; C_t^e|\Theta) \tag{20}$$

ただし，$I(n_t^e; C_t^e|\Theta)$ は場所の名前と場所概念のインデックスの相互情報量を表し，Θ は学習されたパラメータの集合 $\Theta = \{\boldsymbol{\mu}^e, \boldsymbol{\Sigma}^e, \boldsymbol{\pi}^e, \boldsymbol{r}^e, G^e, \boldsymbol{\phi}^{\boldsymbol{v}}, \boldsymbol{\phi}^{\boldsymbol{n}}, G_0\}$ を表す．

3.3.4 評価方法

場所の名前の予測結果は κ 係数を用いて評価する．κ 係数は，-1 から 1 の範囲で値をとり，1 に近い値ほど予測した名前と正解ラベルの名前との一致度が高いことを示す評価指標である．Landis らが示した κ 係数の目安では，0 未満が不一致 (poor)，0 以上 0.2 未満がごく軽度の一致 (slight)，0.2 以上 0.4 未満が軽度の一致 (fair)，0.4 以上 0.6 未満が中程度の一致 (moderate)，0.6 以上 0.8 未満が高度の一致 (substantial)，0.8 以上がほぼ完全な一致 (almost perfect) となっている [Landis 77].

表 2: 名前予測の評価値の結果

	0%	7%	14%	21%
SpCoA	-0.03	0.19	0.30	0.29
転移学習モデル (0 環境)	0.02	0.39	0.39	0.51
転移学習モデル (2 環境)	0.65	0.61	0.70	0.71
転移学習モデル (4 環境)	0.77	0.72	0.74	0.78
転移学習モデル (8 環境)	0.76	0.79	0.71	0.81
転移学習モデル (16 環境)	0.83	0.86	0.88	0.85
転移学習モデル (32 環境)	**0.95**	**0.94**	**0.93**	**0.94**

$$\kappa = \frac{p_o - p_e}{1 - p_e} \tag{21}$$

$$p_o = \frac{c}{N} \tag{22}$$

$$p_e = \frac{1}{N^2}\sum_{k=1}^{N} n_k^{est} n_k^* \tag{23}$$

このとき，c は予測した場所の名前と正解ラベルの場所の名前が一致する数，N はテストデータの総数，n_k^{est} は予測した名前のうち名前辞書における k 番目の語彙と一致する数，n_k^* は正解ラベルの名前のうち名前辞書における k 番目の語彙と一致する数を表す．

4 種類の間取りのテスト用環境における κ 係数の平均値を名前予測の評価値とする．ここで，被験者がテストデータに対して付与した場所の名前を正解ラベルの名前とする．つまり，評価値が高いほどモデルが被験者に近い名前の予測ができている事を意味している．

3.3.5 結果

表 2 に名前予測の評価値の結果を示す．場所概念転移学習モデルは，全ての名前の付与率において既存手法である SpCoA より高い数値になった．また，場所概念転移学習モデルはトレーニング用環境の数が多いほど，各名前の付与率において高い数値になる傾向があることが確認された．

3.4 位置予測実験

3.4.1 実験目的

場所概念転移学習モデルがトレーニング用環境で形成した場所概念をもとに，テスト用環境において場所の名前の教示回数が少ない場合でも，場所の名前から概念を通して位置を予測できるかを検証する．

3.4.2 実験条件

位置予測実験では，名前予測実験と同様，テスト用環境の名前情報の付与率を 0%, 7%, 14%, 21%と変化させ学習を行う．各名前の付与率に対して，事前に 0 環境，2 環境，4 環境，8 環境，16 環境，32 環境のトレーニング環境で学習した場所概念転移学習モデルのほか，SpCoA を用いて位置予測結果の比較を行う．

3.4.3 位置の予測方法

テスト用環境 e において与えられた場所の名前 n_t^e から場所の位置 $x_t^{e,est}$ を以下のように予測する．予測する位置は場所の名前から予測された位置分布の中心座標 (平均ベクトル) と

表 3: 位置予測の評価値の結果

	0%	7%	14%	21%
SpCoA	4.33	4.43	3.76	3.07
転移学習モデル (0 環境)	4.26	2.62	3.32	2.75
転移学習モデル (2 環境)	2.31	2.05	1.59	1.70
転移学習モデル (4 環境)	2.07	1.27	1.99	1.47
転移学習モデル (8 環境)	1.41	1.78	2.07	1.56
転移学習モデル (16 環境)	1.29	1.79	**1.30**	**1.29**
転移学習モデル (32 環境)	**1.21**	**1.22**	1.43	1.49

する．

$$r_t^{e,est} = \underset{r_t^e}{\operatorname{argmax}}\, p(r_t^e|n_t^e) \tag{24}$$

$$= \underset{r_t^e}{\operatorname{argmax}} \sum_{C_t^e} p(r_t^e|C_t^e)p(C_t^e|n_t^e) \tag{25}$$

$$= \underset{r_t^e}{\operatorname{argmax}} \sum_{C_t^e} p(r_t^e|C_t^e)p(n_t^e|\phi_{C_t^e}^n)p(C_t^e|G^e) \tag{26}$$

$$= \underset{r_t^e}{\operatorname{argmax}} \sum_{C_t^e} p(r_t^e|\pi_{C_t^e})p(n_t^e|\phi_{C_t^e}^n)p(C_t^e|G^e) \tag{27}$$

$$x_t^{e,est} = \mu_{r_t^{e,est}}^e \tag{28}$$

3.4.4 評価方法

被験者が場所の名前を教示した位置を x_t^* として，その位置と推定した位置 $x_t^{e,est}$ との誤差を以下のように計算し，$cost_t$ と定義する．また，全てのテストデータの誤差の平均値を $cost^{ave}$ とし，評価値とする．評価値は低い数値であるほど，予測できていることを示す．

$$cost_t = \sqrt{(x_t^* - x_t^{e,est})^2 + (y_t^* - y_t^{e,est})^2} \tag{29}$$

$$cost^{ave} = \frac{1}{N}\sum_{t=1}^{N} cost_t \tag{30}$$

ただし，N はテストデータの総数を表す．

1DK, 1LDK のテスト用環境における $cost^{ave}$ の平均値を位置予測の評価値とする．このとき，2LDK, 3LDK のテスト用環境は同じ名前の場所が複数個存在するため評価の対象としない．位置予測の評価値が低いほど，モデルが被験者に近い場所の位置を予測できている事を意味している．

3.4.5 結果

表 3 に位置予測の評価値の結果を示す．場所概念転移学習モデルはトレーニング用環境の数が多いほど数値は低くなる傾向があり，既存手法である SpCoA よりも数値が低くなることが確認された．また，場所概念転移学習モデルは，データに対する名前の付与が行われない 0%の結果においても高い精度で位置の予測ができていることが確認された．

4. おわりに

本研究では，クラウド仮想環境を用いた場所概念転移学習モデルによる大規模な性能評価実験を場所の名前と位置の予測において実施した．

今回実施した名前予測実験及び位置予測実験より，大規模な環境で学習した場所概念転移学習モデルは名前の教示回数が少ない場合でも，既知の環境で形成された場所概念を新規環境に転移する事により，新規環境においてユーザの認識に近い場所の名前や位置が予測できることが示された．

今回実施した実験で用いたトレーニング用環境とテスト用環境では，類似した形状やテクスチャの物体が配置されていた．そのため，場所概念転移学習モデルを用いた場合，テスト用環境に場所概念の転移が行われやすく，名前予測や位置予測の性能が高かったと考えられる．今後の展望として，各環境に配置された物体の形状やテクスチャが異なる場合や複数の被験者を対象とした実験条件での評価や提案モデルの拡張を行っていく．

参考文献

[Kostavelis 13] Kostavelis, Ioannis, and Antonios Gasteratos. "Learning spatially semantic representations for cognitive robot navigation." Robotics and Autonomous Systems 61.12 (2013): 1460-1475.

[Taniguchi 16] Taniguchi, Akira, Tadahiro Taniguchi, and Tetsunari Inamura. "Spatial concept acquisition for a mobile robot that integrates self-localization and unsupervised word discovery from spoken sentences." IEEE Transactions on Cognitive and Developmental Systems 8.4 (2016): 285-297.

[Ishibushi 16a] Ishibushi, Satoshi, et al. "Statistical localization exploiting convolutional neural network for an autonomous vehicle." Industrial Electronics Society, IECON 2015-41st Annual Conference of the IEEE. IEEE, 2015.

[Ishibushi 16b] 石伏智．"Transfer Learning." https://youtu.be/bK77nOKYGW4. (2017)

[Inamura 10] Inamura, Tetsunari, et al. "Simulator platform that enables social interaction simulation—SIGVerse: SocioIntelliGenesis simulator." System Integration (SII), 2010 IEEE/SICE International Symposium on. IEEE, 2010.

[Asada 16] 浅田和弥，萩原良信，谷口忠大，稲邑哲也：「没入型インタフェースを伴うクラウド仮想環境における HRI に基づく場所の学習」インタラクション 2017 年 3 月，東京，2-501-10.

[Jia 14] Jia, Yangqing, et al. "Caffe: Convolutional architecture for fast feature embedding." Proceedings of the 22nd ACM international conference on Multimedia. ACM, 2014.

[Landis 77] Landis, J. Richard, and Gary G. Koch. "An application of hierarchical kappa-type statistics in the assessment of majority agreement among multiple observers." Biometrics (1977): 363-374.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

動作と文脈の双方向な認識手法における身体動作認識性能評価

Evaluation of bidirectional method between motion and context for human motion recognition

小椋 忠志 *1　稲邑 哲也 *1*2
Tadashi Ogura　Tetsunari Inamura

*1総合研究大学院大学
SOKENDAI(The Graduate University for Advanced Studies)

*2国立情報学研究所
National Institute of Informatics

It is generally difficult to recognize and distinguish human motion which are different kinds of motions but whose motion patterns are similar to each other. Conventionally, we have proposed a method of alternately performing two processes, motion recognition using context information and re-estimation of context based on recognition results. However, the performance evaluation of reasonable repetition times in these two recognition processes was not discussed. In addition, only an unrealistic ideal distribution is used as the motion appearance probability, and utility in the probability distribution including noise has not been discussed. In this paper, we aim to investigate these problems and clarify the conditions for performance improvement. Through experiments, a high motion recognition ratio was obtained when the number of iterations was 5 and 10. Furthermore, we confirmed that the proposed method maintains a high motion recognition ratio even if using noisy motion appearance probability. From these results, we have concluded that the proposed method has utility for practical motion patterns.

1. はじめに

「バイバイする」という動作と「窓を拭く」という動作は，身体動作のみに着目すると，どちらも手を振るという動作でとてもよく似ている．動作のみに着目した認識手法ではこのようなよく似た動作を区別することが難しく誤認識の要因となる．実際に人が人を観測している際には，それまでの観測情報から文脈を考慮出来るため，これらの動作を誤認識することは考えにくい．例えば,「窓を拭く」という動作の観測の前に,「机を拭く」「床を掃く」という動作を観測できたのであれば，観測者は「掃除」をしているという観測対象者の動作のカテゴリを推測することが出来る．本稿では，この動作のカテゴリを文脈と呼び，文脈を活用した動作認識手法について述べる．

生活支援ロボットのような人とのコミュニケーションが求められる場面では，人とロボットで共有可能な概念となる文脈が求められる．Recurrent Neural Network(RNN) に基づく動作認識手法 [Du 15] は，コンテクスト層を所持しているものの，その内部状態の可読性が低くコミュニケーションのための文脈情報の抽出は難しい．Attamimi らは，動作を含む複数のモダリティを用いたカテゴリ分類手法を提案している [Attamimi 14]．提案されているカテゴリ分類は人とのコミュニケーションに適したものであるが，カテゴリや文脈そのものの時間的関係性は考慮されていない．そのため，動作認識に用いるための文脈は，その時々に応じて適切に観測情報から推定することが求められる．

本研究は，似ている動作への誤認識を低減することを目的として次のような手法を提案する．冒頭の「掃除」のような可読性のある文脈情報と，パターン認識手法を組み合わせて動作を認識する．また，動作の認識結果に基づいて，現在の文脈情報を更新する．そして，この 2 つのプロセスが双方向に繰り返し実行される．この動作と文脈の双方向な認識手法によって，時系列な観測データに対してその時々に応じた文脈情報を活用し，似た動作への誤認識低減を実現する．

連絡先: 小椋忠志，総合研究大学院大学，東京都千代田区一ツ橋 2-1-2，t-ogura@nii.ac.jp

本研究におけるこれまでの研究成果 [Ogura 18] では，双方向な認識における繰り返し処理において，最適な繰り返し回数など詳細なアルゴリズムの性能評価について議論がされていなかった．また，文脈情報として動作の観測を予測する動作出現確率 (Motion Appearance Probability Distribution; 以下 MAPD) について，ノイズの少ない理想的な分布のみを用いており，ノイズを含む確率分布における有用性についても議論されていなかった．そこで本稿では，これらの点を調査し，性能向上のための条件を明らかにすることを目的とする．適切な繰り返し回数は何回であるか，よりノイズの多い MAPD を用いた場合でも認識性能を保つことができるか，という 2 点について実験を通して評価する．

2. 文脈と動作の双方向推定手法の概要

提案する手法は大きく分けて 2 つの処理によって構成される．一つ目は文脈を用いた動作認識で，二つ目は動作認識結果に基づく文脈の推定である．手法のより詳しい説明は文献 [Ogura 18] に示されているため，ここでは手法の概要について簡単に述べる．

2.1 文脈を用いた動作認識

提案手法の処理手順の概要を図 1に示す．文脈情報は日常生活における動作のカテゴリを対象に，図 1右上のように確率分布として扱われる．文脈の確率分布は図 1中央のように離散的に取り扱われる．時刻 τ の時の動作パターン $\boldsymbol{o}_\tau$ が観測されたとき，HMM によって認識尤度 $P(\boldsymbol{o}_\tau|\lambda_i)$ が求められる．ここで，HMM である λ_i は動作 m_i に対応する．離散の粒 k が所属する文脈 j を q_k とすると，離散の粒 k における認識処理の際に用いられる文脈情報としての MAPD は $P(m_i|j = q_k)$ である．HMM による認識尤度 $P(\boldsymbol{o}_\tau|\lambda_i)$ と現在の文脈に基づく MAPD$P(m_i|j = q_k)$ を組み合わせる処理 [Ogura 18] によって，文脈を用いた動作認識を実現する．

2.2 動作認識結果に基づく文脈の推定

動作の認識結果は，2.1節の離散的処理によって，図 1の下部のように離散分布として得られる．離散の粒 k の認識結果

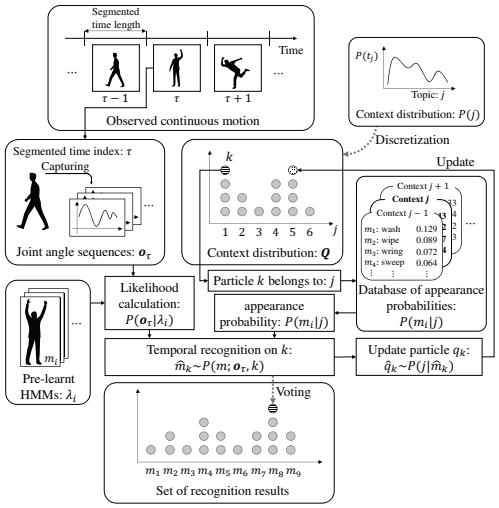


図 1: 文脈情報を用いた動作認識と文脈分布の更新手順

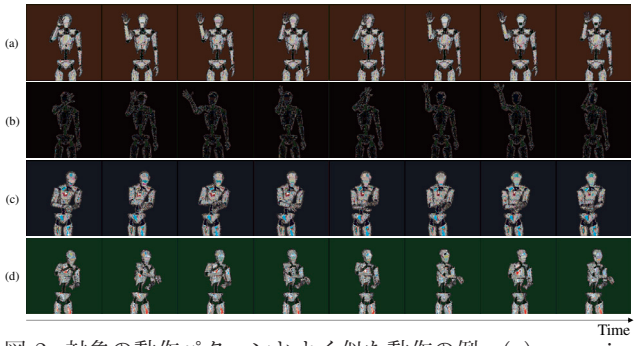


図 2: 対象の動作パターンとよく似た動作の例．(a) m_6: wiping window．(b) m_{33}: waving hand．(c) m_8: washing．(d) m_{13}: frying with pan．(a) と (b) の動作，(c) と (d) の動作はそれぞれよく似ており，誤認識を引き起こしやすい．

を $\hat{m}_k$ とする．k が次に所属する文脈 j を $\hat{q}_k$ とすると，$\hat{q}_k$ を得るための確率分布 $P(j|\hat{m}_k)$ を，ベイズの定理に基づいて次のように求める．

$$P(j|\hat{m}_k) = \frac{P(\hat{m}_k|j)P(j)}{P(\hat{m}_k)} \tag{1}$$

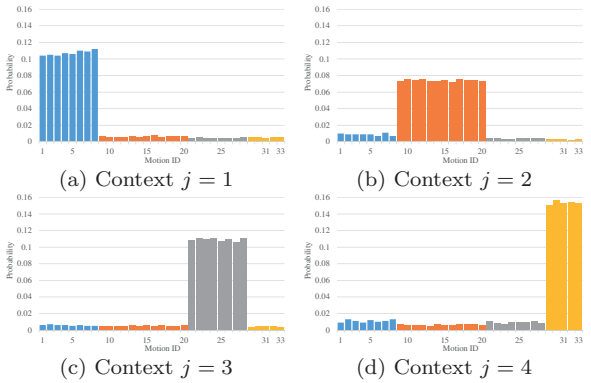
ここで，$P(\hat{m}_k|j)$ は MAPD$P(m = \hat{m}_k|j)$ によって得られ，同様に $P(\hat{m}_k)$ は MAPD を参照し j についての周辺化によって得られる．また本稿では，$P(j)$ には図 1の左上部に示されるような，一時刻前の時刻 $\tau - 1$ の時の文脈の確率分布を用いる．

2.1節における文脈を用いた動作認識と本節の動作認識結果に基づく文脈の推定は，1 つの時刻において複数回繰り返し実行される．

3. 評価実験

3.1 対象のデータ

ここでは 2 つの実験に共通する対象のデータについて述べる．4 種類の文脈に所属する合計 33 種類の日常動作を用意した [Ogura 18]．図 2に実際にキャプチャした動作パターンを示す．対象の動作の中では図 2(a) と図 2(b) の様によく似た身体動作を含んでいる．観測の身体動作が対象とする関節角は，



(a) Context $j = 1$　(b) Context $j = 2$

(c) Context $j = 3$　(d) Context $j = 4$

図 3: 実験に用いる文脈 j ごとの動作出現確率 $P(m_i|j)$

頭・両肩・両手首の各 3 次元と，肘・全指の各 1 次元の，合計 27 次元である．各動作は 60[Hz] でキャプチャされ，約 4 秒間の長さとする．Left-to-right モデルの HMM を用い，状態数は 16，GMM の混合数は 5 で学習を行った．

図 3に本実験に用いる MAPD を示す．今回の実験では，$P(m_i|j)$ の値は手動で与えた．図 3を見て分かるように，ある文脈はそのカテゴリに属する動作を出力する確率が高く，異なるカテゴリに属する動作はほとんど出力しない．この実験では，文脈の数 J は 4，離散の粒の数 K は 400 で，文脈の確率分布は一様分布を初期状態とした．

3.2 比較手法

この実験では提案手法を含む 4 つの手法を用いて実施した．

(i) Only HMM

この手法は HMM のみによる認識手法であり，すなわち文脈情報を用いない手法である．この手法による認識結果の動作インデックスを i_{hmm} とすると，その i_{hmm} は次のように計算される．

$$i_{hmm} = \arg\max_i P(\boldsymbol{o}_\tau|\lambda_i) \tag{2}$$

(ii) With N-grams

この手法は，N-grams から得られる次のラベルを推測する確率値を認識に用いる．N-grams は，単語の前後関係を確率で表現したモデルで，文章の文脈を考慮する手法であるといえる．一方で，HMM による尤度と組み合わせるためには工夫が必要となる．そのため，HMM による尤度と次の動作の確率値を統合するスコア $S_{ngram}(\boldsymbol{o}_\tau, i)$ を次式のように定義する．

$$\begin{aligned} S_{ngram}(\boldsymbol{o}_\tau, i) = \exp\{&\alpha\left(\log P(\boldsymbol{o}_\tau|\lambda_i) - C\right) \\ &+ \log P(m_i^\tau|\hat{m_i}^{\tau-1}, \cdots, \hat{m_i}^{\tau-N+1})\} \end{aligned} \tag{3}$$

ここで，$\hat{m_i}^{\tau-1}, \cdots, \hat{m_i}^{\tau-N+1}$ は 1 時刻前から $N-1$ 時刻前までの動作の認識結果であり，N は N-grams の学習の対象となる単語の連結数である．また，$P(m_i^\tau|\hat{m_i}^{\tau-1}, \cdots, \hat{m_i}^{\tau-N+1})$ は $\hat{m_i}^{\tau-1}, \cdots, \hat{m_i}^{\tau-N+1}$ の情報から次の動作が m_i^τ となる確率を示したもので，これは N-grams によって得ることが出来る．この手法による認識結果の動作インデックス i_{ngram} は次式のように計算を行う．

$$i_{ngram} = \arg\max_i S_{ngram}(\boldsymbol{o}_\tau, i) \tag{4}$$

表 1: シーケンスデータ A に対する各手法による認識率

	Recognition Ratio				
(i)	0.66116				
			2-gram	3-gram	4-gram
(ii)			0.70110	0.63499	0.55647
	Recognition Ratio on Repeat Cycles				
	once	2 cycles	3 cycles	5 cycles	10 cycles
(iii)	0.66942	0.66942	0.66529	0.67493	0.66116
(iv)	0.61846	0.69697	0.70661	**0.72727**	0.71488

(iii) Not sequential
この手法では，提案する手法のうち，文脈の確率分布を毎時刻一様分布にリセットする．とある時刻の入力情報に対して，上位と下位のループ処理を実行するものの，認識そのものはその時刻で独立しており，次の時刻へ継承しないものとなる．この手法を用いる理由は，時系列を考慮しない手法と比較する目的のためである．

(iv) Our method
提案する手法である．

3.3 2 種類のシーケンスデータに対する実験

3.3.1 2 種類のシーケンスデータについて

この実験では，2 種類のシーケンスデータを認識の対象とする．ここで，シーケンスデータとは複数の動作を繋ぎ合わせた連続動作のことを示す．1 つのシーケンスデータの中では動作だけでなく文脈も次々に変化している．具体的には次の 2 種類である．

シーケンスデータ A
シーケンスデータ A における 1 系列のデータは，動作ラベル m_1 から m_{33} まで順番に動作を繋げたものである．このシーケンスデータを 22 種類用意し，認識の対象に用いる．シーケンスデータ A は，22 種類のデータにおいて動作の順番が固定されている条件となっている．シーケンスデータ A の目的は，22 種類のデータに対する認識結果を比較し，文脈の分布の変化の追従性の評価を行う点にある．またこのシーケンスデータは，1 系列が 33 動作なのに対して 4 種類の文脈が次々に変化していくため，文脈の切り替わりが早いという特徴がある．

シーケンスデータ B
このシーケンスデータは動作の順番が固定されていないデータであり，1 つの系列に約 200 動作が含まれている．1 つの系列の中では 9 回文脈が切り替わり，文脈に従った動作が順番に実行される．この実験では合計 10 種類のシーケンスデータが用意されている．シーケンスデータ B は，動作の順番が固定でなく，そして文脈の切り替わりが比較的緩やかであり，先のシーケンスデータ A と比べてより実践的なテストデータであることを示している．

この 2 種類のシーケンスデータを対象として，手法ごとに動作の認識を行った．

3.3.2 シーケンスデータ A に対する実験結果

すべての手法による認識率を表 1に示す．(iii) と (iv) の手法は，上下層において双方向の認識処理を持つ認識手法であるため，双方向の認識処理の繰り返し回数による認識率の違いについても検討を行う．ループ構造の繰り返し回数を，1，2，3，5，10 回と変更して実施した．また，N-gram に基づく手法 (ii) では，2-gram，3-gram，4-gram の 3 種類を対象とした．表 1を見ると，最も高い認識率を出した手法は，繰り返し回数 5 回での手法 (iv) である．22 種類のシーケンスデータの平均の認識率の比較では，提案手法が他の手法よりも優れていることが示された．

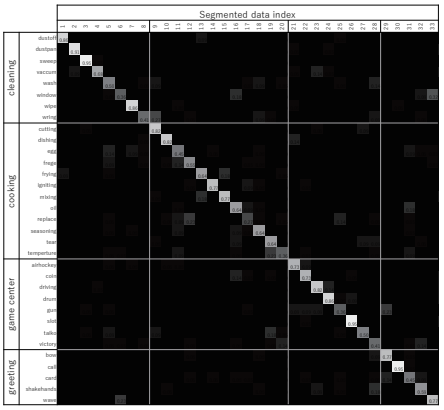


図 4: 手法 (i) による認識結果の混同行列

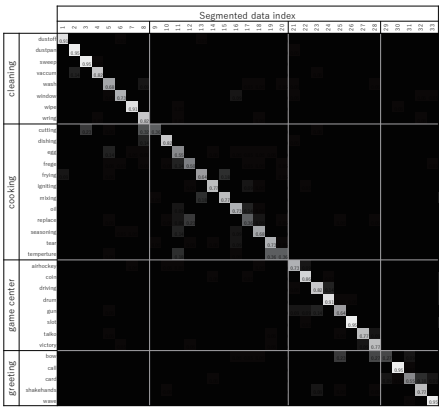


図 5: 手法 (iv) による認識結果の混同行列

図 4に手法 (i) による認識結果の混同行列を示す．縦軸は動作ラベルで，横軸はシーケンスデータを動作ごとに区切ったのち，区切られた動作の時系列順序のインデックスを示す．この混同行列は 22 種類のシーケンスデータを対象にした認識結果を，割合と濃度で示したものである．用意されたシーケンスデータは動作 m_1 から m_{33} まで順番に実施されているため，正しい認識結果を示した場合，図の左上から右下まで対角線上に白くなる．図 4の認識率の低い箇所を見ていくと，「wiping the window」の動作 m_6 の多くが「bye-bye」の動作 m_{33} として誤認識されていることがわかる．図 2の (a) と (b) を見てもわかるようにこれらの動作はよく似ている．

図 5には，ループ構造の繰り返し回数 5 回の手法 (iv) による認識の混同行列を示す．手法 (i) の誤認識が確認された動作 m_6 と動作 m_{33} に注目すると誤認識は減少している．この誤認識が減少した理由は，これまでの観測情報から現在の文脈を正しく推測し，その文脈情報を用いて認識率が向上したからである．

22 種類のシーケンスデータに対する文脈の分布の平均と標準偏差を図 6に示す．横軸は分割された動作のインデックスで，縦軸は離散の粒の数である．また，網掛けの色は対象の動作が所属する文脈を示し，線の色と網掛けの色は対応している．平均の値をみると，おおよそ正しい文脈の推定が行われていることがわかる．一方で，動作のインデックス 9 番を見ると，文脈 $j = 2$ の動作であるのに対し文脈 $j = 1$ の離散の粒の数のほうが多くなっている．この原因は，これまでの観測情報から文脈 $j = 1$ の方が確率が高いためである．そのため，図 5の文脈が切り替わる直後に認識率が低下している．

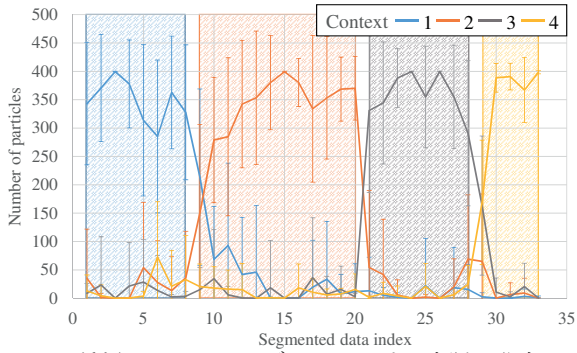
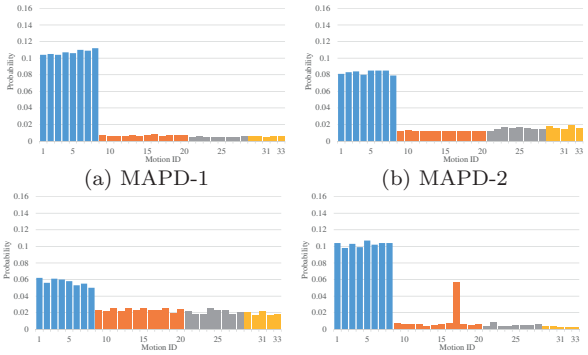


図 6: 22 種類のシーケンスデータにおける文脈の分布の平均と標準偏差の推移



(a) MAPD-1 (b) MAPD-2

(c) MAPD-3 (d) MAPD-4

図 7: 文脈 $j = 1$ の時における動作出現確率 MAPD-1，MAPD-2，MAPD-3，MAPD-4

3.3.3 シーケンスデータ B に対する実験結果

次に，シーケンスデータ B に対する認識結果を表 2に示す．手法 (i) による認識率は先の実験結果による認識率と大きくは変わらない．提案手法では，繰り返し回数 10 回においてすべての手法の中で最も高い認識率を得た．

2 種類のシーケンスデータを対象にした実験では，A，B それぞれ繰り返し回数 5，10 回の時に最も高い認識率を得た．繰り返し回数 5 回と 10 回での認識率の違いは大きくはないが，この繰り返し回数の差は，文脈が切り替わる頻度に関係性があると考察する．

3.4 動作出現確率の検討のための実験

図 3の MAPD は，対象の文脈に所属する動作とそれ以外の動作における確率がある程度はっきりとわかるくらいに差のある，いわゆる理想に近いデータであると言える．そこで，MAPD にノイズが多い場合の提案手法のパフォーマンスを評価する．

3.3節での 2 種類のシーケンスデータに対する実験に用いた MAPD を MAPD-1 と呼び，新たに MAPD-2，MAPD-3，MAPD-4 を追加した．4 つの MAPD のうち文脈 $j = 1$ の MAPD を比較したものを，図 7に示す．MAPD-2 と MAPD-3 を見てわかるようにこれらは MAPD-1 の出現確率と比較して，文脈に属する動作の確率が低く，異なる文脈に属する動作の確率が高くなっている．MAPD-4 による文脈 $j = 1$ の MAPD を図 7(d) に示す．MAPD-4 は，MAPD-1 に対して他の文脈の動作の確率が一部高くなってしまっているような，分布である．

表 3に，手法 (iv) による，各 MAPD に対する認識率を示す．いずれの結果においても，手法 (i) と比較して高い認識率を保っていることがわかる．単純なシーケンスに対する認識率は，MAPD の変化に伴い，やや低くなっている．一方で，実践的なシーケンスデータに対する認識率は，すべての MAPD において，高い認識率を保っている．

表 2: シーケンスデータ B に対する各手法による認識率

	Recognition Ratio				
(i)	0.67350				
		2-gram	3-gram	4-gram	
(ii)		0.75300	0.76100	0.65150	
	Recognition Ratio on Repeat Cycles				
	once	2 cycles	3 cycles	5 cycles	10 cycles
(iv)	0.63450	0.76550	0.75850	0.75800	**0.76600**

表 3: 手法 (iv) による MAPD を変化させた際の認識率

	MAPD-1	MAPD-2	MAPD-3	MAPD-4
Sequence A	0.72727	0.67906	0.68182	0.67080
Sequence B	0.75800	0.75250	0.72350	0.77100

4. おわりに

本稿では，提案する文脈と動作の双方向な認識手法を評価するため，2 つの実験を行った．2 種類のシーケンスデータを対象にした実験では，急激な文脈を変化を含むデータを対象にした際には繰り返し回数 5 回，文脈の変化が緩やかなデータの際には繰り返し回数 10 回の時に，最も高い認識率を得た．また，同条件で実施した他の手法と比較して，提案する手法が優れた手法であることを示した．MAPD の検討のための実験では，よりノイズの多い MAPD をを用いた場合においても，高い認識率を保つことを示した．これらの結果から，提案手法は理想的な条件ではない，実践的な動作パターンを対象とした場合でも，有用性が確保されるという結論を得た．

本稿では，文脈と動作の双方向な認識手法の有効性を示した対象は動作パターンのみだったが，この考え方は他の認識対象においても十分適用可能であると考える．例えば，動作の文脈を用いることで，観測対象者が持つ道具の認識性能を高めることが可能である．また，所持する道具情報を用いることで，動作の認識を見直すことが可能となる．今後は，このような動作パターン以外への拡張に取り組む．

謝辞

本研究は，JST，CREST（グラント番号 JPMJCR15E3）の支援を受けたものである．

参考文献

[Du 15] Du, Y., Wang, W., and Wang, L.: Hierarchical recurrent neural network for skeleton based action recognition, IEEE Computer Society Conference on Computer Vision and Pattern Recognition, pp.1110–1118, (2015).

[Attamimi 14] Attamimi, M., Fadlil, M., Abe, K., Nakamura, T., Funakoshi, K., and Nagai, T.: Integration of various concepts and grounding of word meanings using multi-layered multimodal LDA for sentence generation, IEEE/RSJ International Conference on Intelligent Robots and Systems, pp. 2194–2201, (2014).

[Ogura 18] 小椋 忠志, 稲邑 哲也: 長時間動作の文脈と身体動作の相互認識, 2018 年度 人工知能学会全国大会（第 32 回）, 1O1-03, (2018).

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

筆順の類似度に関する評価モデルに対する考察

A Study on Evaluation Model on Stroke Order Similarity

藤井 涼佑 *1　森 直樹 *1　岡田 真 *1
Ryosuke Fujii　Naoki Mori　Makoto Okada

*1大阪府立大学工学研究科
Graduate School of Engineering, Osaka Prefecture University

Since sketch is one of the most important creation by human, analysis of sketch drawing process by artificial intelligence is the essential topic. In this paper, we consider a computational model to evaluate the similarity of stroke order. We have proposed CASOOK in order to realize communication between computers and humans. In this research, we are trying to develop CASOOK-SR which is extended CASOOK adopting sketch-rnn. Since evaluating stroke order similarity is a difficult problem, and there was only a method to evaluate the similarity of stroke order by persons. In this paper, we define an objective comparable evaluation function on the similarity of stroke order. In our experiment, the correlation coefficient between the function and the similarity evaluation values by a person were 0.344 and 0.446. It is found that our calculation model is the same as human evaluation when an image made from a stroke order matrix is similar to another.

1. はじめに

近年，機械学習の発展を背景とした人工知能 (Artificial Intelligence : AI) が注目を浴びている．AI は単純なパターン認識では人間の能力を凌駕する性能を示すが，一方で，人間の情緒や感性に関する分野への AI の適用, 特に創作物への適用はいまだ困難である．創作物の中でも，スケッチは，年齢，国籍，文化にかかわらず，幅広く共感可能な表現であるため重要度が高い．このため，感性を取り扱う分野での重要な AI の課題の 1 つとされてきた [Eitz 12]．著者らはこれまで計算機と人間とのコミュニケーションを実現するため，Creative Animating Sketchbook（CASOOK） [Ueno 15] を提案してきた．従来の研究において，CASOOK は筆順の情報を持たない静止画像のみを対象していたが，CASOOK の拡張として筆順を扱うために，深層学習モデルである sketch-rnn [Ha 17] を導入した Creative Animating Sketchbook with sketch-rnn (CASOOK-SR) を提案している．この手法では，筆順の決定プロセスが潜在意識下にあるという観点から，最終画像と同程度に人間の感性が筆順に含まれていることに着目している．また CASOOK-SR を実問題に適用するため，探し絵を自動生成するモジュールとして VSAPS を提案してきた．

しかしながら，過去の研究から生成された筆順を定量的に評価するために必要な類似性の比較は困難な課題の 1 つであり，人によって筆順の類似性を直接評価するしかなかった．そのため，本稿では，筆順の類似性に関する客観的で比較可能な評価モデルを定義し，その有効性を 2 種類の実験によって確認し，創作物としてのスケッチを人工知能で用いることの重要性を示す．

2. 要素技術

2.1 CASOOK

児童を対象としたユーザからのスケッチを入力として，スケッチに込められた感性情報を解析し，感性に合わせたアニメーションを付与するシステムとなっている．

連絡先: 藤井 涼佑，大阪府立大学，fujii@ss.cs.osakafu-u.ac.jp

2.2 CASOOK-SR

従来の CASOOK はユーザの入力したスケッチを画像情報のみで解析していた．これを拡張するために，CASOOK-SR では深層学習モデルである sketch-rnn を利用することで筆順情報と画像情報を解析し，筆順方法を活用した上で感性に合わせたマシンインタフェースが実現可能なシステムを目指す．

2.3 Sketch-rnn

sketch-rnn とは，人間がイラストを描くときの一連の描き順を学習することでユーザのイラストを補完，推測する深層学習を利用したモデルである．図 1 に sketch-rnn の学習モデルを構成する Variational Autoencoder (VAE) [Pu 17] を示す．入力はスケッチの時系列を含む筆順行列であり，潜在ベクトルがエンコーダの中間出力となる．また，最終出力は画像を生成可能とする筆順行列となる．

2.3.1 温度パラメータ τ について

sketch-rnn のパラメータである温度 τ は潜在空間の多様性に関して調整をする．温度 τ が 0 の場合出力は決定的，つまり，単一の特徴を強く反映した出力になる．

2.4 VSAPS

静止画像のみを扱う CASOOK に対して，筆順を導入する CASOOK-SR のコアモジュールとして探し絵に適用した Visual Search Automotive Production System (VSAPS) を提案した．VSAPS には大きな特徴が 2 つ存在する．1 つ目はユーザと計算機が対話できる構造を持っていることである．ユーザが描いたスケッチを元に探し絵の問題を作成後，ユーザは自分の描いたスケッチを VSAPS による類似画像の中から選択し，VSAPS がその正誤判定を確認する．2 つ目の特徴は筆順ベクトルを扱うことによって，静止画像の問題形式だけでなく，筆順を再現する動画の問題形式をユーザに提供できることである．画像生成を畳み込みニューラルネットワーク (Convolutional Neural Network : CNN) [Simard 03] ベースの VAE ではなく，再帰型ニューラルネットワーク (Recurrent Neural Network : RNN) [Jain 99] ベースの sketch-rnn を使用することで VSAPS は時系列データの学習が可能できる．

図 2 に VSAPS の画面の配置を示す．左側の部分にユーザが描いたスケッチを表示し，右側に探し絵の問題の選択肢を表

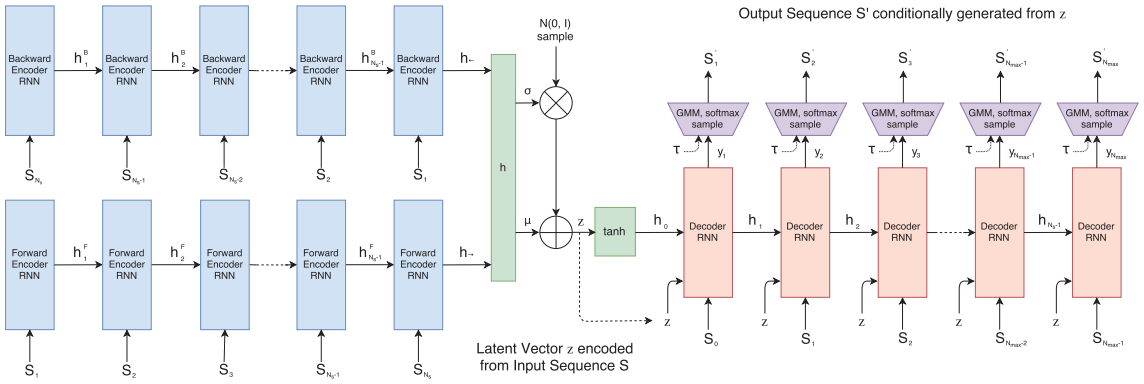


図 1: sketch-rnn モデル図

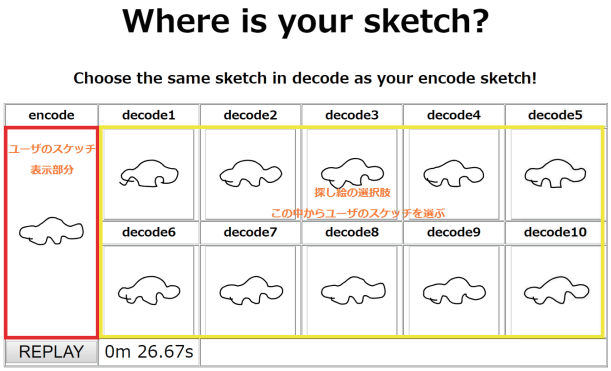


図 2: VSAPS 画面構成

示する．ユーザは右側の選択肢から正解を選ぶことをゲームの趣旨とする．

3. 提案手法

3.1 評価モデル

(1) 式に本稿で提案する指標を示す．ただし，U，V は 1 枚のスケッチの筆順を含む行列で，それぞれのサイズは $t_U \times 3$，$t_V \times 3$ であり，t_U や t_V は各スケッチの時間長を示し，3 は sketch-rnn がもつペンの状態ベクトルのサイズを示す．sketch-rnn では，ペンの x 座標とペンの y 座標，ペンの上下運動の有無を示す Bool 値をもつ．また，K は任意の時間をもち，$0 < K \leq \min(l_U, l_V)$ を満たす値である．ここで，l_U はスケッチの筆順行列 U の時間長を，l_V はスケッチの筆順行列 V の時間長を示す．したがって，ある時刻までの筆順の総和である筆順ベクトルのコサイン類似度 [Singhal 01] の時間軸方向に対する平均値として定義する．

$$\mathrm{S}(U,V) = \frac{1}{K}\sum_{k=1}^{K} \frac{(\sum_{i=1}^{k} \boldsymbol{U}_i)\cdot(\sum_{i=1}^{k} \boldsymbol{V}_i)}{(||\sum_{i=1}^{k} \boldsymbol{U}_i||)(||\sum_{i=1}^{k} \boldsymbol{V}_i||)} \qquad (1)$$

4. 実験

4.1 目的

筆順の類似性を測る指標として，従来研究で使用されてきた人間の主観による定性的評価の代替となる，(1) 式の有効性を確認する．4.2 節では大きく異なる 2 つの筆順間での評価を扱う．4.3 節では VSAPS を用いることで，似ている多数の筆順間での評価を扱う．

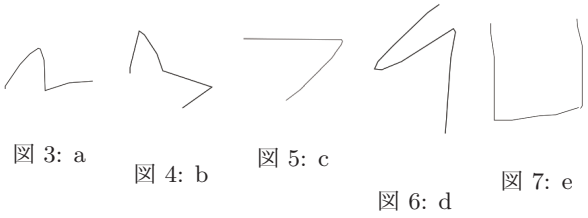


図 3: a　図 4: b　図 5: c　図 6: d　図 7: e

4.2 2 組の筆順の比較

4.2.1 手順

(1) 式で表される評価モデルが，2 つの筆順間の類似性に関する人間の主観的評価との相関を調べる．テストデータから選んだ 10 枚の画像を描き始め・中盤・描き終わりの 3 段階，つまり 30 種類の画像を，5 人の実験協力者に筆順の類似性に関して「非常に似ている」,「似ている」,「異なる」,「非常に異なる」の 4 段階で評価してもらう．5 人の評価を平均した値と (1) 式の値に関して相関係数を求めて，提案する指標の信頼度を確認する．尚，相関係数を計算するとき，実験協力者が評価する 4 段階について，「非常に似ている」は 4 に，「似ている」は 3 に，「異なる」は 2 に，「非常に異なる」は 1 に変換する．

図 3 ～ 7 に評価対象のスケッチの一例を示す．実験においては画像の比較ではなく，スケッチの筆順をアニメーションで再現したものを比較する．

4.2.2 結果

図 8 に人の評価値と (1) 式で表される評価モデルでえられる評価値の散布図を示す．図より，評価モデルが負の値を取るデータ 12 件はすべて人の主観的評価も非常に低いことがわかる．また，人の評価値が 2.5 以上で評価モデルの評価値が 0 以上であったデータは 19 件あった．

これらのデータを用いて相関係数を計算したところ，0.344 が得られた．したがって，人の評価と評価モデルは弱い正の相関があることを確認した．

4.2.3 考察

正の相関ではなく，弱い正の相関になった要因について考察する．主な原因は筆順行列の類似性と画像の形の類似性の関係性にあると考えている．

特に顕著な現象として，評価モデルによる評価値は高くなる傾向がある一方で，人の評価は低くなる傾向がある点であげ

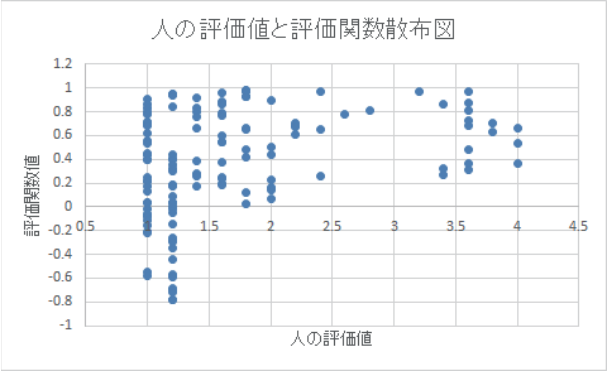


図 8: 人の評価と評価モデルの散布図

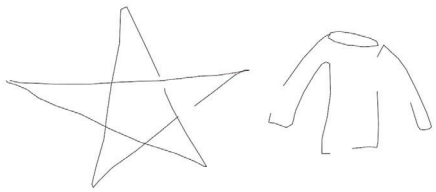


図 9: 実際に使用した画像ペア

られる．評価モデルにおいて，正の値は 135 件中 108 件あった．反対に人の評価において，2.5 以上は 135 件中 19 件であった．これらの現象は，評価モデルでは類似性の加点が多すぎることに起因すると考える．

これを確認するため，図 8 において左上のデータ，つまり，人の評価は低い一方で，評価モデルの値が高い画像のペアを示す．この画像ペアの評価モデルの値は 0.86 であった．一方で，人の評価値は 1.0 であり，「非常に異なる」をすべての実験協力者が回答していた．このデータから，筆順に関するコサイン類似度が高いにもかかわらず，全くの別画像の画像ペアの存在が確認された．

図 10 に図 9 における筆順の同時刻帯のベクトルの比較を示す．図 10 より，同時刻帯のベクトルの向きは図中の 1 ～ 7 番において一致していることがわかる．したがって，最終画像としてみた場合，2 つのスケッチが異なる一方で，筆順データとしてみた場合，類似性の高いスケッチが得られることもあると考えられる．

一方で，図 8 より，評価モデルの値が小さいすべてのデータは人の評価値も低いことが示された．したがって，評価モデルの値が小さければ人の評価は低いことがいえる．このため，提案した評価モデルは 2 の筆順の類似性が極端に低いケースには有効であると考えられる．

4.3 VSAPS を使った比較

4.3.1 手順

次に，VSAPS を使い，自動生成された筆順を使った探し絵の選択肢における類似性の評価をする．

4.3 節の実験では，4.2 節の実験で使用したデータと異なり，比較対象の筆順が非常に高い類似性をもつ．探し絵の類似度は，ユーザの入力した筆順と VSAPS が生成した筆順に対して (1) 式を適用した値を 9 組求め，それらの平均値とした．また，画像の類似具合を変更するパラメータとして，2.3 節で述べた τ の値を変動させた．

図 11 に τ が大きい，つまり，最終画像が非決定的な出力

表 1: VSAPS における類似性の主観的評価と客観的評価

画像 No.	主観的評価	客観的評価
1	2	0.8811
2	1	0.7270
3	1	0.9240
4	1	0.9517
5	3	0.9534
6	1	0.8996
7	1	0.8212
8	3	0.8385
9	1	0.8460
10	4	0.9810

において，評価モデルの値が小さい例を示す．また，図 12 に τ が小さい，つまり，最終画像が決定的な出力において，評価モデルの値が大きい例を示す．ただし，類似性の評価モデルの平均値はおよそ 0.80～0.99 の範囲の値を取った．図 11 より，正解である decode 9 以外の選択肢の筆順はいずれも丸みを帯びているため，人間の主観的にも類似性が低いといえる．一方で，図 12 では decode 4 ～ 10 の選択肢はほとんど区別がつかないほど類似性が高いことが確認される．これらの結果を裏付けるように，図 11 では，評価モデルの平均値は約 0.84 を示し，図 12 では，評価モデルの平均値は約 0.96 を示している．以上から， 評価モデルの評価値と VSAPS の難易度は一定の相関があると推測される．これを前提として，探し絵の類似度を変更した場合，人による類似性評価と探し絵の類似度にどの程度相関があるか確認する．

このため，実験協力者に用意済みの探し絵を解いてもらい，探し絵の選択肢における類似性についてのアンケートを回答してもらった．評価項目には「非常に似ている」,「似ている」,「異なる」,「非常に異なる」の 4 つを準備した．ただし，4.3 章では類似性が高い中で，どれぐらい異なるかを見ており， 4.2 章の評価項目とは全く異なる評価スケールである．

4.3.2 結果

表 1 に 1 人の実験協力者のアンケート結果と評価モデルの値を示す．ただし，主観的評価が実験協力者の回答結果を指し, 客観的評価が評価モデルの値を指す. また，主観的評価は,「非常に似ている」は 4 に,「似ている」は 3 に,「異なる」は 2 に,「非常に異なる」は 1 に変換した値となっている．主観的評価と客観的評価の相関係数は 0.446 を示した．したがって，主観的評価と客観的評価に正の相関があることを確認できた．

4.3.3 考察

主観的評価と客観的評価の相関係数は 0.4463 であった．したがって，VSAPS によって生成された筆順行列から構成される最終画像が類似している場合，(1) 式が与える評価値は非常に妥当性のあるモデルであると考えられる．

5. まとめと今後の課題

本稿では，筆順の類似性を測る客観的な指標を作るため，(1) 式の評価値と実験協力者による筆順の評価を比較した．データセットのテストデータからランダムに選んだ筆順の比較をした 4.2 節では，弱い正の相関がある 0.344 という相関係数を実験で確認した．VSAPS で自動生成した類似性の高い筆順同士の比較をした 4.3 節では，正の相関がある 0.446 という相関係数を実験で確認した．したがって，画像特徴における類似性の

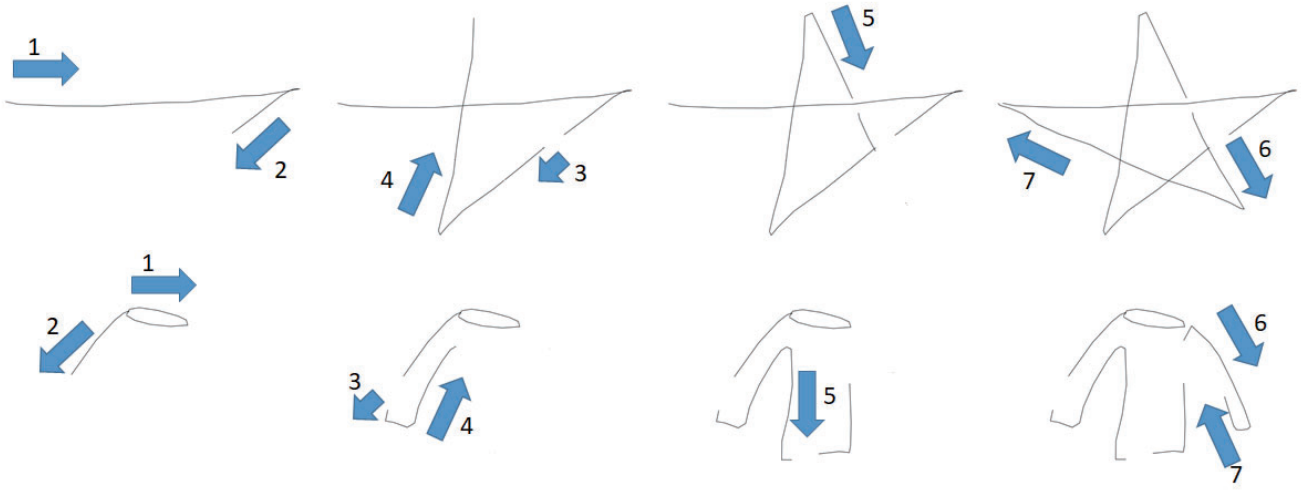


図 10: 筆順の部分ベクトル比較

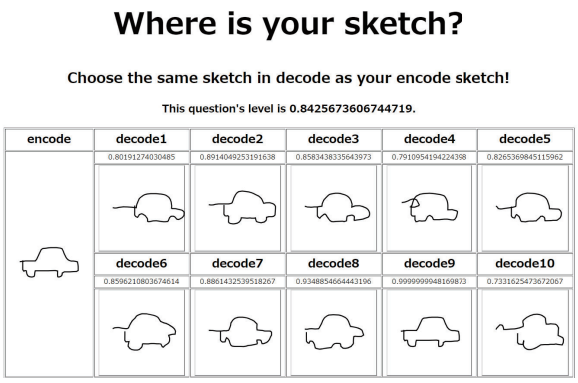


図 11: 評価モデルの値が小さい例

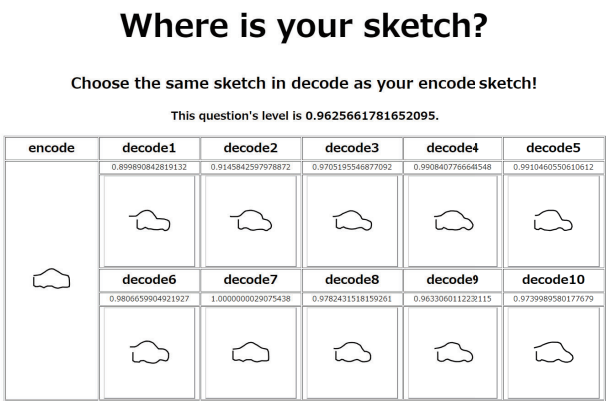


図 12: 評価モデルの値が大きい例

高い画像ペアの筆順は (1) 式の評価値が有効であり，部分的に筆順の類似性を測る客観的な指標の作成ができたといえる．

今後の課題としては，まず 4.2 節, 4.3 節において，評価する人数が少ない点について改善が必要である．次に (1) 式の評価値は比較対象の最終画像ペアが大きく異なる場合にも適用できる補正項を必要としているについてより深い考察が必要である．最後に，人の創作物としてのスケッチを用いることで，人と人工知能の間にどのようなインターラクションが生じるかについて詳細な実験が必要である．

尚，本研究は一部，日本学術振興会科学研究補助金基盤研究 (C) (課題番号 26330282) の補助を得て行われたものである．

参考文献

[Eitz 12] Eitz, M., Hays, J., and Alexa, M.: How Do Humans Sketch Objects?, *ACM Trans. Graph. (Proc. SIGGRAPH)*, Vol. 31, No. 4, pp. 44:1–44:10 (2012)

[Ha 17] Ha, D. and Eck, D.: A Neural Representation of Sketch Drawings, *CoRR*, Vol. abs/1704.03477, (2017)

[Jain 99] Jain, L. C. and Medsker, L. R.: *Recurrent Neural Networks: Design and Applications*, CRC Press, Inc., Boca Raton, FL, USA, 1st edition (1999)

[Pu 17] Pu, Y., Gan, Z., Henao, R., Li, C., Han, S., and Carin, L.: VAE Learning via Stein Variational Gradient Descent, in Guyon, I., Luxburg, U. V., Bengio, S., Wallach, H., Fergus, R., Vishwanathan, S., and Garnett, R. eds., *Advances in Neural Information Processing Systems 30*, pp. 4236–4245, Curran Associates, Inc. (2017)

[Simard 03] Simard, P. Y., Steinkraus, D., and Platt, J. C.: Best practices for convolutional neural networks applied to visual document analysis., in *ICDAR*, Vol. 3, pp. 958–962 (2003)

[Singhal 01] Singhal, A.: Modern Information Retrieval: A Brief Overview, *Bulletin of the IEEE Computer Society Technical Committee on Data Engineering*, Vol. 24, No. 4, pp. 35–43 (2001)

[Ueno 15] Ueno, M., Fukuda, K., Yasui, A., Mori, N., and Matsumoto, K.: CASOOK: Creative Animating Sketchbook, in Omatu, S., Malluhi, Q. M., Gonzalez, S. R., Bocewicz, G., Bucciarelli, E., Giulioni, G., and Iqba, F. eds., *Distributed Computing and Artificial Intelligence, 12th International Conference*, pp. 175–182, Cham (2015), Springer International Publishing

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

Parallel residual adapterを用いたマルチタスク学習によるジェスチャー識別

Gesture Recognition by Multi-task Learning using Parallel Residual Adapters

鈴木 乃依瑠 *1 Noeru Suzuki　菊井 浩祐 *2 Kosuke Kikui　伊藤 勇太 *3 Yuta Itoh　鹿島 久嗣 *1 Hisashi Kashima　山田 誠 *1 Makoto Yamada

*1京都大学 Kyoto universiy　*2慶應義塾大学 Keio University　*2東京工業大学 Tokyo Institute of Technology

The photo reflective sensor (PRS) is a tiny distant-measurement module whilch is widely used in wearable user-interface. A issue of such wearable PRS devices is the performance degradation when a user data is not included in the training set (we call the inter-user setup). Moreover, the recognition accuracy also degrades when the same user re-wears the device (we call the intra-user setup). In this paper, we introduce the multi-task learning algorithm using the Parallel residual adapters as a method to perform additional training at high speed using a small amount of additional data. In the experiments, we demonstrate the performance improvement particularly in intra-user setup with the data of an actual PRS device.

1. はじめに

近年、普及が広がり注目を集め始めているウェアラブルデバイスであるが、それを構成する電子部品の一つに Photo reflective sensor (PRS) というセンサーがある。小型で安価であるという利便性から、PRS を利用することで様々なウェアラブルデバイスのユーザインタフェースを設計することができる。

このようなウェアラブルデバイスで計測したデータに対して機械学習の手法を適用する場合、避けられない問題がいくつか存在する。まず、学習データに含まれない新規ユーザのデータに対する識別精度が低下してしまうという問題がある。これはデータのユーザ依存性が高いことに起因する。また、ユーザがデバイスを再装着してデータを計測した場合にも装着具合の差によってデータの分布が変化し、識別精度が低下することがある。したがって、ユーザが変わることやユーザがデバイスを再装着することによる識別モデルのパフォーマンス低下を防ぐことが実用において重要な課題となってくる。

この問題を解決するため、追加で収集したデータを用いたモデルの追加学習を行うことを考える。しかし、大量のラベル付きデータをユーザごとに収集するのは多くのコストがかかってしまう。また、ウェアラブルデバイスに搭載される CPU は処理速度が遅く、大量データでの追加学習を行うことは現実的ではない。

したがって本研究では、少量の追加データを用いて高速に追加学習を行うための手法として、Parallel residual adapter [Rebuffi 18] によるマルチタスク学習を導入する。具体的には、識別モデルをユーザ間で共通のパラメタを学習する部分（ベースの分類器）とユーザ特有のパラメタを学習する部分 (Parallel residual adapter) に分け、まず大量のデータを用意できるユーザに関して全体の学習を行った後、少量のデータを用意するユーザに対して Parallel residual adapter のみ追加学習を行う。Parallel residual adapter のパラメタ数は共通のパラメタ数よりはるかに少ないため、高速な追加学習が可能となる。

実験では PRS を使用した Head Mounted Display (HMD) で計測した実データを用いて、新規のユーザがデバイスを使用する場合 (Inter-user) と既存のユーザがデバイスを再装着して使用する場合 (Intra-user) の二つの問題設定についていくつかの比較手法と提案手法の比較を行った。その結果、Inter-user においては提案手法が既存手法に精度の面で劣ったが、Intra-user においては既存手法を上回る精度を高速な学習で実現できることを示した。

本研究における貢献は、PRS を用いたウェアラブルデバイスのジェスチャー識別に対してマルチタスク学習を導入し、少量の追加データを用いて短時間で効率的に追加学習を行うための手法を提案したこと、そしてその有用性を実データを用いて実験的に示したことが挙げられる。

連絡先: 鈴木 乃依瑠, suzuki.noeru.47c@st.kyoto-u.ac.jp

2. 関連研究

PRS を用いた研究はいくつか存在する。Yamashita らは複数の PRS を HMD のフレームに取り付け、フレームから頬までの距離を PRS で計測することによって頬の形の変化を検出し、頬の上で指を使って行われる複数のジェスチャーのデータに対して support vector machine (SVM) による識別を行った [Yamashita 17]。また、Kikui らは本研究と同様の問題設定において fine-tuning によるドメイン適応を導入し、CheekInput [Yamashita 17] で計測したデータを用いてジェスチャー識別を行い、新しいユーザのデータに対する識別精度が 63.26%から 80.06%、既存ユーザのデバイス再装着のデータに対する識別精度が 68.96%から 87.43%に向上することを実験的に示した [Kikui 18]。

3. 問題設定

本研究におけるジェスチャー識別問題とは、ジェスチャーを計測したセンサーの時系列データからそのジェスチャーのラベルを予測する問題である。

集合 $\mathcal{X} \subset \mathbb{R}^{S \times F}$ をセンサーデータの集合 (S はセンサー数、F はフレーム数)、$\mathcal{Y}$ をラベル集合とする。本研究では、元ドメインの大量のラベルつき学習データ $D_s = \{(X_i^{(s)}, y_i^{(s)}) | X_i^{(s)} \in \mathcal{X}, y_i^{(s)} \in \mathcal{Y}\}_{i=1}^{N_s}$ を用いて学習した分類器 $H : \mathcal{X} \to \mathcal{Y}$ に対して、目標ドメインの少量の追加のラベルつき学習データ $D_t = \{(X_i^{(t)}, y_i^{(t)}) | X_i^{(t)} \in \mathcal{X}, y_i^{(t)} \in \mathcal{Y}\}_{i=1}^{N_t}$ を用いて追加学習を行うことでテストデータに対する精度を上げることを目的とする。なお、$N_t \ll N_s$ である。

追加の少量学習データ D_t 及びテストデータに関して、以下の二つの設定を想定する。

- 大量の学習データ D_s には含まれない新しいユーザのデータ (以下この設定を Inter-user と呼ぶ)。
- 大量の学習データ D_s に含まれるユーザがデバイスを再装着して計測したデータ (以下この設定を Intra-user と呼ぶ)。

4. 提案手法

4.1 Convolutional Neural Network

本研究ではベースとなる分類器として Convolutional Neural Network (CNN) を採用した。CNN とは、画像認識などに使われる代表的なニューラルネットワークの一つで、いくつかの畳み込み層、pooling 層と全結合層から成る。畳み込み層は元の画像にフィルタを畳み込むことで特徴マップを作成する層で、これにより領域ベースでの特徴抽出が可能となる。pooling 層は畳み込み層で抽出した特徴マップを重要な情報を残しながら圧縮する層で、これらの処理により特徴の位置感度が低下し、画像の移動や変形に対する頑健性が高くなる。全結合層では畳み込み層とプーリング層で抽出した特徴から最終的な分類を行う。

本研究では畳み込み層と pooling 層がそれぞれ二層と全結合層から成る CNN を構築した。pooling 層には小領域の最大値を選択する手法である max-pooling を採用した (したがって以下 max-pooling 層と呼ぶ)。

4.2 Parallel residual adapters

本節では、まず Rebuffi らの提案したドメイン特有のパラメタを学習するためのモデルである Parallel residual adapter [Rebuffi 18] の概要について説明し、次に本研究における工夫点について述べる。最後に追加学習を行う際の Parallel residual adapter の初期値について述べる。

Parallel residual adapter は、ベースとなる分類器の畳み込み層に対し並列に接続されるフィルターサイズ 1×1 の畳み込み層で、以下のように定義される。

$$q = f * p + diag(A) * p$$

ここで p は元の畳み込み層への入力、q は次の max-pooling 層への出力で、f は元の畳み込みフィルタ、$*$ は畳み込み演算子である。畳み込み層への入力チャネルを C、出力チャネルを D とすると、Parallel residual adapter のフィルターセットは $A \in \mathbb{R}^{C \times D}$ となる。$diag$ は上記の式の第一項と第二項の行列のサイズを合わせて加算ができるようにするための関数であり、$f \in \mathbb{R}^{L \times L \times C \times D}$($f$ のフィルターサイズが $L \times L$) とすると $diag : \mathbb{R}^{C \times D} \to \mathbb{R}^{L \times L \times C \times D}$ で、$diag(A)$ の (u, v, i, j) 成分を $[diag(A)]_{uvij}$、A の (i, j) 成分を A_{ij} とすると、以下のように定義される。

$$[diag(A)]_{uvij} = \begin{cases} A_{ij} & (u = v = (L+1)/2) \\ 0 & (otherwise) \end{cases}$$

f をドメイン共通のパラメタを学習するパラメタ、A をドメイン特有のパラメタを学習するパラメタと見なし、ドメインごとに Parallel residual adapter を用意し、切り替えて学習、識別を行う。具体的にはまず、大量の学習データ D_s を用いて、D_s に含まれるドメインの A を f と共に学習する。次に少量の追加学習データ D_t を用いて、f を固定したまま D_t に含まれるドメインの A を学習する。これにより少ない追加データによる短時間での学習が可能となる。識別の際は入力データのドメインに対応する Parallel residual adapter の A を用いて行う。本研究でベースとなる CNN は畳み込み層が二層であるので、両方に Parallel residual adapter を接続する。したがって、ユーザ一人あたり二箇所の Parallel residual adapter を学習することとなる。バッチ学習を行う場合、一つのバッチに含まれるデータは全て同一ユーザのデータである必要があることに注意されたい。本研究においては D_s での学習時、ユーザ共通のパラメタの学習が特定のユーザに対して偏ることがないようランダムな順番でユーザを選んで学習した。

次に、本研究における Parallel residual adapter の工夫点について述べる。本研究において実験に使用するデータはセンサー数 10、フレーム数 180 となっており、フレーム数の方向にデータが偏っている。したがって、データの端を切り落とすこととなる上記の $diag(A)$ をそのまま用いるとセンサー数の方向で失われるデータ量が多いと考えた。したがって代わりに p を A で畳み込んだ後、f と同じフィルターサイズの max-pooling を適用することによって失われるデータ量を抑えつつ第一項の行列と同じサイズとなるようにした。max-pooling を関数 mp として、以上の操作を式で表すと以下のようになる。

$$q = f * p + mp(A * p)$$

最後に、追加学習時の A の初期値について述べる。Inter-user においては大量の学習データ D_s に含まれない新しいユーザについて学習するので、ランダムな初期値から学習を行う。Intra-user においては D_s と D_t に含まれるユーザが共通であるので、D_s で学習した A の値が存在する。したがって、ランダムな初期値から学習を行う場合と D_s で学習済みの A の値から学習を行う場合の二通りが考えられる。実験において両者の学習結果について比較を行う。

5. 実験

5.1 データセット

本研究では実験のデータセットとして、Kikui ら [Kikui 18] が CheekInput [Yamashita 17] を用いて計測した実データを利用した。具体的には PRS を取り付けた HMD を用いて計測したジェスチャーの時系列データである。ユーザは予め決められた 4 つのジェスチャーを左頬の上で指を動かして行い、10 個の PRS がその頬の形を計測する。4 つのジェスチャーは以下の通りである。

1. Line 一直線に動かす。
2. Caret V を横に倒した形に動かす。
3. Circle 円を描くように動かす。
4. Stairs 階段状 (2 段) に動かす。

各ジェスチャーは 6 秒間（30Hz で 180 フレーム）の間に行われる。被験者となるユーザは 6 人で、各ユーザはランダムに指示される順にそれぞれのジェスチャーを 30 回ずつ行う試行（1 回目）を行った後、3 分のインターバルを挟み HMD を再装着して同じ試行（2 回目）を行う。したがってユーザ 1 人あたりのデータ数は 240 となる。データの値は 0 から 1023 で、最大値で割ることで正規化を行っている。

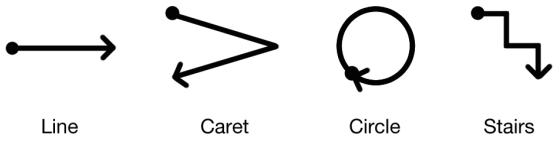


図 1: 4 つのジェスチャー [Kikui 18]

表 1: データの分割

設定	D_s	D_t 及びテストデータ
Inter-user	4 人のユーザのデータ	2 人のユーザのデータ
Intra-user	6 人の 1 回目のデータ	6 人の 2 回目のデータ

次に、3. で述べた二つの設定それぞれに関してデータの分け方を説明する。Inter-user においては、ユーザ 6 人中 4 人（以下学習ユーザと呼ぶ）のデータを大量の学習データ D_s、残り 2 人（以下テストユーザと呼ぶ）のデータを少量の学習データ D_t 及びテストデータとして用いる。D_t のサイズは各テストユーザについて 5、10、20、30、40、50、60 とし、残りをテストデータとする。Inter-user の場合は 1 回目と 2 回目のデータの区別をしないので、5 以外の場合は 1 回目と 2 回目のデータから半数ずつを取る。5 の場合はデータサイズが小さいので、ジェスチャーの種類数が 4 であることを考慮して 1 回目のデータから全種類のジェスチャーを含むようにデータを取る。

Intra-user においては、ユーザ 6 人の 1 回目の試行のデータを D_s、2 回目の試行のデータを D_t 及びテストデータとして用いる。D_t のサイズは各テストユーザについて 5、10、20、30、40、50、60 とし、残りをテストデータとする。データの分け方をまとめたものを表 1 に示す。

5.2 ベースライン

本節では、提案手法と比較するベースラインとして用いた手法について説明する。

5.2.1 CNN(D_s)

Parallel residual adapter を接続しないベースの CNN を用いる。D_s を用いて学習した後、追加学習を行わずにテストデータの精度を調べる。したがってこの手法においては D_t は存在せず、D_s 以外のデータが全てテストデータとなる。

5.2.2 CNN(D_t)

Parallel residual adapter を接続しないベースの CNN を用いる。この手法においては D_s での学習は行わず、D_t のみで最初から学習を行った場合のテストデータの精度を調べる。ユーザごとにモデルを用意し、別々に学習とテストを行う。

5.2.3 CNN($D_s + D_t$)

Parallel residual adapter を接続しないベースの CNN を用いる。D_s と D_t を混ぜ合わせたものを学習データとして最初からモデルの学習を行い、追加学習は行わずにテストデータの精度を調べる。ユーザごとにモデルを用意し、別々に学習とテストを行う。

5.2.4 CNN(fine-tuning)

Kikui ら [Kikui 18] によって提案された手法である。Parallel residual adapter を接続しないベースの CNN を用いる。D_s を用いて学習した後、追加学習として D_t を用いて CNN の全結合層の fine-tuning を行う。D_s での学習は CNN(D_s) で学習したモデルを利用し、追加学習とテストはユーザごとに別々に行う。

5.2.5 Parallel residual adapters（追加学習なし）

この手法は Intra-user のみに適用する。提案手法と同様の Parallel residual adapters を接続した CNN を D_s を用いて学習した後、追加学習を行わないでテストデータの精度を調べる。したがってこの手法も CNN(D_s) と同様に D_t は存在しない。

5.3 実験結果

二つの問題設定それぞれについて実験結果を示す。本研究では評価指標としてテストデータの正解率 (Accuracy) を用いる。各手法に対して 1 回の学習につき 200 エポックを回し、10 回学習を実行したものの平均を取る。ユーザごとに別々に学習、テストをしている手法についてはさらに全ユーザの平均を取る。なお、表における PRA とは Parallel residual adapter の略である。

5.3.1 Inter-user

Inter-user における実験結果を表 2 に示す。D_t のサイズが 20 以上になると追加学習を行わない CNN(D_s) に対し提案手法が勝るが、CNN(fine-tuning) には及ばない結果となった。CNN(D_t) が D_t のサイズ 60 において CNN(D_s) を上回るのに対し提案手法は 20 で上回るので、追加のデータで最初から学習し直すよりも少ないデータ量で高い精度を出せることがわかる。また、CNN($D_s + D_t$) が一番高い精度を出しているが、この手法は学習のデータ量が多く他の手法に比べて大幅な時間がかかるため実用性という点においては短時間で追加学習が行える提案手法の方が優れているといえる。

5.3.2 Intra-user

Intra-user における実験結果を表 3 に示す。PRA（ランダム初期値）がランダムな値を初期値として A を学習した場合、PRA（学習済み初期値）が D_s で学習した値を初期値として A を学習した場合である。

PRA（ランダム初期値）は D_t のサイズが 40 を超えると CNN(D_s) を上回るが、CNN(fine-tuning) とはあまり大差ない結果となった。一方で PRA（学習済み初期値）は D_t の全てのサイズにおいて CNN(D_s) を上回っており、PRA（ランダム初期値）以上の追加学習の効果が見られる。また CNN(fine-tuning) に対しても全てのサイズにおいて上回っていて、学習済みの値から学習する場合は D_t が小さくても高い精度を出すことができるということがわかる。Inter-user 同様、CNN(D_s+D_t) が高い精度を出しているが、これも学習に時間がかかるため実用的ではないと思われる。

5.4 考察

以上の実験結果について、Inter-user と Intra-user の結果を比較しながら考察を行う。

Intra-user では既存手法を上回った提案手法が Inter-user では既存手法を下回ってしまった原因の一つとして、まず二つの問題設定における D_s と D_t の性質が異なることが挙げられる。Inter-user では D_s と D_t に含まれるユーザが異なるのに対して Intra-user では共通であるため、D_s と D_t の類似度が高い。このことは、CNN(D_s) の実験結果において Inter-user では 80.5%まで下がってしまう精度が Intra-user では 95.5%に留まることからもわかる。

また、Intra-user において PRA（ランダム初期値）が PRA（学習済み初期値）に劣る結果となったことから、Parallel resid-

表 2: Inter-user 実験結果

手法	D_t のサイズ なし	5	10	20	30	40	50	60	実行時間 (s/user)
CNN(D_s)	0.805	-	-	-	-	-	-	-	-
CNN(D_t)	-	0.517	0.630	0.710	0.764	0.840	0.762	0.843	3.928
CNN($D_s + D_t$)	-	0.811	0.855	0.897	0.913	0.926	0.932	0.952	125.370
CNN(fine-tuning)	-	0.731	0.809	0.843	0.907	0.920	0.921	0.906	3.881
PRA	-	0.761	0.777	0.856	0.841	0.874	0.881	0.885	5.737

表 3: Intra-user 実験結果

手法	D_t のサイズ なし	5	10	20	30	40	50	60	実行時間 (s/user)
CNN(D_s)	0.955	-	-	-	-	-	-	-	-
CNN(D_t)	-	0.629	0.755	0.844	0.890	0.873	0.906	0.906	3.984
CNN($D_s + D_t$)	-	0.969	0.962	0.981	0.986	0.984	0.972	0.991	98.641
CNN(fine-tuning)	-	0.878	0.914	0.943	0.933	0.948	0.963	0.969	3.792
PRA(追加学習なし)	0.938	-	-	-	-	-	-	-	-
PRA(ランダム初期値)	-	0.916	0.917	0.928	0.936	0.956	0.955	0.964	6.209
PRA(学習済み初期値)	-	0.960	0.972	0.976	0.974	0.976	0.976	0.979	5.309

ual adapter の初期値が少なからず役割を果たしていることがわかる。したがって、Intra-user においては学習の際にユーザの区別をしない CNN(fine-tuning) よりもユーザ特有のパラメタを学習する提案手法の方がより各ユーザの特徴を学習し、PRA（学習済み初期値）において追加学習の際にその情報を Parallel residual adapter の初期値として得ることができるため精度の向上に貢献しているのだろうと考えられる。逆に、Intra-user の PRA（ランダム初期値）や Inter-user では Parallel residual adapter の初期値がランダムであるために情報を得られず、追加学習でテストユーザの特徴を学習しきれなかったのだろうと思われる。

次に実行時間に関する考察を行う。5.3 節でも述べた通り、一番高い精度を出している CNN($D_s + D_t$) は学習時間が多くかかるため実用性に欠ける。また、Inter-user、Intra-user 共に CNN(fine-tuning) の方が提案手法より学習時間が短い。追加学習時の学習パラメタ数は CNN(fine-tuning) に比べ提案手法の方が少ないが、重みの更新を行う際に提案手法の方がモデルの構造が複雑であるため時間がかかってしまうのではないかと思われる。この差は D_t のサイズが大きくなるにしたがって大きくなると考えられるが、本研究の目的は小さいサイズの D_t で追加学習することであるので、実用において支障が出る程の差ではないと考えられる。

6. 結論

本論文では、PRS を用いたウェアラブルデバイスによるジェスチャー識別問題に取り組み、Parallel residual adapter によるマルチタスク学習を導入したモデルを提案した。さらに新規のユーザがデバイスを使用する場合 (Inter-user) と既存のユーザがデバイスを再装着して使用する場合 (Intra-user) の二つの問題設定において実データを用いた実験を行い、少量データによる短時間の追加学習で精度の向上を実現できることを示した。また、特に Intra-user において提案手法が既存手法を上回る精度を出せることを示した。

今後の展望としてはまず、提案手法が既存手法を上回ることのできなかった Inter-user において、より効果的に追加学習を行うことができるような Parallel residual adapter の A の初期値を求めることが挙げられる。例えば学習ユーザとテストユーザのデータの分布などを解析し、識別するテストユーザに似たデータを持つ学習ユーザの A の値を初期値とすることが考えられる。あるいは、ランダムな初期値からの追加学習であっても少ないデータ量でテストユーザ特有の特徴を十分学習できるように Parallel residual adapter の構造の改良を行うことが挙げられる。また Parallel residual adapter について、今回関数 *diag* の代わりに max-pooling を用いているが、本研究においてはこれらの違いによる性能比較を行っていない。したがってどちらがより有用か、あるいはほかに有用な方法はないかなどの検証を行う必要がある。

7. 謝辞

本研究では慶應義塾大学の杉本麻樹准教授と杉浦裕太講師にデータ提供を頂きました。厚くお礼申し上げます。

参考文献

[Yamashita 17] Yamashita, K., Kikuchi, T., Masai, K., Sugimoto, M., Thomas, B. and Sugiura, Y.: CheekInput: Turning your cheek into an input surface by embedded optical sensors on a head-mounted display, *Proceedings - VRST 2017*, Vol. Part F131944, Association for Computing Machinery (2017).

[Rebuffi 18] Rebuffi, S., Bilen, H. and Vedaldi, A.: Efficient parametrization of multi-domain deep neural networks, *CoRR*, Vol. abs/1803.10082 (2018).

[Kikui 18] Kikui, K., Itoh, Y., Yamada, M., Sugiura, Y. and Sugimoto, M.: Intra- /Inter-user Adaptation Framework for Wearable Gesture Sensing Device, Proceedings of the 2018 ACM International Symposium on Wearable Computers, ISWC '18, ACM, pp. 21-24 (2018).

General Session | General Session | [GS] J-13 AI application

[2M3-J-13] AI application: consumption and market

Chair:Kazunori Matsumoto Reviewer:Jun Ichikawa

Wed. Jun 5, 2019 1:20 PM - 2:40 PM Room M (Front-right room of 1F Exhibition hall)

[2M3-J-13-01] Promotion of unmanned stores through automatic AI accounting

○kanae matsuo[1], kana kawatani[1], tomoki ishida[1], ruriko tsubota[1] （1. doshisha university）

1:20 PM - 1:40 PM

[2M3-J-13-02] A Context-Aware Recommender System for AR-based Shopping Support

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

1:40 PM - 2:00 PM

[2M3-J-13-03] Discrepancy prediction between the results purchase and pre-listening of the face-to-face sales

○Takumi Uchida[1,2], Kenichi Yoshida[2] （1. Recruit Communications Co., Ltd., 2. University of Tsukuba Graduate School）

2:00 PM - 2:20 PM

[2M3-J-13-04] Verification of Consumer Behavior Model Focusing on Point System

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

2:20 PM - 2:40 PM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

AI自動会計による無人店舗導入の推進

Promotion of unmanned stores through automatic AI accounting

石田朋己、笠谷奏乃、坪田凛々花、

松尾佳苗、間宮有紀、tomoki ishida, kanano kasatani, ririka tsubota, kanae matsuo, yuki mamiya

同志社大学商学部商学科田口聡志ゼミ

Satoshi taguchi seminar ,The department of commercial science ,Doshisha university

概要　Abstract

①本稿の目的は、日本の生産年齢人口の減少から生じる人手不足を解消するために、無人店舗を増やすことを推進するこ とである。世界では無人店舗が多数営業するも、日本ではほとんど無人店舗はない。世界では主に、価格帯の低い商品を販 売する店舗で無人営業が行われているのだが、それは人間が価格帯の低い商品なら、AIによる自動会計で店員を必要としな いことに基づいているのか、疑問に感じた。そこで、AIが高価格帯の店で受け入れられるためには会話のスキルが必要なの ではないかと考えた。

The purpose of this paper is to promote the increase of unmanned stores in order to eliminate the labor shortage resulting from the decline of the working-age population in Japan. Although there are many unmanned stores operating in the world, there are almost no unmanned stores in Japan. In the world, unmanned sales are mainly performed at stores that sell low-priced products, but it is based on the fact that AI does not need clerks in automatic accounting by AI if it is a low-priced product. I felt it was a question. Therefore, I thought that it would be necessary for conversation skills to be accepted by AI at high-price stores.

②結果として人々が買い物時に求めるものとして、会話はそれほど重要な要素では無く、現在の技術でも十分顧客の要望 に沿ったサービスを提供できると考えられた。一方で、人々にAIの技術が受け入れられてないという側面もある。その理由 として「AIに対する知識不足」「損失回避性」「現状維持バイヤス」か〝働いていると考えた。

As a result, it was thought that conversation was not a very important factor that people would like to do when shopping, and that the current technology could provide a service that fully met the needs of customers. On the other hand, there is also an aspect that people can not accept the technology of AI. As the reason, I thought that "insufficient knowledge of AI", "loss aversion", and "status maintenance bias" were working.

第1章 研究の背景 日本は今、深刻な人手不足に陥っている。1995年のピー

クから徐々に労働人口は減少し、2065年には6割程度にまで　減ってしまう。そこで世界では人を使わない無人店舗が勢 力を広げている。amazon goというスーパーは入り口のゲー トで携帯をかざし、あとは好きな商品をカバンに入れゲー トをくぐるだけで自動決済してくれるというサービスだ。 しかし、現在導入されているAI自動会計は比較的に低い価 格帯の商品を販売する店がほとんどで、逆に価格帯の高い 店では世界的にみてもほぼ導入されていない。価格帯が高 い店でAIシステムの導入がされにくいのは何故か。そこに　はAIにはない人間特有の消費者の購買意思決定を促進させ　る能力があると考えた。すると「思考のジャンプ」という 現象に行き着いた。「思考のジャンプ」とは会話時に店員 が消費者の予測とは違う意外な返答をした時に消費者の購 買意思決定を引き起こす現象だ。

第2章 仮説

そこでAIが高価格帯の店で受け入れられるためには会話 のスキルが必要なのではないかという仮説を立てた。

第3章 調査

調査は、googleフォームのアンケートを用い、大学生102人を対象にデータの収集を行った。アンケートでは価格帯 の低い商品、高い商品についてAI自動会計、人間の会計の どちらが好ましいかを質問した。収集されたデータをグラ フで見ると明らかに価格帯の低い商品においてはAIレジが 好まれ、価格帯の高い商品においては人間の会計が好まれ るという傾向が見られた。

第4章 分析

今回はt検定を用いて分析を行った。帰無仮説は二つの標 本の差の平均は0である、つまり二つの質問の回答に差がな いとする。対立仮説は二つの標本の差の平均は0ではない、 つまり二つの質問の回答に差があるとする。t検定の分析の 結果、P値1.15E-53より有意水準1%の検定において帰無仮 説を棄却し対立仮説を支持する。つまり二つの質問(価格 帯が低い商品においてどちらの会計が好ましいか、価格帯 の高い商品においてどちらの会計が好ましいか)の回答に 差がある。

第5章

このことから価格帯の低い店ではAI、高い店では人が好 まれることが立証された。次に、人とAIへの意識を調査す べく、それぞれに足りないものを自由記述で質問した。人 では「スピード」「正確さ」「平等な接客」、AIでは「面 白み」「会話コミュニケーション能力」「温かさや感情」 という回答が多く見られた。 また買い物をするときに何を求めるか、という選択式の質 問をした。(下記グラフ参照)多数の回答が得られたものか ら順に「気軽さ」「自由さ」「商品の情報」となった。こ れらは現在のAIの技術で対応可能なものだ。一方、複数選 択可という条件の下、一人当たり3.1個の回答があったにも 関わらず、「会話の楽しさ」を選択した人は僅か12%と なった。

第6章 考察 これらの分析結果を踏まえ着目したのは、AIに不足して いるものと買い物をする時に求めるものが一致しない点 である。人々がAIに本当に求めている能力はコミュニ ケーション能力なのだろうか。また、近年予想を上回る 技術が搭載されたAIが開発されている。伊勢丹新宿店で は個々の感性を学習し、顧客ごとの嗜好を理解するAI「SENSY」を導入。他にも、数少ないデータからユーザー の好みの傾向を把握し、予兆を検知する「kibit」、顔の 筋肉の僅かな動きを捉えて感情をデータ化する「affdex」など様々な分野で活躍する人工知能が開発されてい る。日本では、上記のような技術を持つAIが比較的高い 価格帯のブランドである「4°C」で実験的に導入された 例もある。「4°C」では、いくつかの選択肢から顧客が 好みの条件を選択し、最終的に商品の提案へ導くチャッ ト形式の人工知能を採用。結果は、チャットを開きAIと の会話に至ったユーザーは来店客の僅か2割と少なかっ た。しかし、チャットを開いたユーザーの中で商品提案 の段階まで辿り着いたのは約8割。更に、人が接客を行っ た場合の購入確率は1.53%て゛、AIが接客を行った場合の 購入確率は4.49%と約3倍もの購買効果が期待できると明 らかになったのた゛。これらの例により、AI接客にも購買 行動を促進する能力が存在していることが分かる。

第7章 再調査

考察で述べたような技術が既にAIに搭載されているとい うことを前提として調査を行えば、人とAIどちらが好まれ るのか。人々は店員との会話を重要視しているのか。この2点について再調査を行った。前回のアンケートは飲食業、 ホテル業、アパレル業を比較したが、対象の範囲が広いた めアパレル業に絞る。アパレル業を選んだ理由としては、 価格帯が広く、会計を終えるまでの流れが統一されている

参考文献

オンラインショッピングシステムのインタフェ ースの向上へ向けて——実購買行動の分析結果か らの示唆

https://ipsj.ixsq.nii.ac.jp/ej/index.php?action=pages_view_main&active_action=repository_action_common_download&item_i d=11935&item_no=1&attribute_id=1&file_no=1&page_id=13&block_id=8

https://ledge.ai/theai-2nd-cyberagent/

ためである。取集方法は前回同様、Googleフォームのアン ケートを用い、110人の大学生を対象に行った。まず、接客 に求めるものは何かを自由記述で質問。次に「ファスト ファッション」「ハイブランド」て゛それぞれ店員に話しか けられることについての意識を二択で質問。「ファスト ファッション」は前回同様8割が店員に話しかけられること を「嫌」だと答えた。一方、「ハイブランド」では前回AIによる接客を好む層は僅か5%だったにも関わらず、およそ4割が店員に話しかけられることを「嫌」だと答えた。最後 に自由記述でAIが高い能力を持っている上で人かAIどちら に接客されたいか、またその理由を質問した。約半数がAIによる接客が良いと回答した。これにより人々が会話に よって得ようとしている情報などはAIでも提供が可能であ ると考えられる。

第8章 結果 考察

以上の結果から会話能力、特に店員側から客に話しかけ る能力はAIの普及において重要な能力ではないことか ゛分か る。また、客の要望に応対するコミュニケーション能力は 現在の技術で大方持ち合わせていることか ゛わかる。

また充分導入できる技術があるのにも関わらずAIシステ ムによる店舗が受け入れられない理由として、AIに対する 知識が浅いという点が挙げられる。これは二度目の調査で 現在のAIの技術の進歩を提示するとAIの支持率が上がった ことからも分かる。 また、まだ一般的に導入されていないAIを導入して失敗するというリスクを回避しようとする損失回避性や、変化 をして利益を得る可能性があっても現状を維持しようとす る現状維持バイアスが働いていると考えた。

第9章 研究の限界と展望

研究の限界は日本ではAIが実際に導入されている事例は まだ少ないこともありイメージが個人によってずれるので 調査結果が正確でないことや、企業側の意見を聞くことが できなかったので今回の結果はあくまで消費者側からの見 解しか得られなかったことだ。というのも再調査での「AIにどのような能力が備われば人間に勝るか」という自由記 述の質問で「消費者を購入に誘導する話術」という回答が あった。消費者目線では会話はそれほど重要ではないかも しれないが、1枚でも多く売りたい企業にとってAI導入に よる人件費の削減というメリットよりも、店員の会話の誘 導による売上が減るというテ ゛メリットのほうが大きいかも しれない。これらもふまえて今後の展望として企業側の意 見を取り入れて分析を進めることで、企業にとってもメ リットのあるAIの導入方法を研究することが挙げられる。

2018.5.28日経産業新聞10ページ2018.9.17日経MJ13ページ2018.11.30日本経済新聞朝刊3ページ

2018.10.19日経MJ13ページ1018.12.18日本経済新聞19ページ2018.12.26日本経済新聞 地方経済面SENSSY 株式会社 https://sensy.si

-2-

FRONTEOhttp://www.kibit-platform.com/products/knowledge-probe/

総務省 平成29年版情報通信白書 人口減少社会の課題

と将来推計

http://www.soumu.go.jp/johotsusintokei/whitepaper/ja/h29/ht ml/nc141110.html

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

AR技術を用いた購買支援のための状況依存な推薦システム

A Context-Aware Recommender System for AR-based Shopping Support

安藤力哉 *1 伊藤栄俊 *1 大囿忠親 *1 新谷虎松 *1
Rikiya Ando Eishun Ito Tadachika Ozono Toramatsu Shintani

*1名古屋工業大学大学院情報工学専攻
Department of Computer Science, Graduate School of Engineering, Nagoya Institute of Technology

AR (Augmented Reality) technologies enable us to support shopping in the real world by presenting relevant information about recognized objects. When acquiring related information of objects, it is insufficient to simply search for images or characters related to the objects. It is necessary to select an appropriate information source from multiple dedicated information sources according to the context. Regarding the selection of information source, a selective meta search engine can be used. In this research, we aim to realize a new selective meta search engine considering the context in the real world to take advantage of AR technologies through a development of an AR-based shopping support system. This paper discusses a design of the selective meta search engine for AR applications.

1. はじめに

現実空間内での購買支援において，AR(Augmented Reality) 技術を用いて現実世界の物体に関する関連情報の提示は有益である．物体の関連情報を取得する際に，単に対象物体に関する画像や文字を検索するのは不十分であり，状況に応じた適切な情報源の選択が必要となる．情報源の選択に関しては，選択的メタサージエンジン [1] が利用可能であるが，AR における検索を考慮すると，現実空間の状況を扱うための新たな技術が必要である．本研究では，AR に基づく購買支援システムの試作を通じて，AR に適した選択的メタサーチエンジンの実現方法を明らかにすることを目標とする．本稿では，AR を用いた購買支援のための，選択的メタサーチエンジンを利用した状況依存な推薦システムについて議論する．

2. AR を用いた物体の認識および位置推定

本研究の関連研究である，Wedge について説明する．Wedge とは，画像マーカを用いることにより，三次元空間における再配置問題を解決するためのシステムである．再配置問題とは，三次元空間上に投影されるオブジェクトの位置情報をどのように決定するかという問題である．ここで，Wedge の機能の詳細について説明する．Wedge は，現実空間の位置と AR 空間の位置を対応づける機能を持つ．そのため，現実空間の位置情報を取得するために，画像マーカを与える．画像マーカとは，条件を満たす任意の画像を用いたマーカを意味する．Wedge における画像マーカは，一般的な画像マーカと異なる．ここでは，画像マーカとは，QR コードのような人間にとって無意味な標識ではなく，日常的に用いられる物体を撮影したものやメタファーを表す画像をマーカとして使用することができる．画像マーカを用いることで，QR コードなどの特別なマーカを用意する必要がない．Wedge は画像マーカをトラッキングしており，画像マーカの位置が更新されれば，更新された位置に応じて，対応した AR オブジェクトの位置情報が変更される．これにより現実空間の物体の移動により，AR オブジェクトの再配置が可能になる．位置情報の変更だけでなく，向きの変更も可能である．

また，Wedge システムの応用として，AR Poster が開発されている．AR Poster は Wedge システムを用いて AR 空間上に様々なポスターを貼ることを支援するシステムである．AR で作成するポスターを AR Poster と定義する．AR Poster はポスター画像をテクスチャとしてもつ三次元モデルである．現実世界におけるポスターは壁や掲示板に画鋲等で貼り付けて掲示する．AR Poster は，AR 空間上にポスターを表示させることで，現実空間のいたるところにポスターを貼り付けることを可能にするシステムである．

連絡先: 安藤力哉，名古屋工業大学工学研究科情報工学専攻，愛知県名古屋市昭和区御器所町，052(735)5584，rando@toralab.org

3. AR に基づくコンテキスト情報を用いた選択的メタサーチエンジン

AR アプリケーションで取得可能なコンテキスト情報を利用した効果的なサービスの実現に必要な，選択的メタサーチエンジンについて述べる．本選択的メタサーチエンジンは，AR アプリケーションで取得可能なコンテキスト情報として，(1) 映像内の物体 (2) 位置情報，および (3) 日時を考える．(1) の映像内の物体とは，物体名および，物体の詳細情報である．例えば，物体名を用いての検索を行う際に利用する．(2) の位置情報とは，現在のユーザの所在である．例えば，ユーザが書店にいる際に，現在位置は書店であると判断する際に利用する．(3) の日時とは，物体の利用期限および，現在時刻との差である．例えば，物体の利用期限の確認を行う際に利用する．

映像内で認識した物体情報に対して関連情報の重畳表示する処理は，(a) 物体認識，(b) マーカの特定，および (c) AR オブジェクト表示の 3 ステップから構成される．(a) の物体認識では，一般物体検出器を用いて，画像内の物体を検出する．現実空間における物体の検出は先行研究で開発済みの Piepple[2] を利用している．(b) のマーカの特定では，事前に登録済みの特定の画像をマーカとし，実空間の物体と一致するマーカを特定する．マーカの特定に，Wedge システムを利用している．(c) の AR オブジェクト表示では，マーカに一致した実空間の物体に対して，関連情報を重畳表示する．具体的にはマーカに一致した物体の表示座標に，AR オブジェクトを配置し，関連情報を表示する．

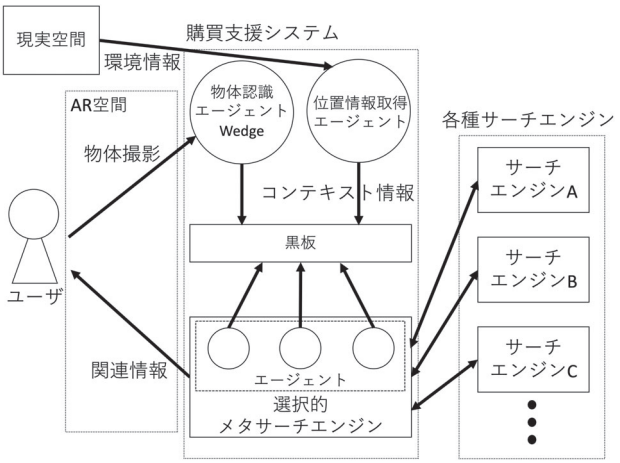


図 1: システム構成図

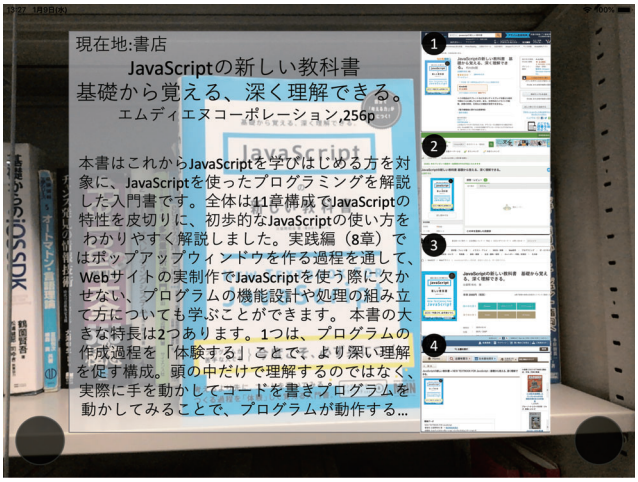


図 2: AR を用いた購買支援システム

マーカには事前に関連情報が紐付けされており，それに基づき物体の関連情報を検索する．マーカに紐づいている情報として，物体名，物体の詳細情報等がある．さらに，コンテキスト情報を統合的に利用して，サーチエンジンを選択するために，マーカに対する情報提示のためのエージェントを割り当てる．エージェントは，利用するコンテキスト情報，サーチエンジン，コンテキスト情報の条件等を設定するためのルール集合を持つ．撮影する物体に対して，適したエージェントを割り当てることにより，ユーザの必要とする情報を取得する．

モバイル端末から得られる位置情報および，AR 技術を利用し，空間内から得られるコンテキスト情報を利用することが可能になる．得られたコンテキスト情報を用いることで，適切なサーチエンジンを選択する．適切なサーチエンジンを用いることで，物体に関連する必要な情報の検索および取得が可能になる．

4. 購買支援のための推薦システム

図 1 は，本システムの構成図を表している．ユーザは物体をモバイル端末で撮影することにより，システムからその物体に関連する情報を取得できる．また，ユーザはモバイル端末上での物体撮影時，情報取得時において，AR 空間を通して情報の受け渡しを行う．購買支援システムでは，物体認識エージェント Wedge と，位置情報取得エージェントが存在する．Wedge によって撮影した物体が，登録されている画像マーカと一致するかを検証する．物体が画像マーカと一致した場合は，登録されている物体情報を取得する．また，位置情報取得エージェントによって，現実空間から座標情報，センサ情報等の環境情報を取得することにより，ユーザの現在位置を推定する．これにより，各エージェントによって取得した情報を，コンテキスト情報として，黒板に渡す．選択的メタサーチエンジンでは，各エージェントが黒板からコンテキスト情報を取得し，検索するためのサーチエンジンを選択する．サーチエンジンの選択には，認識した物体についての情報が得られるか，現在の位置情報から，ユーザの必要とする情報が何かを考慮する．この際のサーチエンジンの選択について，必要な情報を提示するために，画像マーカ登録時に設定されたエージェントが利用される．これにより，選択されたサーチエンジンを用いて，認識した物体について必要な情報の取得を行う．

図 2 は，システムの実行例である．物体の関連情報は，撮影した物体に対して，AR Poster の技術を利用することにより，重畳表示される．関連情報として，物体名，物体の詳細，現在の位置情報，サーチエンジンへのリンクが表示される．ここで，サーチエンジンについては，画像マーカに対応するエージェントに設定されているサーチエンジンを 1 つまたは複数個表示する．サーチエンジンの表示については，優先順に昇順で配置される．リンク先の Web ページの閲覧および操作についてもシステム上で行うことができる．これにより，ユーザは物体を撮影することで，物体についての関連情報を得ることができる．

ユーザは，本システムを利用することによって，店舗等で，物体に関連する情報を得ることができる．つまり，購買する際に，手に取るだけでは得られないような，商品に関連する情報を得ることができる．そのため，商品の購買促進に繋がるものである．また，店舗でない場合においても，購入サイトを Web 上で閲覧することにより，購買に繋げることが可能である．また，関連する情報により，購買意欲の促進にも繋がる．

5. おわりに

本稿では，AR に基づく購買支援の実現に必要な，実空間上の物体に対して，得られた情報依存な推薦システムについて述べた．本推薦システムの実現に向けて，コンテキスト情報を利用して適切なサーチエンジンの選択を行う選択的メタサーチエンジンについて検討した．適切なサーチエンジンの選択には，コンテキスト情報に基づく検索のためのエージェントを導入した．エージェントは，サーチエンジンを選択し，利用するためのルール集合から構成されている．本システムに基づく購買支援システムを示した．本購買支援システムは，ユーザの状況に応じて情報源となるサーチエンジンを列挙し，それらのサーチエンジンを用いた情報提示により購買を支援する．

参考文献

[1] 後藤, 大囿, 新谷, ”選択的メタサーチエンジンにおけるシソーラスを用いたサーチエンジン選択手法の提案”, 人工知能学会論文誌 17 巻 3 号, pp.285-292, 2002.

[2] 伊藤, 大囿, 新谷, ”Piepple: 拡張現実技術に基づく実世界描画オブジェクトの切り抜き機構とその応用”, FIT2018, 第 2 分冊, pp.31-34, 2018.

対面販売でのヒアリング内容と購入結果の食い違い予測

Discrepancy prediction between the results purchase and pre-listening of the face-to-face sales

内田 匠 *1*2　吉田 健一 *2
Takumi Uchida　Kenichi Yoshida

*1株式会社リクルートコミュニケーションズ
Recruit Communications Co., Ltd.

*1*2筑波大学大学院 ビジネス科学研究科
University of Tsukuba Graduate School of Business Sciences

It is difficult to interview real hope from customer through face-to-face consultation. For example, when customers try to purchase houses, even if they explain their hope to the sales staffs, they frequently purchase houses which are different from what they explain before. In other words, getting real hope of customer from face-to-face consultation is a difficult task. As the result, sales staff cannot offer satisfactory houses and lose their customers. In this study, we conducted a questionnaire on customers who bought house to see the relationship between pre-lisning results from them and their actual purchases.

1. はじめに

本研究では顧客と対面販売員のコミュニケーション問題として、必ずしも購入される商品が顧客から事前にヒアリングした内容と同じものではない現象について分析を試みた。この現象は企業が適切な商品を顧客に提案する上で、問題となっている可能性が高い。本研究にあたり、1) 始めにこの問題が実在するかをアンケート調査で確認した。さらに、2) 何をヒアリングすれば購入内容を予測できるか、を機械学習の手法を用いて調査した。

1.1 「実際にこの問題が実在するか」の概要と結論

1 年以内に分譲マンションを購入した人を対象にアンケート調査を行い、購入の際に事前に重視していた項目と実際に購入したマンションの情報を比較した。この解析結果から、事前の重視項目と実際の購入物件に直接的な関係がある場合とそうでない場合が確認できた。(図 1,2,3) 例えば、広さを重視すると回答した顧客が、実際に床面積の広い物件を購入する傾向は観測できなかった。一方、駅からの徒歩分数を重視すると回答した顧客は、そうでない顧客と比較した場合に、駅から近い物件を購入する傾向にあった。ただし、重視すると回答したとしても必ずしも駅から近い物件を購入するわけではなく、本研究が対象とする問題は実在すると考えられる。

1.2 「何をヒアリングすれば購入内容を予測できるか」の概要と結論

我々は価格、床面積、駅からの徒歩分数などは顧客の様々な事情や状況の組み合わせで決定され、有能な販売員は適切なヒアリングを行って顧客が満足する提案を行っていると仮説した。よって、対面販売でどのようなヒアリングをすればこれらが予測できるかを分析した。具体的には「都道府県、家族構成、物件選びで重視する項目、購入の目的、希望の生活」などをアンケートで取得し、実際に購入された物件の「価格、床面積、駅までの徒歩分数」が予測可能かを検討した。結果、線形回帰モデルや回帰木などの単純なモデルでは「都道府県、家族構成」のみを説明変数として利用する場合が最も予測精度がよく、それ以上の変数追加は精度を悪化させることが確認できた。一方で、Gradient Boosting Tree や多層ニューラルネットワークなどの複雑なモデルでは「物件選びで重視する項目、希望する生活や暮らし」などの複雑な情報を用いた方が精度が高いことも確認できた（表 2)。

連絡先: 内田 匠, 株式会社リクルートコミュニケーションズ, 〒 104-0054　東京都中央区勝どき 1-13-1　イヌイビル・カチドキ

表 1: アンケートの項目

変数分類	質問内容	選択肢など
目的変数	購入物件の価格	整数を入力。単位は万円
	購入物件の床面積	整数を入力。単位は平方 m
	購入物件の最寄り駅までの徒歩分数	整数を入力。単位は分
説明変数	購入物件の都道府県	[東京, 大阪, ...]
	家族構成	[配偶者, 子ども, 親] の有無
	物件の重視項目	[価格, 広さ, 駅までの距離, ...] など 18 項目から最大 5 つ
	購入目的	[家族のため, 仕事の都合, ...] など 24 項目から最大 3 つ
	希望する生活や暮らし	[ホームパーティ, ペット, ...] など 50 項目から最大 5 つ

2. 実施したアンケートについて

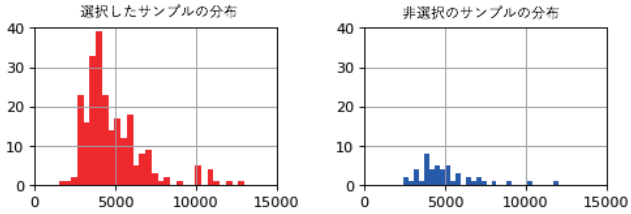
1 年以内に新築分譲マンションを購入した 330 人に対してインターネット調査を行った。調査項目を表 1 に示す。

3. アンケートの解析結果

顧客が事前に重視していた内容と実際の購買結果にどの程度の差があるのかを確認するために、アンケート項目の「検討にあたって重視する項目」と「実際の購入結果」を比較した（表 1, 2, 3)。これらの結果から、価格と駅の近さについては事前の重視項目と実際の購入に若干の関係性が見られたが、明確な影響があるとは言い難い結果となった。また、物件の広さについては事前の重視項目に選択されていても、実際に床面積の広い物件が購入される傾向は確認できなかった。よって、新築マンションの販売現場において、事前のヒアリング内容と実際に購入される物件に違いがあることは確認できた。

図 1: 重視項目に価格の有無と実際の購入価格の関係

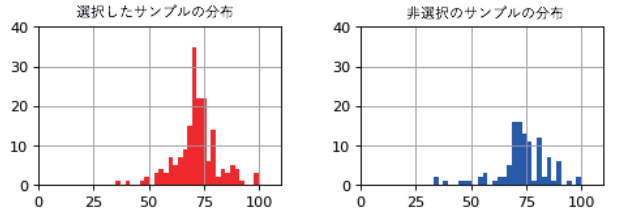
	購入した物件の価格			
価格	平均値	中央値	標準分散	サンプル数
重視項目に選択	4,825	4,290	1,910	240
重視項目に非選択	5,073	4,500	1,891	48



重視項目に選択したサンプルは、実際に安い物件を購入する傾向がある。しかし、サンプル数に大きな偏りがある。

図 2: 重視項目に広さの有無と実際の床面積の関係

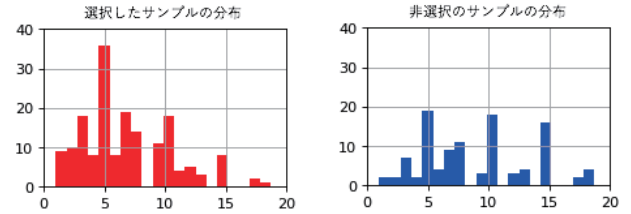
	購入した物件の床面積			
住戸の広さ	平均値	中央値	標準分散	サンプル数
重視項目に選択	71.58	71.00	9.78	179
重視項目に非選択	73.40	74.00	11.55	109



重視項目に選択したサンプルが、床面積が広い物件を購入するとは限らない

図 3: 重視項目に駅までの距離の有無と実際の徒歩分数

	購入した物件の最寄り駅までの徒歩分数			
最寄り駅までの時間	平均値	中央値	標準分散	サンプル数
重視項目に選択	7.17	7.00	4.30	179
重視項目に非選択	9.25	8.00	4.75	109



重視項目に選択したサンプルは、駅までの徒歩分数の少ない物件を購入する傾向がある。ただし、大きな傾向とは言えない。

4. ヒアリング内容を変数とした購入物件の予測精度

対面販売において、ヒアリング内容と購入物件の食い違うという課題が実在することを確認した上で、どのようなヒアリングを行えば購入物件を特定できるか検討した。具体的にはアンケートで取得した顧客それぞれの希望や状況（都道府県、家族構成、物件選びで重視する項目、購入の目的、希望の生活）を説明変数として用いて、購入した物件のスペック情報（価格、床面積、駅までの徒歩分数）を学習し予測させた。検証方法は 10-hold の交差検証による予測誤差の絶対値平均（MAE）を確認した。この時、学習に用いる説明変数は対面販売で実際にヒアリングすることを想定して以下のように分類し、それぞれの説明変数群ごとの予測精度を確認した。

変数群 A 都道府県

変数群 B 都道府県 + 家族構成

変数群 C 都道府県 + 家族構成 + 物件の重視する項目

変数群 D 都道府県 + 家族構成 + 購入目的

変数群 E 都道府県 + 家族構成 + 希望する生活や暮らし

変数群 F 変数全て

上記の変数群ごとに、予測に用いる手法として、線形回帰モデル, 回帰木 [Breiman 84], ランダムフォレスト [Breiman 01], GradientBoostingTree[Friedman 01], 多層ニューラルネットワーク [Hinton 89] を用いて実験した。目的変数である「価格, 床面積, 徒歩分数」はそれぞれ単位が違うことから、あらかじめ 0 から 1 に標準化した上で学習、予測を行なった。実装は機械学習ライブラリ [scikit-learn] を用い、調整パラメータは原則として該当ライブラリのデフォルト設定を利用した。

ただし、線形回帰モデルは L2 正則化を導入しその係数を 1 として、次元の呪いを抑制した。これは、変数群 F になるとかなりの多次元データになるがサンプル数が 330 程度しかないことから予測精度が著しく悪化することが明らかであったためである。また、多層ニューラルネットワークについては実装は [pytorch] を用い、ニューロンを 20 個の Relu を活性化関数とする 2 つの隠れ層で、各層が全て全結合で接続されたネットワークを構築した。

全体的な結果として、床面積については変数群 B の [都道府県, 家族構成] だけを用いた場合が最も予測精度が高かく、予測に用いるモデルもシンプルな線形回帰が最も良かった。床面積については、変数や予測手法を複雑にしても精度の改善は確認できなかった。一方で、価格については変数群 E の [都道府県, 家族構成, 希望の生活] を用いた GradientBoostingTree が最も精度が高く、こちらでは複雑なモデルで予測精度を改善することができた。また、最寄駅までの徒歩分数については変数群 C の [都道府県, 家族構成, 重視項目] を用いた線形モデルが最も精度が高く、こちらは単純なモデルでかつ重視項目をヒアリングすることで精度が改善することを確認できた。

この結果の詳細は表 2 でまとめた。

参考文献

[scikit-learn] Lars Buitinck, et al.: API design for machine learning software: experiences from the scikit-learn project, 2013.

表 2: 10hold の交差検定による平均絶対誤差 (予測対象の変数は 0 から 1 にスケーリング)

予測手法 / 説明変数	A) 都道府県	B) A ＋家族構成	C) B+重視項目	D) B+購入目的	E) B+希望の生活	F) 全変数
↓購入したマンションの価格の予測誤差						
01.LinearRegression	**0.108**	0.108	0.111	0.116	0.117	0.130
02.RegressionTree	**0.109**	0.118	0.144	0.146	0.134	0.167
03.RandomForest	**0.109**	0.114	0.117	0.118	0.118	0.118
04.GradientBoostingTree	0.110	0.112	0.114	0.111	***0.107**	0.112
05.MultiNNet	0.116	0.121	0.117	0.118	**0.115**	0.117
↓購入したマンションの床面積の予測誤差						
01.LinearRegression	0.110	***0.105**	0.111	0.107	0.116	0.122
02.RegressionTree	**0.111**	0.112	0.143	0.143	0.139	0.160
03.RandomForest	0.111	**0.109**	0.119	0.116	0.113	0.116
04.GradientBoostingTree	0.109	**0.107**	0.109	0.108	0.116	0.114
05.MultiNNet	0.116	0.109	**0.105**	0.106	0.110	0.109
↓購入したマンションの最寄駅からの徒歩分数の予測誤差						
01.LinearRegression	0.195	0.198	***0.191**	0.203	0.208	0.213
02.RegressionTree	**0.203**	0.215	0.255	0.279	0.244	0.246
03.RandomForest	0.200	0.217	0.209	0.224	**0.193**	0.197
04.GradientBoostingTree	0.197	0.204	**0.196**	0.203	0.203	0.199
05.MultiNNet	0.196	0.195	0.193	0.194	**0.192**	0.193

[pytorch] Paszke, et al.: API Automatic differentiation in PyTorch.(2017)

[Breiman 84] L. Breiman, J. Friedman, R. Olshen, and C. Stone, “Classification and Regression Trees”, Wadsworth, Belmont, CA, 1984.

[Breiman 01] L. Breiman, “Random Forests”, Machine Learning, 45(1), 5-32, 2001.

[Hinton 89] Hinton, Geoffrey E. “Connectionist learning procedures.” Artificial intelligence 40.1 (1989): 185-234.

[Friedman 01] J. Friedman, Greedy Function Approximation: A Gradient Boosting Machine, The Annals of Statistics, Vol. 29, No. 5, (2001).

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

ポイント制度に着目した消費者行動モデルの検証

Verification of Consumer Behavior Model Focusing on Point System

家入祐也 *1　中島悠 *2　菱山玲子 *1
Yuya Ieiri　Yuu Nakajima　Reiko Hishiyama

*1早稲田大学創造理工学研究科
Graduate School of Creative Science and Engineering, Waseda University

*2東邦大学理学部情報科学科
Faculty of Science, Department of Information Science, Toho University

Today, when the point system is sufficiently spread, it is very important to clarify how customers' behavior changes by giving points when each store makes decisions. Therefore, in this research, in order to predict consumer behavior in considering point system, we propose a consumer behavior model considering point system. Then we try to verify the validity of the proposed model by comparing the actual data with the predicted value of the proposed model, and consider the change in consumer behavior due to the difference in point granting method. As a result, it can be shown that the proposed model is valid considering the incentive effect by point granting method based on the discount rate. Furthermore, considering the incentive effect by point granting method based on the discount amount, we are able to confirm the tendency to visit stores that do not cost in time when customers use stores.

1. はじめに

競争が激しい今日の経済状況下では，顧客維持のためにロイヤルティ・プログラムの導入が求められる．中でも特に有名なロイヤルティ・プログラムの一つとして，ポイント制度が挙げられ，様々な研究 [青木 11][中川 15] でポイント制度の有効的な利用方法について検討されてきた．しかし，ポイント制度が十分に浸透している今日では，店舗間の競争の激化によって，周囲の店舗がどのようにポイントを付与しているかにより，ポイント付与による効果は大いに変化しうる．そのため，各店舗の意思決定において，ポイント付与を考慮した顧客の行動を予測することは重要であると言える．

また，ポイント制度と一口に言っても，そのポイント付与手法は実社会に則すと大きく二つ存在する．一つ目は，値引き額に基づいたポイント付与手法である．この手法では，店舗で支払った金額は関係なく，店舗で購入した事実に対してポイントが付与される．二つ目は，値引き率に基づいたポイント付与手法である．この手法では，店舗で支払った金額によってポイントが付与される．

以上のことから本研究では，はじめにポイント制度を考慮した消費者行動モデルを提案する．その後，ある商業地域における実データと提案モデルによる予測値を比較することによって，先の二つのポイント付与手法に基づいてポイント制度を布いたコミュニティにおける提案モデルの妥当性を検証する．

2. 関連研究

ポイント制度を考慮した消費者行動モデルに関する研究は様々存在する．藤田ら [藤田 11] は，会員サービスによる割引プログラムを考慮した消費者行動モデルの構築を試み，山下ら [山下 11] は，グリーンファンド施策のためにポイント制度を考慮した消費者行動モデルを構築している．また Tanaka ら [Tanaka 13] は，ポイント付与と割引という二つの戦略の特徴を明らかにするためにポイント制度を考慮した消費者行動モデルを提案している．これらの研究は，本研究と同様にポイント制度を考慮した消費者行動モデルを提案しているが，本研究は実データとの比較による消費者行動モデルの検証や，ポイント付与手法の違いによって生じる影響の分析を試みているという点でこれらの研究とは異なっている．

連絡先: 家入祐也，早稲田大学創造理工学研究科，東京都新宿区大久保 3-4-1，現在日本学術振興会特別研究員（DC1），ieyuharu@ruri.waseda.jp

3. 提案モデル

本研究では，多項ロジットモデルを用いて，各店舗のポイントを考慮した消費者行動モデルを提案する．多項ロジットモデルは，選択肢が 3 つ以上存在する状態における離散選択モデルであり，Thomas ら [Thomas 09] によって消費者 c が状況 s において店舗 o を選択する確率 $P(o,c,s)$ は以下のように定義されている．

$$P(o,c,s) = \frac{\exp(\mu \cdot V_{o,c,s})}{\sum_{o=1}^{|O|} \exp(\mu \cdot V_{o,c,s})}$$

ここで，μ はパラメータを，$V_{o,c,s}$ は状況 s 時における消費者 c の店舗 o への効用関数を，O は選択候補となる店舗 o の集合を示す．そして，状況 s を固定した時，消費者 c の店舗 o への効用関数 $V_{o,c}$ は次のように表現される．

$$V_{o,c} = \sum_{k=1}^{|K|} \beta_{k,c} \cdot X_{o,k,c}$$

ここで，k は評価指標を指し K は考慮する評価指標の集合を示す．そして，$\beta_{k,c}$ は消費者 c の評価指標 k に対する重み付けを示し，$X_{o,k,c}$ は消費者 c から見た店舗 o の評価指標 k における評価値を示している．

そして櫻井ら [櫻井 11] は，顧客がある店舗に引き付けられる力に起因する要因は，魅力的な要因と抵抗的な要因に分けられることが知られている [Huff 75] ことから，効用関数 $V_{o,c}$ に

抵抗的な要因として距離を考慮した．しかし，店舗選択のうえで抵抗的な要因は複数存在すると考えられるうえに，本研究では特に，ポイント付与による誘因効果を考慮した行動モデルが必要となる．

以上のことから，本研究における消費者 c の店舗 o への効用関数 $V_{o,c}$ を，複数の魅力的な要因による効用関数と複数の抵抗的な要因による効用関数の差で形成される基本項にポイントによって追加される魅力的な要因を足し合わせることによって定義されるものとした．そして，効用関数 $V_{o,c}$ を構成する評価指標 k のうち，魅力的な要因となりうる要素（Positive Elements）の集合を P，抵抗的な要因となりうる要素（Negative Elements）の集合を N とする．

なお本研究では，消費者 c から見た店舗 o の評価指標 k に対する 5 段階評価（1-5）を収集し，その平均値を $X_{o,k,c}$ とする．その一方で，消費者 c から見た店舗 o のポイントに対する評価 $X_{o,po,c}$ は直接的に消費者 c の利得に影響するため，5 段階による評価ではその影響を考慮するのは難しいと考えられる．そこで本研究では，$X_{o,k,c}$ における値域が $1 \leq X_{o,k,c} \leq 5$ であるのとは異なり，$X_{o,po,c}$ における値域を $1 \leq X_{o,po,c}$ として，ポイント数自体を $X_{o,po,c}$ とすることで，ポイントの影響を考慮する．

また，$\beta_{k,c}$ の導出コストを抑えるために，$\beta_{k,c}$ が，消費者 c がどれほど評価指標 k を重要視しているかを示している点に着目し，消費者へのアンケート調査の結果をもとに評価指標 k の重み付けを行う．集合 P，集合 N に属する評価指標 k のうち，消費者 c が重要だと感じている評価指標のリストを L_c とする．この時，ある評価指標 k を重要と感じている消費者 c の集合 $M_{c,k}$ は以下のように表すことが出来る．なお，ポイントを重要と感じている消費者 c の集合は $M_{c,po}$ と示すものとする．

$$M_{c,k} = \{c \mid k \in L_c\}$$

ここで，消費者 c がどれほど評価指標 k を重要視しているかを示す重み付け $W_{c,k}$ を以下のように定義し，これが $\beta_{k,c}$ と同等の役割を果たすとする．

$$W_{c,k} = \begin{cases} \frac{|M_{c,k}|}{\sum_{k \in P} |M_{c,k}| + |M_{c,po}|} & (\text{if } k \in P) \\ \\ \frac{|M_{c,k}|}{\sum_{k \in N} |M_{c,k}|} & (\text{if } k \in N) \end{cases}$$

また，消費者 c がどれほどポイントを重要視しているかを示す重み付け $W_{c,po}$ を以下のように定義する．

$$W_{c,po} = \frac{|M_{c,po}|}{\sum_{k \in P} |M_{c,k}| + |M_{c,po}|}$$

そして，効用関数 $V_{o,c}$ における基本項を $Base_{o,c}$ とし，これを以下のように定義する．

$$Base_{o,c} = \sum_{k \in P} W_{c,k} \cdot X_{o,k,c} - \sum_{k \in N} W_{c,k} \cdot X_{o,k,c}$$

以上より本研究では，ポイント制度を考慮した消費者行動モデルとして以下のモデル（以降，提案モデルとする）を利用する．

$$P(o,c,s) = \frac{\exp(\mu \cdot V_{o,c,s})}{\sum_{o=1}^{|O|} \exp(\mu \cdot V_{o,c,s})}$$

$$V_{o,c} = Base_{o,c} + W_{c,po} \cdot X_{o,po,c}$$

4. 提案モデル検証の準備

本節では，提案モデルにおける妥当性の検証のために収集したデータについて具体的に説明する．なお，提案モデルにおける消費者の店舗選択確率は，店舗 o，消費者 c，状況 s に依存する．そこで本研究では，消費者 c を固定するために同属性の消費者を，状況 s を固定するために，分析対象とする店舗 o を同性質の店舗 [*1] とし，以降で扱う消費者の店舗選択確率を示す数理モデルは，提案モデルのうち，消費者 c，状況 s を固定した次のようなものとする．

$$P(o) = \frac{\exp(\mu \cdot V_o)}{\sum_{o=1}^{|O|} \exp(\mu \cdot V_o)}$$

$$V_o = Base_o + W_{po} \cdot X_{o,po}$$

$$Base_o = \sum_{k \in P} W_k \cdot X_{o,k} - \sum_{k \in N} W_k \cdot X_{o,k}$$

この時，基本項のみから成る消費者行動モデルによるシミュレーションによって，ポイント制度による誘因効果がない場合の消費者行動を予測でき，基本項にポイント部分を追加した消費者行動モデルによるシミュレーションによって，ポイント制度による誘因効果を考慮した場合の消費者行動が再現できる．

また本研究では，各店舗の店舗選択確率を決定するための評価指標 k を Ieiri ら [Ieiri 18] に基づいて 6 つ選定した．以下に 6 つの評価要素について記す．なお，$P = \{k \mid k = 1,2,3\}$，$N = \{k \mid k = 4,5,6\}$ とする．

$k = 1$： なじみ具合・気楽さ

$k = 2$： 立地条件の良さ

$k = 3$： 店舗ジャンルの入りやすさ

$k = 4$： 価格の高さの妥当さ

$k = 5$： 店舗内の様子の分かりにくさ

$k = 6$： 予測される入店後の居心地の悪さ

本研究で対象とする店舗は，早稲田大学理工学術院に隣接し，飲食物を販売している 14 店舗とし，対象とする消費者属性を大学生とする．そして，大学生 45 人へのアンケート調査によって W_k と W_{po} を導出し，大学生 17 人によるフィールド調査によって $X_{o,k}$ を導出した．

さらに本研究では，提案モデルの妥当性検証のために，予測値と実データの比較を行う．そこで，先に述べた本研究で対象とする 14 店舗を含めた商業地域で大学生を中心とする大学関係者 [*2] をターゲットとして実施された地域活性化イベント「MyShop 発見ツアー [Ieiri 18]」で収集された実データを利用する．

本イベントは，各店舗で何かサービスを受けると一店舗当たり一回ポイントを獲得することができ，50 ポイントためるごとにイベント参加店舗で利用できる 500 円分の金券と交換が可能である，というものであった．なお，各店舗の V_o が均

∗1 同性質の店舗とは，飲食物を販売している店舗，洋服を売っている店舗，など同じ業種業態の店舗を指す．

∗2 イベントの広報にあたり大学内でチラシの配布やポスターの掲示を行った．そのため，大学生がイベント参加者の中心と考えられるが，大学の職員等がイベントに参加した可能性もわずかに存在するため，「大学生を中心とする大学関係者」という表現とした．

表 1: イベントの実施結果

店舗	金券利用枚数（枚）	イベント期間中の被訪問回数（回）
店舗 1	3	0
店舗 2	15	3
店舗 3	18	8
店舗 4	9	4
店舗 5	0	0
店舗 6	0	2
店舗 7	4	14
店舗 8	27	0
店舗 9	7	0
店舗 10	65	1
店舗 11	32	0
店舗 12	0	0
店舗 13	9	12
店舗 14	97	8
総計	286	52

一になるように，$X_{o,po}$ を定め，店舗 o で実際に獲得できるポイント数は，イベントを簡単にするために $X_{o,po}$ に最も近い 5 以上の 5 の倍数とした．この時，各店舗で支払った金額を考慮せずに獲得ポイント数が決まっているため，本イベントにおけるポイント付与手法は，値引き額に基づいたポイント付与手法であると言える．

また，本イベント終了後，利用した街歩きアプリのログ収集によって，イベント参加者の各店舗への総被訪問回数を集計した．イベント参加者の各イベント参加店舗での総購買回数は 65 回，イベントで配布した金券の総利用枚数は 312 枚であった．中でも，本研究で対象としている 14 店舗では，イベント期間中におけるイベント参加者の被訪問回数は 52 回，金券の総利用枚数は 286 枚であった．本イベントの結果を表 1 にまとめる．

ここで，値引き額に基づいたポイントを考慮した場合の実データは，ポイントを考慮している時，すなわちイベント期間中のイベント参加者による被訪問回数であり，ポイントを考慮しない場合の実データは，各店舗における金券利用枚数とみなすことができる．そのため，基本項のみを考慮した消費者行動モデルを用いたシミュレーション値と各店舗における金券利用枚数を比較する．そして，値引き額に基づいたポイントを考慮した消費者行動モデルを用いたシミュレーション値や，このイベントにおいて各店舗で獲得できるポイント数を値引き率に基づいたポイントに変換したデータをもとに導出した消費者行動モデルを用いたシミュレーション値と，イベント期間中のイベント参加者による被訪問回数を比較することによって，提案モデルの妥当性について検証する．

5. シミュレーション実験と実データとの比較

本シミュレーション実験では，提案モデルを消費者の店舗選択行動を表現する数理モデルとし，消費者の店舗選択は一回限りとする．また，対象とする店舗や，W_k，$X_{o,k}$ の値は，4. 章で導出した値とし，本シミュレーション実験では，提案モデルのパラメータ μ を 0 から 1 まで 0.05 間隔で変化させ，それぞれ試行を 30 回繰り返し，その 30 回の試行それぞれにおける集客数の平均値を評価する集客数として実データとの比較を行う．

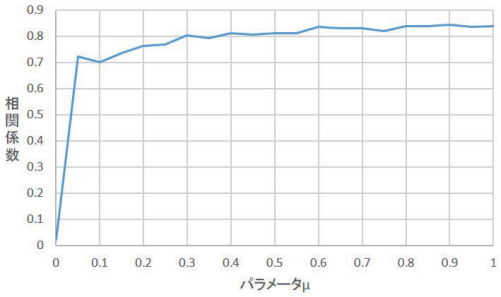


図 1: パラメータ μ を変化させたときの相関係数の変化（ポイントを考慮しない場合）

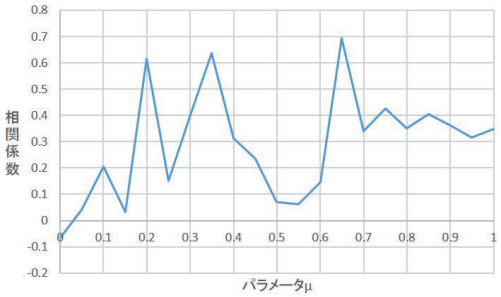


図 2: パラメータ μ を変化させたときの相関係数の変化（値引き額に基づいたポイントを考慮した場合）

ポイントを考慮しない場合，各店舗における金券利用枚数を実データとし，シミュレーション値と比較する．対象とする 14 店舗において，金券の総利用枚数は 286 枚であったことから，本シミュレーション実験では消費者の数 $n = 286$ とする．パラメータ μ を 0 から 1 まで 0.05 間隔で変化させたとき，ピアソンの積率相関係数は図 1 のように変化した．ここで，$\mu = 0.9$ のとき，相関係数が最大で 0.84 となり，相関係数の有意性の検定を行ったところ，1%の水準で有意であることが確認できた．以上より，ポイント付与による誘因効果がない場合の提案モデルは妥当であることが明らかになった．

次に，値引き額に基づいたポイントを付与した場合について，イベント期間中のイベント参加者による被訪問回数を実データとし，シミュレーション値と比較する．対象とする 14 店舗において，イベント期間中のイベント参加者による被訪問回数は 52 回であったことから，本シミュレーション実験では消費者の数 $n = 52$ とする．パラメータ μ を 0 から 1 まで 0.05 間隔で変化させたとき，ピアソンの積率相関係数は図 2 のように変化した．これより，相関係数は μ の変化によって大きく変化しており，シミュレーション値と実データにはほとんど相関関係がみられないことが分かる．これより，値引き額に基づいたポイント付与による誘因効果がある場合，提案モデルは妥当とは言えないことが確認できた．

そこで，この場合において消費者はどのような店舗を選択していたかについて確認する．イベント参加者の各店舗の被訪問回数を変数として，分析対象の 14 店舗に対してウォード法を用いて階層的クラスタリングを行った．その結果は図 3 のようである．なお，各番号は店舗番号を示している．

表 1 と図 3 より，値引き額に基づいたポイントを付与した場合，イベント参加者の訪問は店舗 3,7,13,14 に集中したこと

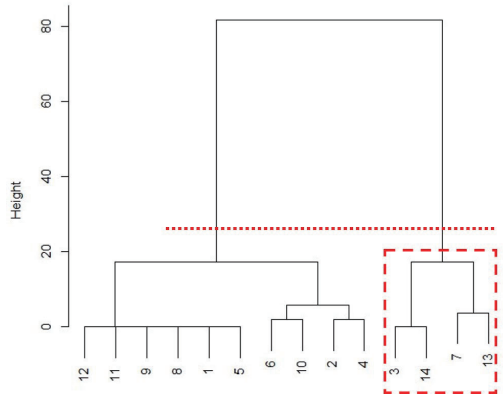


図 3: 被訪問回数に着目したクラスタリング分析の結果

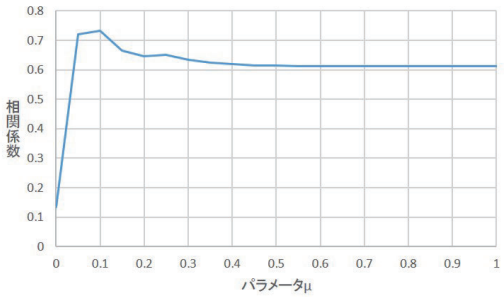


図 4: パラメータ μ を変化させたときの相関係数の変化（値引き率に基づいたポイントを考慮した場合）

がうかがわれる．そこで，これらの店舗業態に着目し，店舗利用に際して店内での飲食が必要かどうか，について確認した．この時，これら 14 店舗のうち店舗 3,7,13,14 のみが店内での飲食を必要としない店であり，これはすなわち，ポイント獲得に時間的コストをかける必要のないことを示している．以上のことから，値引き額に基づいたポイント付与による誘因効果を持つ商業地域コミュニティの場合の消費者行動では，ポイント獲得に際して時間的コストのかからない店舗への訪問がよく見られるということが明らかになった．

最後に，値引き率に基づいたポイントを付与した場合について，イベント期間中のイベント参加者による被訪問回数を実データとし，シミュレーション値と比較する．対象としている 14 店舗において，イベント期間中のイベント参加者による被訪問回数は 52 回であったことから，本シミュレーション実験では消費者の数 $n = 52$ とする．パラメータ μ を 0 から 1 まで 0.05 間隔で変化させたとき，ピアソンの積率相関係数は図 4 のように変化した．ここで，$\mu = 0.1$ のとき，相関係数が最大で 0.73 となり，相関係数の有意性の検定を行ったところ，1%の水準で有意であることが確認できた．以上より，値引き率に基づいたポイント付与による誘因効果がある場合，提案モデルは妥当であることが示された．

6. まとめと今後の課題

本研究では，ポイント制度を考慮した消費者行動モデルを提案した．そして，シミュレーション値と実社会で収集した実データとの比較を行うことで，提案モデルの妥当性を検証するとともに，ポイント付与手法の違いによって生じる消費者行動への影響について分析した．これによって，提案モデルは値引き率に基づいたポイント付与による誘因効果を考慮した時に妥当であることが示されるとともに，値引き額に基づいたポイント付与による誘因効果を考慮した場合には，店舗利用に際して時間的コストがかからない店舗へ訪問する傾向が確認できた．今後の課題として，店舗利用時間などを考慮したモデルの構築により，値引き額に基づいたポイント付与による誘因効果を持つ場合の消費者行動予測を試みることが挙げられる．

謝辞 本研究は，科学技術融合振興財団（FOST）の平成 29 年度補助金助成による成果であるとともに，早稲田大学特定課題の支援を受けた．また，本実験は，新宿区による平成 29 年度商店街補助事業の一環として実施した．本実験の実施にあたりご協力いただいた新宿区文化観光産業部産業振興課の皆様や，商店街の皆様に感謝いたします．

参考文献

[青木 11] 青木 章通，佐々木 郁子：小売業におけるプロモーション手法の検討，メルコ管理会計研究，Vol.4, No.2, pp.3-16 (2011).

[中川 15] 中川 宏道：ポイントと値引きはどちらが得か?: ポイントに関するメンタル・アカウンティング理論の検証，行動経済学，Vol.8, pp.16-29 (2015).

[藤田 11] 藤田 宏介，西野 成昭， 佐藤 勇気，上田 完次，淺間 一：エージェントシミュレーションを用いた会員サービスによる割引プログラムの検証，人工知能学会論文誌，Vol.26, No.1, pp.190-198 (2011).

[山下 11] 山下 賀奈子，近藤 光男，笹山 和延：グリーンファンド施策に対する消費者行動モデルと効果分析，都市計画論文集，Vol.37, pp.679-684 (2002).

[Tanaka 13] Tanaka, Y., Yamada, T., Yamamoto, G., Yoshikawa, A. and Terano, T.: Points or Discount for Better Retailer Services, *7th International Conference on Knowledge Management in Organizations: Service and Cloud Computing. Advances in Intelligent Systems and Computing,* Vol.172, pp.481-491 (2013).

[Thomas 09] Thomas, R. and Teller, C.: Store format choice and shopping trip types, *International Journal of Retail and Distribution Management,* Vol.37, No.8, pp.695-710 (2009).

[櫻井 11] 櫻井 雄大，宮崎 慎也，藤井 明：多項ロジットモデルを用いた商業集積地に対する選択行動モデルの構築と商圏の分析，都市計画論文集，Vol.46, No.3, pp.427-432 (2011).

[Huff 75] Huff, D. and Batsell, R.: Conceptual and Operational Problems With Market Share Models of Consumer Spatial Behavior, *Advances in Consumer Research,* Vol.2, pp.165-172 (1975).

[Ieiri 18] Ieiri, Y., Hishiyama, R., Nakajima, Y.: Walk Rally Application for Revitalizing Shopping Areas, *Proc. The Ninth International Symposium on Information and Communication Technology,* pp.344-350, ACM, Danang, Vietnam. (2018).

[2N3-J-13] AI application: medical diagnosis

Chair:Koji Morikawa Reviewer:Yoshikuni Sato

Wed. Jun 5, 2019 1:20 PM - 2:20 PM Room N (Front-right room of 1F Exhibition hall)

[2N3-J-13-01] Denoising autoencoder-based modification method for RRI data with premature atrial contraction

○Shota Miyatani[1], Koichi Fujiwara[2], Manabu Kano[1] （1. Kyoto University, 2. Nagoya University）

1:20 PM - 1:40 PM

[2N3-J-13-02] Character-level Text Generations with Attention for Chest X-ray Diagnosis

○Kenya Sakka[1], Kotaro Nakayama[1,2], Nisei Kimura[1], Taiki Inoue[1], Ryohei Yamaguchi[1], Yoshimasa Kawazoe[1], Kazuhiko Ohe[1], Yutaka Matsuo[1] （1. The University of Tokyo, 2. NABLAS Inc.）

1:40 PM - 2:00 PM

[2N3-J-13-03] Detecting patient mix-up on blood samples with machine learning

○Tomohiro Mitani[1], Shunsuke Doi[2], Shinichiroh Yokota[2], Takeshi Imai[1], Kazuhiko Ohe[1,2] （1. Graduate School of Medicine, The University of Tokyo, 2. The University of Tokyo Hospital）

2:00 PM - 2:20 PM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

Denoising autoencoder に基づく 心房期外収縮を含むRR間隔データ補正

Denoising autoencoder-based modification method for RRI data with premature atrial contraction

宮谷将太 *1　藤原幸一 *2　加納学 *1
Shota MIYATANI　Koichi FUJIWARA　Manabu KANO

*1京都大学 Kyoto University　*2名古屋大学 Nagoya University

The fluctuation of an RR interval (RRI) on an electrocardiogram (ECG) is called heart rate variability (HRV). Since HRV reflects the activities of the autonomous nervous system, HRV analysis has been used for health monitoring systems. However, the performance of health monitoring systems using HRV features is easily deteriorated by arrhythmias. The present work focuses on premature atrial contraction (PAC) that many healthy people have. To modify RRI data with PAC, the present work proposes a new method based on a denoising autoencoder (DAE), referred to as DAE-based RRI modification (DAE-RM). The proposed method aims to correct the disturbed RRI data by regarding PAC as artifacts. The performance of DAE-RM was evaluated by its application to RRI data which contains artificial PAC (PAC-RRI). The result showed that DAE-RM successfully modified PAC-RRI data. The root means squared error (RMSE) of the modified RRI was improved by 27.4% from the PAC-RRI. The proposed DAE-RM has potential for realizing precise health monitoring systems which use HRV analysis.

1. はじめに

心電図 (electrocardiogram; ECG) 波形の最も高いピークを R 波と呼び，隣接する R 波と R 波の間隔を RR 間隔 (RR interval; RRI) と呼ぶ．RRI が時間的に変動する現象を心拍変動 (heart rate variability; HRV) と呼び，HRV は自律神経活動を反映するとされる．そのため，HRV はストレスや眠気を評価する指標として用いられてきた．また，HRV は循環器疾患でも変化するため，循環器疾患の診断にも用いられている [1]．近年，容易に RRI を測定できるウェアラブルデバイスが開発された [2]．このようなウェアラブルデバイスに使用を前提としたてんかん発作の事前予知 [3] や，運転時の眠気検出 [4] などのヘルスモニタリングシステムが提案されている．

アーチファクトが RRI データに混入した場合，HRV 指標が大きく変化してヘルスモニタリング性能が低下する．アーチファクトには心臓由来，または R 波検出アルゴリズム由来のものがある．前者は不整脈などによるアーチファクトで，後者は ECG における R 波を検出できないことによるアーチファクトである．ヘルスモニタリングシステムを実現するためには，HRV 解析を行う前にこれらのアーチファクトを適切に補正する必要がある．

このような背景から，健常者にも起こりうる珍しくない不整脈である心室期外収縮 (premature ventricular contraction; PVC) を対象とする手法が提案されている [5]．本研究では PVC と同様に健常者にも生じうる心房期外収縮 (premature atrial contraction; PAC) を対象とした [6]．PAC などの不整脈が含まれる RRI データに対して，LS ピリオドグラムを用いて HRV 指標の周波数領域指標を補正する手法は提案されている [7]．一方，HRV 解析を用いた多くのアプリケーションでは HRV 指標の時間領域指標を併用しているため，この手法のみでアーチファクトの影響を除去し，適切な HRV 解析を行うことはできない．本研究では PAC を含む RRI データを補正する手法を提案する．提案手法はノイズ除去を目的とするニューラルネットである denoising autoencoder (DAE) を用いており，本手法を DAE-based RRI modification (DAE-RM) と呼ぶ．本稿ではオープンデータとして公開されている RRI データに人工的な PAC アーチファクトを混入させ，DAE-RM を適用して補正性能を評価する．

連絡先: 藤原幸一，名古屋大学工学研究科，〒 464-8602 名古屋市千種区不老町，fujiwara.koichi@material.nagoya-u.ac.jp

2. 心拍変動解析と心房期外収縮

HRV 解析にはさまざまな指標が提案されているが，本節では広く用いられている時間領域指標と周波数領域指標について説明する [1]．また，PAC について説明し，PAC が HRV 解析に与える影響について述べる．

2.1 時間領域指標

時間領域指標は，被験者から取得した RRI データから直接計算できる．

- **meanNN :** RRI の平均値.
- **SDNN :** RRI の標準偏差.
- **Total Power (TP) :** RRI の分散.
- **RMSSD:** 隣接する RRI の差の 2 乗平均平方根.
- **NN50 :** 隣接する RRI の差が 50 ms を超えた回数.

2.2 周波数領域指標

RRI データは等間隔にサンプリングされていないため，周波数領域指標を計算する前にリサンプリングする必要がある．パワースペクトル密度 (power spectrum density; PSD) はリサンプリング後の RRI データより自己回帰モデルもしくは Fourier 変換を用いて計算できる．

- **LF :** PSD の低周波 (0.04-0.15 Hz) のパワー.
- **HF :** PSD の高周波 (0.15-0.40 Hz) のパワー.
- **LF/HF :** HF に対する LF の比.

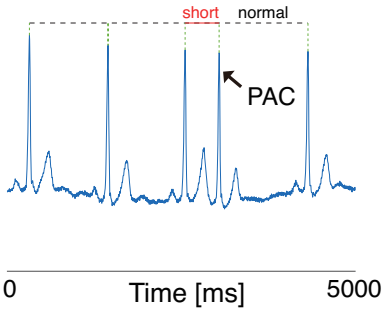


図 1: PAC を含む ECG 波形

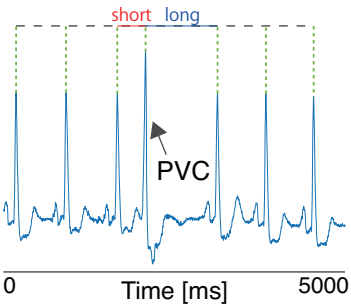


図 2: PVC を含む ECG 波形

2.3 心房期外収縮

心臓の正常な拍動リズムは洞結節の興奮によって生じるが，洞結節以外での興奮が本来の収縮に先行することがある．この現象は期外収縮と呼ばれる不整脈の一種で，特に心房で興奮が生じる期外収縮を PAC と呼ぶ [8]．PAC を含む ECG 波形を図 1 に示す．この図から，PAC が生じたことによって RRI が変化していることがわかる．

次に，PVC を含む ECG 波形を図 2 に示す．図 1， 2 を比較すると，どちらの場合でも RRI が変化しているとわかる．PVC では発生直後の RRI が比較的大きくなっているのに対し，PAC では発生直後の RRI は通常と変わらないことがわかる．

David らは無作為に選ばれた 50 歳以上の被験者 1742 名の ECG をホルター心電図で測定したところ，1 度も PAC を起こさなかった被験者は 18 名であったと報告している [6]．また，同論文では 1 時間あたりに起きた PAC の回数は年齢とともに増加することも報告されている．

PAC が生じると RRI データに大きな変動が生じ，RRI から計算される HRV も大きな影響を受ける．図 3 に PAC アーチファクトを混入させた RRI データ (PAC-RRI) から計算された SDNN と LF/HF を示す．青線と赤線はそれぞれ，元の RRI データから計算された指標と PAC-RRI から計算された指標であることを表し，緑線は PAC アーチファクトが混入したタイミングを表す．この図から，PAC アーチファクトを加えた直後から HRV 指標に変化が生じていることがわかる．PAC によって大きく変化した HRV 指標を用いて解析を行うと，HRV 解析に基づくアプリケーションの性能は大きく低下する．

3. RRI 補正

本節では，PAC-RRI を補正するアルゴリズムについて述べる．提案するアルゴリズムでは，ノイズ除去を目的とするニューラルネットの denoising autoencoder (DAE) を用いる．

3.1 Denoising autoencoder

Autoencoder (AE) はニューラルネットを用いた次元圧縮，特徴抽出手法である [9]．AE では出力が入力と等しくなるように学習を行い，出力を再現できる中間層を獲得する．このとき，中間層と出力層において活性化関数を恒等写像とすると，AE は代表的な次元圧縮手法である主成分分析 (principal component analysis; PCA) と一致する．

DAE は AE と同じ構造を持つニューラルネットである．DAE はノイズを加えたデータを入力とし，ノイズを加える前の入力と同様の出力を得るよう学習を行う [10]．このように学習を行うことから，DAE はノイズを除去する能力があるとされている．

3.2 DAE-based RRI modification

PAC が混入したことによる RRI データの変化はアーチファクトとみなすことができる．そのため，DAE によって PAC アーチファクトを除去できると考えられる．この DAE に基づく手法を DAE-based RRI modification (DAE-RM) と呼ぶ．

提案する DAE-RM のアルゴリズムを Algorithm 1 に示す．ここで，DAE は RRI 補正を行う前にすでに学習済みであるとする．ステップ 3 で first-in-first-out (FIFO) にて，新たに測定された RRI をバッファに記録する．RRI データに PAC が検出された場合，ステップ 5-16 で DAE による補正を行なう．ステップ 5-7 にて，DAE によって補正する RRI の部分データ $\boldsymbol{x}_s$ を構築する．ここで T は PAC によって変化した RRI の要素の数を表しており，$T = 2$ のとき単発性 PAC を表す．また，P は DAE による補正幅を表すパラメータであり，T 拍の前後 P 拍を DAE によって補正する．これは，DAE で補正を行うために PAC 前後の RRI データが必要なためである．ステップ 9 で DAE 適用前に $\boldsymbol{x}_s$ の中心化を行い，ステップ 11 で復元している．$\boldsymbol{x}_s$ の時間合計が補正の前後で変化しないようにするため，補正による時間合計の変化を補う必要がある．そこでステップ 12 にて補正前後の要素の合計値を計算し，ステップ 15 にて $\boldsymbol{x}_s$ 以降の D 個の要素に差分を足し合わせることにより埋め合わせを行う．

4. ケーススタディ

本節では，PAC アーチファクトを加えた実際の RRI データに対し，DAE-RM を適用した結果を示す．

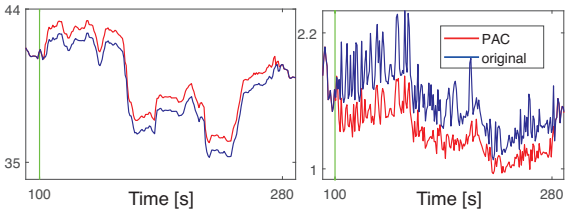


図 3: PAC が HRV 指標に与える影響: SDNN(左図), LF/HF(右図)

Algorithm 1 DAE-RM

while do
  Collect the newly measured tth RRI x_t.
  Store x_t to the buffer in the FIFO manner.
  if PAC detection **then**
    Wait the next t+1th to t+T+P−1th RRI $x_{t+1}, \cdots, x_{t+T-1}, \cdots, x_{t+T+P-1}$.
    Extract the previous P RRI $x_{t-P}, \cdots, x_{t-1}$ from the buffer.
    Construct the RRI subsequence to be modified: $\boldsymbol{x}_s = [x_{t-P}, \cdots, x_t, \cdots, x_{t+T-1}, \cdots, x_{t+T+P-1}]$.
    Calculate the mean of $\boldsymbol{x}_s$, $\bar{\boldsymbol{x}}_s$.
    $\boldsymbol{x}_s = \boldsymbol{x}_s - \bar{\boldsymbol{x}}_s$.
    Get the modified RRI subsequence $\hat{\boldsymbol{x}}_s$ by inputting $\boldsymbol{x}_s$ to the trained DAE.
    $\hat{\boldsymbol{x}}_s = \hat{\boldsymbol{x}}_s + \bar{\boldsymbol{x}}_s$.
    $d = \sum \hat{\boldsymbol{x}}_s - \sum \boldsymbol{x}_s$.
    Replace $\boldsymbol{x}_s$ to $\hat{\boldsymbol{x}}_s$.
    Construct the RRI subsequence to be compensated: $\boldsymbol{x}_D = [x_{t+T+P}, \cdots, x_{t+T+P+D-1}]$.
    $\boldsymbol{x}_D = \boldsymbol{x}_D - (d/D)\mathbf{1}_D$.
  else
    Wait until the next RRI data x_{t+1} is measured.
  end if
end while

4.1 データセット

ケーススタディには PhysioNet の正常洞調律データベース (normal sinus rhythm database; NSRDB) を用いた [11]. NSRDB には成人 18 名の ECG と RRI のデータが含まれており，これらを被験者 A - R とする．被験者は 26 歳から 45 歳までの 5 人の男性（平均 33.8，標準偏差 7.7）と，20 歳から 50 歳までの 13 名の女性（平均 35.8，標準偏差 7.7）で構成され，その全員が循環器疾患をもたないと診断されている．データベースにある RRI データのいくつかには明らかなアーチファクトが含まれており，これらのアーチファクトは DAE-RM の性能を評価する妨げとなるため，これらを除去した．その結果，18 名の被験者から RRI データのエピソードが 166 個作成され，エピソードの合計時間は 375 時間となった．PAC アーチファクトはエピソードのランダムな位置に加え，本ケーススタディではその位置を既知であるものとした．

4.2 DAE の学習

DAE の学習には被験者 A から得られたエピソードを用いた．中間層と出力層の活性化関数にはそれぞれ，Rectified Linear Unit (ReLU) と恒等写像を用いた．DAE のパラメータは被験者 B-F から得られたエピソードを用いて決定し，DAE によって補正する要素の数が 4，中間層のユニット数が 2 となった．つまり，Algorithm 1 において $T = 2$，$P = 1$ となった．

4.3 RRI 補正

被験者 G-R から得られたすべてのエピソードを用いて DAE-RM の性能を検証した．なお，PAC-RRI データの作成と DAE-RM による補正は，加えたアーチファクトの位置に補正性能が依存することを防ぐため，10 回の試行を行ってその平均値を結果としている．図 4 は DAE-RM を被験者 M のあるエピソードに対して適用した結果である．青線，赤線，緑線はそれぞれ，正常 RRI データ，PAC-RRI データ，PAC-RRI データを DAE-RM によって補正した RRI データを表す．この図から，DAE-RM による補正後の RRI データが元の RRI データと非常に近い値をとっていることがわかる．元の RRI データと PAC-RRI データの平方平均二乗誤差 (root mean squared error; RMSE) に対する，元の RRI データと補正後の RRI データの RMSE の改善率は 27.4 %であった．また，HRV 指標における RMSE の改善率は，meanNN: 0.1%, SDNN: 24.8%, TP: 22.7%, RMSSD: 70.8%, NN50: 34.0%, LF: 22.7%, HF: 28.2%, LF/HF: 30.0%となった．この結果から，PAC が HRV 解析に与える影響を DAE-RM によって抑えられていることがわかる．

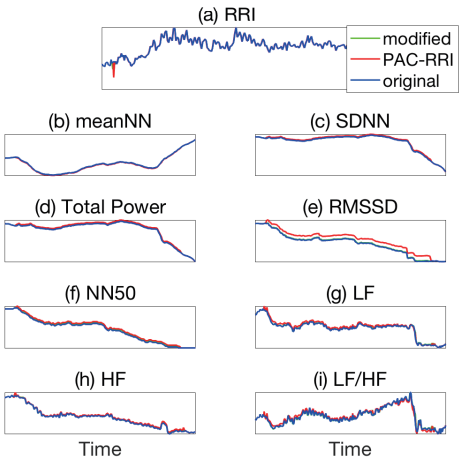


図 4: 被験者 M の補正前後の HRV 指標

4.4 考察

DAE による RRI 補正の性能を他の回帰手法と比較する．今回は，partial least squares (PLS) と，locally weighted PLS (LW-PLS) を比較の対象とした．PLS は広く使われている線形回帰手法であり，入力変数より少ない潜在変数を用いることで多重共線性の問題を回避できる [12]．LW-PLS は PLS を拡張した手法で，すでに得られているデータセットのサンプルとクエリの類似度を重みとして，クエリにおける入出力関係を最もよく表現するサンプルを用いて局所的な PLS モデルを構築する [13].

DAE-RM，PLS，LW-PLS を用いて RRI 補正を行った結果を図 5 に示す．縦軸には RRI と HRV の RMSE の改善率を用いた．提案手法を PVC に適用した際には DAE が最も高い精度であったが，PAC に適用した場合，PLS が最も良い性能であることがわかる [5]．この要因は PAC と PVC によって影響を受ける RRI の要素数であると考えられる．PVC では 2 要素が変化するのに対し，PAC では 1 要素しか変化しないため，DAE が 1 要素のみの変化の特徴をうまく学習できなかった可能性がある．

5. まとめ

本研究では，DAE を用いた PAC を含む RRI データの補正手法を提案した．PVC を含む RRI データに提案手法を適用した際には DAE が最も高い精度であったが [5]，PAC に対しては PLS が最も高い精度であった．

実用化に向けて考えると，PAC と PVC のそれぞれに適合

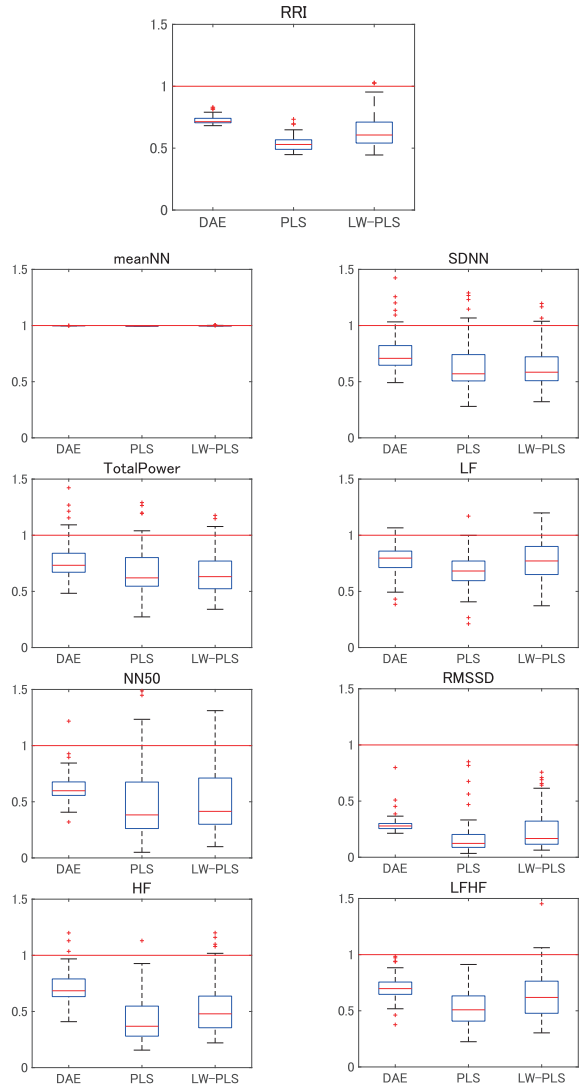


図 5: RRI と HRV 指標の RMSE 改善率

した DAE を作成しているため，補正前にこれらの不整脈の分類を行う必要がある．不整脈を識別するアルゴリズムは様々な論文で提案されているが，これらはオフラインでの解析を前提としているため，ウェアラブルデバイスでのリアルタイム解析においての使用を意図しておらず，今後検討を進める必要がある．

今後は，PAC や PVC，R 波抜けの検出と分類を行い，それぞれを適した手法で補正することにより RRI データに混入したアーチファクトを統合的に扱う手法の提案を目指す．

謝辞

本研究の一部は，科研費基盤 A #17H00872，AMED 先端計測プログラム #171122，JST さきがけ #JPMJPR1859，セコム科学技術振興財団，住友電工グループ社会貢献基金から助成を受けて実施された．

参考文献

[1] Task Force of the European Society of Cardiology and the North American Society of Pacing and Electrophysiology. Heart rate variability: Standards of measurement, physiological interpretation, and clinical use. *Circulation*, Vol. 80, pp. 1043–1065, 1996.

[2] T. Yamakawa, et al. Development of a wearable hrv telemetry system to be operated by non-experts in daily life. In *2013 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference*, pp. 1–4, oct 2013.

[3] K. Fujiwara, et al. Epileptic seizure prediction based on multivariate statistical process control of heart rate variability features. *IEEE Transactions on Biomedical Engineering*, Vol. 63, No. 6, pp. 1321–1332, jun 2016.

[4] E. Abe, et al. Development of drowsiness detection method by integrating heart rate variability analysis and multivariate statistical process control. *SICE Journal of Control, Measurement, and System Integration*, Vol. 9, No. 1, pp. 10–17, 2016.

[5] S. Miyatani, et al. Deniosing autoencoder-based modification of rri data with premature ventricular contraction for precise heart rate variability analysis. In *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp. 5018–5021, July 2018.

[6] C. David, et al. Premature atrial contractions in the general population. *Circulation*, Vol. 126, No. 19, pp. 2302–2308, 2012.

[7] J. Mateo and P. Laguna. Analysis of heart rate variability in the presence of ectopic beats using the heart timing signal. *IEEE Transactions on Biomedical Engineering*, Vol. 50, No. 3, pp. 334–343, March 2003.

[8] F. C. Messineo. Ventricular ectopic activity: Prevalence and risk. *The American Journal of Cardiology*, Vol. 64, No. 20, pp. J53 – J56, 1989.

[9] P. Baldi and K. Hornik. Neural networks and principal component analysis: Learning from examples without local minima. *Neural Networks*, Vol. 2, No. 1, pp. 53 – 58, 1989.

[10] P. Vincent, et al. Extracting and composing robust features with denoising autoencoders. In *Proceedings of the 25th International Conference on Machine Learning*, ICML '08, pp. 1096–1103, New York, NY, USA, 2008. ACM.

[11] M. Costa, et al. Physionet: an nih research resource for complex signals. *Journal of Electrocardiology*, Vol. 36, pp. 139 – 144, 2003.

[12] P. Geladi and B. R. Kowalski. Partial least-squares regression: a tutorial. *Analytica Chimica Acta*, Vol. 185, pp. 1 – 17, 1986.

[13] S. Kim, et al. Development of soft-sensor using locally weighted pls with adaptive similarity measure. *Chemometrics and Intelligent Laboratory Systems*, Vol. 124, pp. 43 – 49, 2013.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

文字単位のアテンション機構を用いた胸部 X 線写真の所見テキスト生成手法

Character-level Text Generations with Attention for Chest X-ray Diagnosis

作花 健也[*1] Sakka Kenya
中山 浩太郎[*2, 3] Kotaro Nakayama
木村 仁星[*2] Nisei Kimura
井上 大輝[*4] Taiki Inoue
山口 亮平[*5] Ryohei Yamaguchi
河添 悦昌[*5] Yoshimasa Kawazoea
大江和彦[*5] Kazuhiko Ohe
松尾豊[*2] Yutaka Matsuo

[*1] 東京大学大学院新領域創成科学研究科 Graduate School of Frontier Sciences, The University of Tokyo
[*2] 東京大学大学院工学系研究科 Graduate School of Engineering, The University of Tokyo
[*3] NABLAS 株式会社 NABLAS Inc.
[*4] 東京大学大学院薬学系研究科 Graduate School pf Pharmaceutical Sciences, The University of Tokyo
[*5] 東京大学大学院医学系研究科 Graduate School of Medicine, The University of Tokyo
[*6] 東京大学附属病院 The University of Tokyo Hospital

Medical images are widely used in clinical practice for diagnosis and treatment, and much time is spent on diagnosis. Therefore, research to automatically generate cases from medical images has been actively conducted in recent years. However, it is difficult to judge the case as a classification problem because there are orthographic variants in the case written in the medical certificate.

In this paper, we aimed to automatically generate character-level cases in order to cope with orthographic variants on chest X-ray images. In addition, the interpretability of the result was improved by introducing an attention mechanism. As a result, it was confirmed cases with features such as position information were generated, and the effectiveness of character-level approach was shown in text generation of medical images.

1. はじめに

医療画像は，診断および治療のために広く利用されている．しかし，医療画像を読影するためには高い専門性が必要であるため，放射線科医師などの専門家でも経験によって読影結果に差が出てしまう．具体的には，胸部 X 線写真を正しく読影するためには以下の 5 つのスキルが求められている [Delrue 11]. (1) 通常時の胸部の解剖学的構造，および胸部疾患の基本的な生理学についての知識を持っていること．(2) 経験的に得られた固定的なパターンを通して胸部 X 線写真を分析すること．(3) 経時的な変化を考慮して評価を行うこと．(4) 患者の臨床症状および病歴に関する知識を持っていること．(5) 他の診断結果(臨床検査の結果[血液，痰]，心電図，呼吸機能調査)との相関に関する知識を持っていること．このような高い専門性が必要なことに加えて，胸部 X 線写真は患者の状況や重要な情報を把握するための方法として最も普及している方法の一つであり，救急医療や健康診断など様々な場面で日々大量の撮影が行われている．この結果，放射線科医師を含む医療従事者へ大きな負担が発生しており，その解決が求められていた．そのため，クラス分類問題として所見を自動で検出する研究が盛んに行われている [Rajpurkar 17]. さらに，ここ1～2年では画像から直接，所見のテキスト情報を出力する end-to-end のモデルなども提案されてはじめている [Jing 18].

所見は，専門家により表記方法に揺らぎが生じる．例えば，異常領域が肺の両側にある際に，「両肺」や「両側肺」のように複数の表現方法が存在する．そのため，クラス分類問題や単語単位での所見生成には複雑な前処理が必要なことに加え，汎用性が低くなるといった問題がある．これらの問題に対応するために，本稿では表記方法の揺らぎがある場合にも有効な手法である，文字単位 (character-level) [Zhang 16]での所見生成を行なった．

本稿では，胸部 X 線写真を入力として受け取り，その画像に対する所見を文字単位で生成する Encoder-Decoder モデルを提案した． Encoder 側では入力画像に対して特徴マップを抽出する．Decoder 側ではアテンション機構 (Attention mechanism)によって重み付けされた特徴マップと 1 ステップ前の状態をもとに文字を出力する．

本稿の主な貢献は次の 2 つである．(1) 医療画像において，文字単位での所見生成を行なった．(2) アテンション機構を導入することで，精度向上だけでなく，生成された各文字が画像のどの部位を参照して生成されたかを視覚的に示し，結果の解釈性を高めた．

2. 関連研究

2.1 文字単位の言語モデル

自然言語処理やキャプション生成の分野では，一般的に単語単位での分散表現を学習した言語モデルが用いられている [Vinyals 15]. しかし，単語単位での言語モデルは前処理が複雑であることや表記方法の揺らぎに弱いといった問題点がある．そこで近年，ユーザー生成コンテンツなどのようにテキストが一定の規則に基づいて整えられていないような場合においても有効である，文字単位での言語モデルが提案されている [Zhang 16]. 文字単位の言語モデルの他の利点として，日本語で特に困難な単語分割の必要がないという点が挙げられる．しかし，長

連絡先：作花健也，東京大学，〒113-8656 東京都文京区本郷 7-3-1，sakka_kenya_17@stu-cbms.k.u-tokyo.ac.jp

期的な依存関係を学習する必要があるため活用が困難であった. 医療画像の所見は, 文字列長が他のキャプション生成の問題と比べて短い. そのため, 専門家により記述方法が異なる医療画像の所見テキスト生成のための手法として, 文字単位の言語モデルは有効な手法であると考えられる.

2.2 アテンション機構

アテンション機構を用いた画像のキャプション生成の方法として, ハード・アテンション (Hard-Attention)とソフト・アテンション (Soft-Attention)の 2 つの方法が考案されている [Xu 16]. ハード・アテンションは, アテンションの重みを特定の領域に絞り込んで適用する特徴を持つ. 一方, ソフト・アテンションは, アテンションの重みを広範囲に適用する特徴を持つ. 胸部 X 線写真の読影は, 広範囲の特徴を捉える必要があることから, 本稿ではソフト・アテンションを用いて所見生成を行なった.

2.3 医療画像における所見生成

医療画像の所見生成にアテンション機構を用いた研究も行われている [Zhang 17, Jing 18]. しかし, 英語の文章を対象としており, 単語単位での所見生成を行なってる. 特に Jing らの研究 [Jing 18]では, 精度向上のために所見に関するタグが用いられているため, 通常の読影では付与されない情報を専門家が付与する必要がある.

他の言語と異なり, 日本語の文章に含まれる文字は位置情報や前後関係などの情報を豊富に持つ. そのため, 日本語の所見生成においては, アテンション機構を用いた文字単位の手法が有用であると考えられる.

3. 提案手法

本稿では, 胸部 X 線写真を入力として受け取り, ソフト・アテンションを用いて所見を文字単位で出力する Encoder-Decoder モデルを提案した (図 1). モデルは, 正解の所見と生成された所見の交差エントロピー誤差とアテンション機構に関するソフトマックス関数の和で定義された損失関数を最小化するように, Encoder, Decoder を End-to-End で学習した. Early-Stopping を用いて, 2epoch 連続して検証データで精度の向上がないとき学習を打ち切った.

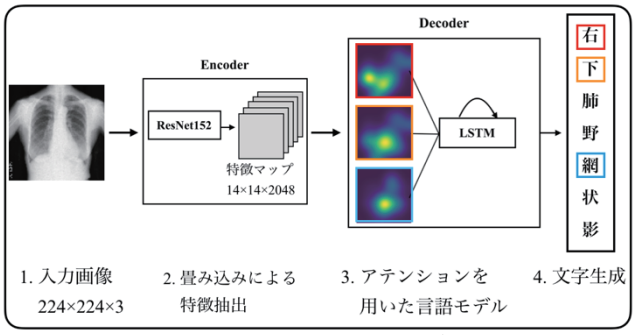


図 1 Encoder-Decoder モデル

3.1 Encoder

ResNet152 [He 15]の事前学習済みモデルを用いて, 入力画像に対する特徴マップを取得した. しかし, 事前学習は一般物体で行われているため, 胸部 X 線写真ではうまく特徴が抽出できないと考えられる. そのため, 胸部 X 線写真を用いて所見の頻度が高い上位 11 クラスの分類問題として, 再度事前学習を行なった.

胸部 X 線写真をモデルに入力する際には, 以下の前処理を行なった. まず, 画像のサイズが 2048×2048 と大きいため, 224×224 にリサイズした. その後, 3 チャネル画像の各チャネルの値を平均 (0.485, 0.456, 0.406), 分散 (0.229, 0.224, 0.225)に正規化した.

学習時には, モデルの汎用性を高めるためにデータ拡張 (Data Augmentation)を用いた. 入力画像を 256×256 にリサイズした後, Random Crop を行い 224×224 の領域を抽出し, 50%の確率で Horizontal flip を行なった. 最適化関数は, Adam を利用し, 学習率は 0.0001 に設定した.

3.2 Decoder

ソフト・アテンションによって重み付けされた 14×14×2048 の特徴マップと 1 ステップ前の状態を入力として受け取り, 1 層の LSTM [Hochreiter 97]を用いて所見の文字を 1 文字づつ出力するモデルを構築した. 一文字ずつアテンション機構を用いて出力することで, より詳細に前の状態を反映した所見生成を行い, 結果の解釈性を高めることもできる.

Decoder のハイパーパラメータはそれぞれ以下のように設定した. 隠れ状態を 256 次元, 最適化関数は Adam を利用し, 学習率は 0.0004 に設定した. 今回のデータセットでは, 文字の種類が 300 以下と比較的少ないため, 分散表現は用いていない.

4. 評価実験

4.1 データセット

東京大学附属病院より提供していただいた 18,004 枚の胸部 X 線写真を用いて評価実験を行なった. これらの各写真には, 専門家による所見情報が付与されている. データセット内の所見情報は, 全て同一の専門家によってラベル付けされているのではなく, 複数人の専門家によってラベル付けされているため, 同じ所見でも異なる記述方法で書かれていることもある.

上記のデータセットの所見情報から, ”前回と変化なし”などのように時系列情報が必要なデータに関しては, データセットから除いた. 加えて, ”手入力 部位”などのように所見情報として, 不必要なものも除き, データセットの整形を行なった.

4.2 実験設定

提案手法の有効性を BLEU スコア [Papineni 02]を用いて検証した. データ量を保証するために, 所見の出現回数に閾値を設定した. 本稿では, 閾値を 5 と 30 に設定した 2 つのデータセットを用いて検証を行なった (表 1). 閾値を 5 に設定した場合は全 18,004 件の所見のうち 91.5%, 閾値を 30 に設定した場合は 84.3%の所見を含んでいる.

上記で得られた 2 つのデータセットについて, ラベルの分布を保持するように各ラベルの出現回数の 80%を訓練データ,残り 20%の内それぞれ 10%を検証データとテストデータとして抽出した. ラベルによっては, データ数が 3 枚程度のものもあり学習データとして不十分である. 加えて, ラベルごとの頻度のばらつきが大きい. そのため, 訓練データに関して, 異常なし以外のラベルのデータ数を 100 枚にし, 異常なしとその他のラベル (異常あり)の比率が元のデータセットの分布に従うようにアップサンプリングを行なった.

表 1 データセットの詳細

	症例数	文字の種類	データ数 (訓練)	データ数 (検証)	データ数 (テスト)
症例の出現頻度の閾値：5	158	128	12,893	1,616	1,616
症例の出現頻度の閾値：30	25	61	11,887	1,472	1,472

4.3 実験結果

各文字毎のアテンション機構の結果と生成された文字列の結果を示す (図 2). デバイスが埋め込まれている患者の胸部 X 線写真では, 所見生成時にデバイスの周辺にアテンション機構が機能していることが確認できる (図 2 A). 「両側肺尖胸肥厚」のように, 所見に位置情報が含まれる例では, アテンション機構が位置情報を反映するように機能していることが確認できる (図 2 B). モデルによって生成された所見の中では, 「肥厚」と「癒着」のように素人目では判断が難しいような誤りが見られた (図 2 C). これらの結果は, 専門家に確認してもらい, どの程度診断に影響のある誤りであるかを判断する必要がある. 胸部 X 線写真のみの情報から, 「異常なし」と判断するためには, 画像を網羅的に読影する必要がある. モデルが「異常なし」と所見生成した際のアテンション機構の推移を確認すると, 他の所見の場合とは異なり広範囲にアテンション機構が機能していることが確認できる (図 2 D).

各データセットのテストデータに対する精度評価の結果を示す (表 2). どちらのデータセットでも, 高いスコアが出ていることがわかる. テストデータは, 実際の分布をもとに作成されているため, 「異常なし」のラベルが全体の 8 割含まれている. そのため, 「異常なし」の所見を正しく判断できるモデルであれば, BLEU スコアが高くなる. そこで, 「異常なし」以外のラベルについてのみ BLEU スコアを計算した結果も示した.

表 2 各データセットの精度評価の結果

	BLEU 1	BLEU 2	BLEU 3	BLEU 4
閾値：5 (元の分布)	0.7105	0.7053	0.7021	0.6966
閾値：30 (元の分布)	0.8366	0.8355	0.8347	0.8262
閾値：5 (異常ありのみ)	0.1362	0.1135	0.1002	0.0760
閾値：30 (異常ありのみ)	0.3621	0.3547	0.3493	0.2926

5. 考察

所見生成において, アテンション機構がデバイスの有無や位置情報を捉えることができていることが確認された (図 2 A, B, C). 位置情報が出力された時とアテンション機構がその位置に働いている時が一致していない例もある. これは, 読影に必要な異常部位がその位置にあるため, 時系列的に前後して関係のある文字を出力する時に参照されるためであると考えられる.

医療画像の所見には, 表記の揺らぎが存在するため, 既存の BLEU などの評価指標では正しく評価することが難しい. 例えば, 「両側肺尖胸膜肥厚」と「両肺尖部胸膜肥厚」は意味的に同じ所見を表している (図 2 B). しかし, 既存の評価指標では各文字の位置が考慮されていることや単語のオントロジーが考量されていないため, これら二つの所見の類似度は低くなる.

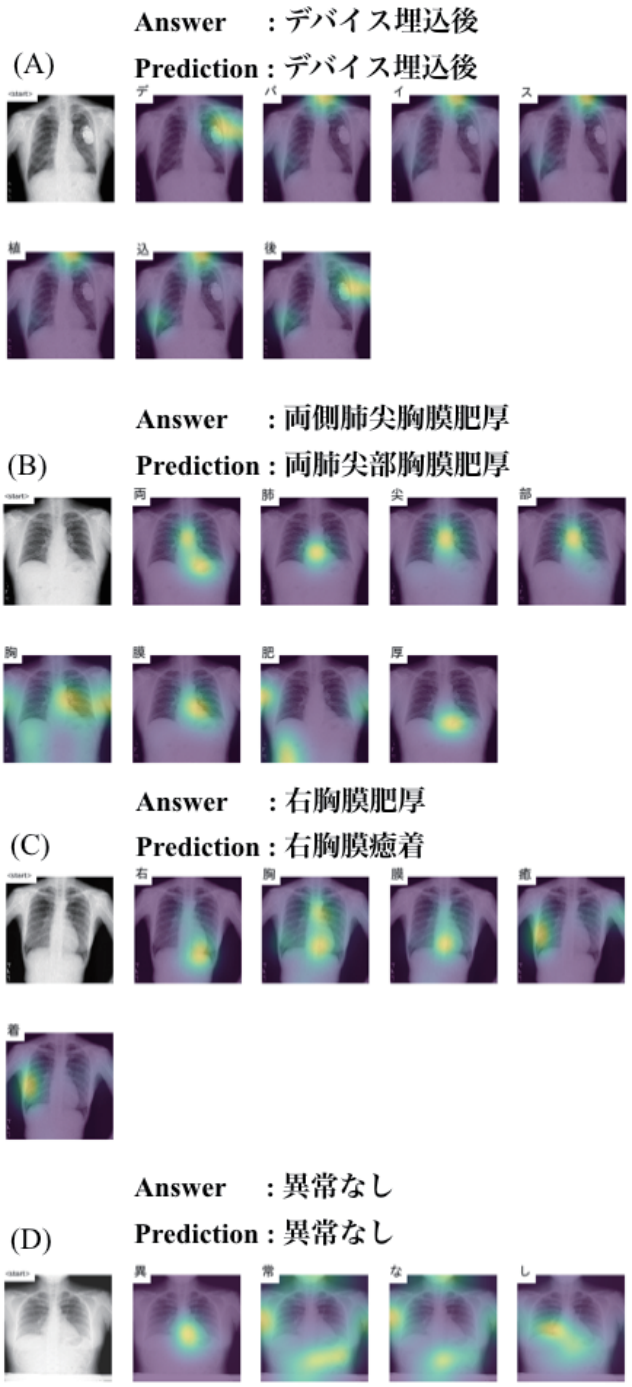


図 2 所見生成の結果とアテンション機構の推移

医療画像の所見の実際の分布を反映したテストデータでは, 高い BLEU スコアが得られた (表 2). 実際の分布では, 「異常なし」が全体の所見の 8 割を占める. そのため, 常に「異常なし」を出力することで精度が上がってしまう可能性がある. しかし, 本稿で提案した手法で作成されたモデルでは, 81 種類の所見が生成されており, 「異常なし」のデータに対して正しく「異常なし」と出された結果は 68%程度, 異常所見に対して誤って「異常なし」と出した結果は 11%程度であった. 「異常なし」の精度が低い原因として, 「異常なし」と判断する際には, 画像全体を見る必要があり問題設定として難しいことが考えられる. 結果からも, 他の例では異常部位に重点的にアテンション機構が働いているのに対して, 「異常なし」ではアテンション機構が広範囲に働

いており，画像全体を見て判断していることが確認できる (図 2 D). テストデータから「異常なし」を除いた場合，BLEU スコアが下がった. この原因として，実験結果で例を挙げた精度評価指標の問題も考えられる.「異常なし」以外の所見では，特に表記の揺らぎが大きく BLEU で正しく評価を行うことが困難である.

本稿で提案した手法は，所見と重点的に見るべき領域を同時に確認できることから，仮に生成された所見に誤りがある場合でも専門家がアテンション機構が働いている領域を重点的に確認することで正しい読影が可能である. また，読影のためのスクリーニングとして利用することで，専門家の労力を下げることに貢献できると考えられる.

6. まとめ

本稿では，胸部 X 線写真におけるアテンション機構を用いた文字単位での所見生成を行う手法を提案した. さらに，アテンション機構を用いることで結果の解釈性を高めた. 提案した手法について，BLEU スコアを用いて精度評価することで，手法の有用性を確認した. 今後の応用として，アテンション機構の結果を用いることで，経験の少ない専門家が胸部 X 線写真の読影方法を学ぶ際の手助けも可能であると考えられる. 文字単位でのキャプション生成は，一般的に困難であるため実用例が少ないが，今後医療画像のみならず多くの分野で用いられることが期待できる. 医療画像は大量のデータを集めることが困難であるため，どのようなデータ拡張が有効か検証する必要がある. 特に本稿でも使用した Horizontal Flip が，左右で似た構造を持つ胸部 X 線写真においても有効であるか検証を行いたい.

本稿で提案した手法は，日本語のみならず他の言語でも適用が可能であると考えられる. 特に日本語と同様に文字の持つ情報量が多く，よりデータ量が豊富な中国での適用が期待される.

今後は，医療画像の所見のように単語の位置情報が重要でなく，類似語が多いような文章に対しても適切に評価できる指標を専門家と作っていく必要がある.

7. 謝辞

本研究は，JSPS 科研費 JP25700032 JP15H05327 JP16H06562 国立研究開発法人日本医療研究開発機構 (AMED)の平成 28 年度「臨床研究等 ICT 基盤構築研究事業」の助成を受けたものです.

参考文献

[Delrue 11] Louke Delrue, Robert Gossenlin, Bart Ilsen, An Van Landeghem, Johan de Mey, and Philippe Duyck: Difficulties in the Interpretation of Chest Radiography, In Comparative Interpretation of CT and Standard Radiography of the Chest, page 27-49 , Springer, 2011.

[He 15] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun: Deep Residual Learning for Image Recognition, arXiv: 1512.03385v1, 2015.

[Hochreiter 97] Sepp Hochreiter, and Jurgen Schmidhuber: Long Short-Term Memory , Neural Computation 9 , page 1735-1780 , 1997.

[Jing 18] Baoyu Jing, Pengtao Xie, and Eric P. Xing: On the Automatic Generation of Medical Image Reports , arXiv: 1711.08195v3, 2018.

[Papineni 02] Kishore Papineni, Salim Roukos, Todd Ward, and Wei-Jing Zhu: BLEU: a Method for Automatic Evaluation of Machine Translation, Proceedings of the 40th Annual Meeting of the Association for Computational Linguistics (ACL), page 311-318, 2002.

[Rajpurkar 17] Pranav Rajpurkar, Jeremy Irvin, Kaylie Zhu, Brandon Yang, Hershel Mehta, Tony Duan, Daisy Ding, Aarti Bagul, Robyn L. Ball, Curtis Langlotz, Katie Shpanskaya, Matthew P. Lungren, Andrew Y. Ng: ChestXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning, aeXiv:1711.05225v3, 2017.

[Vinyals 15] Oriol Vinyals, Alexander Toshev, Samy Bengio, and Dumitru Erhan: Show and Tell: A Neural Image Caption Generator, The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), page 3156-3164, 2015.

[Xu 16] Kelvin Xu, Jimmy Lei Ba, Ryan Kiros, Kyunghyun Cho, Aaron Courville, Ruslan Salakhutdinov, Richard S. Zemel, and Yoshua Bengio: Show, Attend and Tell: Neural Image Caption Generation with Visual Attention , arXiv: 1502.03044v3, 2016.

[Zhang 16] Xiang Zhang, Junbo Zhao, and Yann LeCun: Character-level Convolutional Networks for Text Classification, arXiv:1509.01626v3, 2016.

[Zhang 17] Zizhao Zhang, Yuanpu Xie, Fuyong Xing, Mason McGough, and Lin Yang: MDNet: A Semantically and Visually Interpretable Medical Image Diagnosis Network, The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 6428-6436, 2017.

機械学習を用いた検査結果からの患者取り違え採血検出手法の検討

Detecting patient mix-up on blood samples with machine learning

三谷 知広[*1] Mitani Tomohiro　土井 俊祐[*2] Doi Shunsuke　横田 慎一郎[*2] Yokota Shinichiroh　今井 健[*1] Imai Takeshi　大江 和彦[*1*2] Ohe Kazuhiko

[*1] 東京大学大学院医学系研究科医療情報学分野
Department of Biomedical Informatics, Graduate School of Medicine, The University of Tokyo

[*2] 東京大学医学部附属病院企画情報運営部
Department of Healthcare Information Management, The University of Tokyo Hospital

Patient mix-up on blood samples is one of the common causes of blood test errors. It is also known as patient misidentification problem. Although the detection of mix-up is commonly performed by naive comparison with the last laboratory results of the same patients: delta checks, either the sensitivity or the specificity of delta checks is not satisfactory. To establish a new detection system, we made simulated mix-up data from actual data of complete blood count and serum chemistry in our hospital. Using differences from the previous laboratory results as features, a highly accurate detection system was built by machine learning technique. An XGBoost model recorded the best ROC AUC score of 0.9986.

1. はじめに

誤った患者からの採血は再検査や誤診などの原因となり，提出された検体の 0.1%〜0.3%に発生すると言われている[Dunn 2010, Schifman 2017]. このような患者取り違えはバーコードによるラベルや採血時の患者認証，複数の認証方法の導入などにより減少するが，人員不足や疲労，作業の中断などに起因するプロトコル違反によって発生するとされる[Randell 2019].

検体検査結果のチェック機構としては、各項目が前回値とどの程度変化したかを比較するデルタチェックと呼ばれる手法が広く用いられているが，その精度は十分とは言えない. デルタチェックにおける検出アラートの大半は生理的な変化や治療に関連する変化であり，検査エラーの関連する検出アラートは全体の約 4.8%である. さらにその大半は試薬の干渉やサンプルの汚染によって引き起こされ，患者取り違えに起因する検出アラートはアラート全体の約 0.3%であったと報告されている[Schifman 2017]. また，最近のレビューにおいて，多くの一般的なデルタチェックで感度は 30%未満であったと報告されている[Rendall 2019]. 単純なデルタチェックに代わる方法として，どの項目がデルタチェック陽性になったかに応じて検体としての判定を変えるルールベースの手法[Miller 2015]や，検査値ごとにデルタチェックの閾値を変える手法[Sourati 2015]，後述する加重累積デルタチェック法[Yamashita 2013]などが提案されているが，上記の中で最も精度の良い Yamashita らの報告でも ROC 曲線下面積(ROC AUC)は 0.98 であり，真のエラー率を 0.1%と仮定すると感度 0.90 を得る場合の陽性適中率は約 1〜2%となる. 渉猟した範囲で，採血取り違え検体の検出に昨今の機械学習技術を活用した報告はなかった.

検査結果を用いた患者取り違え採血の検出は，異常検知および変化検知のタスクとして捉えることができるが、個人個人の採血結果の推移は多系列かつ多変量な時系列データであり、各系列の時間軸が一般的な時系列データに比べて短いという点で時系列データに対する異常検知手法を適応することは難しい. 本研究では人工的な取り違えデータを作成した上で，主に以前の値との差分を特徴量として使用し，古典的な異常検知手法である Mahalanobis-Taguchi 法および複数の機械学習技術を適用し，患者取り違え採血の検出を行なった.

連絡先：三谷知広，東京大学大学院医学系研究科医療情報学分野，東京都文京区本郷 7-3-1，tmitani-tky@umin.ac.jp

2. 対象データ

2.1 データの概要

東京大学医学部附属病院における 2011 年から 2017 年の血液検体による臨床検査を対象とした. データは患者の個人情報が匿名化された SS-MIX2 データベースより取得した. 生化学検査と血算検査など複数の検体採取容器にわかれていても一度の採血で実施されることが多く，今回は同一時刻に記録されたデータは一連の検査として扱った. なお，このデータは検査部門や担当医などにより不整合と判断されたデータは削除もしくは修正された後の最終的なデータである.

血液に対する全 374 万件の検査のうち，血算検査 8 項目(WBC, Hb, Hct, RBC, MCV, MCH, MCHC, Plt)および生化学検査主要 7 項目(Alb, AST, ALT, BUN, Cre, Na, K)を含む 258 万件の検査を抽出した. この 7 項目は，当院での各項目の検査数を元にシステムがカバーするデータ割合を元に決定した. なお，対象とならなかった 116 万件の大半は血液ガス検査および腫瘍マーカー検査や抗体検査，ホルモン検査，血液型検査などであった.

血算および生化学主要 7 項目を含む 258 万件の中で，欠損値が 4 項目以内の検査は 233 万件であった. 各患者の初回検査 43 万件を除いて，前回値を有する 190 万件を対象とした.

2.2 取り違えのシミュレーション

まず患者ごとに検査結果を時系列に並べて window size を 4 回とした sliding window を適用し，今回値，前回値〜前々々回値の計 4 回分の検査結果を持つ部分時系列データを作成した. このデータを元に検査時刻や以前の検査結果などはそのまま固定して今回の検査結果のみを後述の基準による他人の検査

結果に取り替えた擬似的な患者取り違え採血データを作成した. ここに元の取り替えていないデータを加え, 4 回分の部分時系列データから今回値が取り替えられたデータか本来のデータかを二値分類するタスクとした.

なお, 入院・外来の違いや病棟の違いにより疾患・病態の分布が異なり, 検査結果の分布も異なる. 全患者内で検査結果を取り替えると, そのような入院外来・病棟ごとの分布の違いを学習してしまい, 実運用時に機能しない懸念がある. 実際の患者取り違えの状況に近づけるべく, 同一部署内での採血結果を取り替えることとし, また, 欠損パターンの違いを学習することも避けるため, 部署に加えて 15 項目中の欠損パターンも同一なデータ間で取り替えることとした. 実装の問題から各グループ内での単純な順列並び替えとしたが, 同一患者のデータに交換されてしまったデータは5186件(0.27%)と少なく, これらは削除した.

また, train/dev/test set への分割については, train set: 2011 年～2017 年 7 月, dev set: 2017 年 8 月～10 月, test set: 2017 年 11 月～12 月として test set に出現した患者のデータは dev set および train set から取り除き, さらに dev set に出現した患者のデータは train data から取り除いた. 以上により train set 380 万件, dev set 4 万件, test set 9 万件のデータを作成した.

3. 方法

3.1 検討したモデル

(1) デルタチェック (baseline)

閾値としては当院内で使用している以下の閾値を用いた(表 1.). 当院におけるデルタチェックは患者取り違えのみではなく試薬のエラーなどを含めた検査エラーの検出を目的として用いられており, 今回対象とした項目以外にも設定項目がある. また, 全ての検査項目を網羅しているわけではない. 本研究で対象とした 15 項目中の 9 項目に基準が設定されており, 9 項目について基準外となった項目数を取り違え陽性・陰性判別の閾値としたときの感度・特異度をプロットして ROC AUC を計算した. また, 1 項目でも基準外のものを陽性と判定した場合の Accuracy を求めた.

表 1. 当院におけるデルタチェック基準(該当項目)

項目	下限	上限	項目	下限	上限
Plt	70%	200%	BUN	70%	150%
MCV	95%	105%	Cre	80%	120%
Hct	85%	115%	Na	96%	104%
ALT	20%	350%	K	81%	123%
AST	20%	350%			

(2) Weighted Cumulative Delta-Check Index (wCDI)

Yamashita らによって報告された患者取り違え検体検出手法である[Yamashita 2013]. 各検査項目の分布を Box-Cox べき乗変換によって標準正規分布に変換して前回値との差分をとると, 個人間変動に比して個人内変動が大きい項目は広い分布となり, 逆に個人内変動が小さい項目は狭い分布となる. よって検査に含まれる各項目について, 正規化した前回値との差分をその分散の逆数で重み付けした加重平均を異常度の指標とし, 患者取り違え採血検知に用いた. データの存在する項目についてのみ平均を取るため欠損値に対応可能なモデルであり, 論文中では計算に使用できた項目数ごとの精度が報告されていた. 10項目以上でほぼプラトーに達したとの報告であり, 今研究では 15 項目中 10 項目以上で差分の計算できるデータを対象とした. 実装には scikit-learn [Pedregosa 2011]を使用した.

(3) Mahalanobis-Taguchi 法

対数正規分布が既知の項目については対数変換をおこなった上で, 前回値との差分を計算した. MCV, MCHC, MCH は Hb, RBC, Hct から計算される値であり, 多重共線性の懸念からこの 6 項目中 Hb, MCH, MCV を用いた. 以上により得られた 12 項目の差分データから Mahalanobis-Taguchi 法による異常度を計算し、その異常度についての ROC AUC を計算した. Accuracy を計算した閾値は, dev set 上の accuracy が最良となる点に設定した. なお, このモデルはデータの欠損に対応していないことから, 今回値および前回値が完全データであるデータ(train 97 万件, dev 2.3 万件)のみを対象とした.

(4) Deep Neural Network

欠損なしのデータのみを使用して sliding window を作成しなおし, 4 回×15 項目すべてが揃ったデータ(train 104 万件, dev 2 万件)を対象とした. 一部の項目を対数化した上で全項目について平均 0 標準偏差 1 に正規化し, MLP, 1D CNN, LSTM を検討した. CNN は時系列分類タスクに対して精度が優れると報告される ResNet 構造をベースとした[Hassan 2018]. いずれも Tensorflow を使用し, 層数や中間層のサイズなどのハイパーパラメータは Optuna により探索した.

(5) Gradient Boosting Decision Trees (GBDT)

GBDT のアルゴリズムとしては広く使用されている XGBoost[Chen 2016]を用いた. 今回値と, 各前回値・前々回値・前々々回値との差・時間差, 今回の測定時刻を特徴量として用いた. なお, 前々回値は約 14.3%, 前々々回値は 25.5%で欠損していた.

3.2 モデルの評価方法

各ハイパーパラメータチューニングは dev set 上で行った. 各モデルは dev set の ROC AUC で比較し, 最良のモデルを最終モデルとした. 最終モデルに対して test set における精度評価を行った. また, 一例として, baseline であるデルタチェックと同じ感度を実現できる閾値を設定し, 混同行列を求めた.

3.3 軽量モデルの検討

XGBoost を用いたモデルに対して以下の検討を追加した.

(1) 特徴量の削減

特徴量を削減したデータセットでの学習結果を比較した.

(2) データ量の削減

検査実施件数が小規模な医療機関でも自施設のデータのみでモデルを構築できるか検討するため, 100 万件, 10 万件, 1 万件, 1000 件のデータについて学習させた結果を比較した.

4. 結果

4.1 モデルの比較

各モデルにおける dev set 上の ROC AUC を比較検討した. XGBoost は欠損値を含むデータを対象としていながら最良の結果を達成しており, 最終モデルとして XGBoost によるモデルを採用した. なお, デルタチェック (baseline)において 1 項目でも基準外の項目があった検査を取り違え陽性とした場合の感度は 95.9%, 特異度は 72.3%であった. 真の取り違え発生率を 0.1%と仮定した場合の陽性適中率は 0.35%であった.

表 2. 各モデルによる結果

方法	Accuracy	ROC AUC	備考
Delta Check	0.8400	0.9306	Baseline
wCDI	0.9248	0.9781	欠損値含む
MT	0.9304	0.9787	
MLP	0.9678	0.9958	
CNN	0.9686	0.9950	
LSTM	0.9705	0.9962	
XGBoost	**0.9792**	**0.9980**	欠損値含む

4.2 最終モデルの検出精度

XGBoost による最終モデルとデルタチェック(baseline)における test set 上の結果を示す(図 1). なお, 前項の結果は dev set 上の結果であり以下の test set における最終評価結果とは異なっている. Test set のデータはこの最終評価にのみ用いた.

XGBoost のモデルにおいて, 閾値を 0.05 刻みとして感度を計算し, デルタチェック(baseline)による感度 95.9%を達成できる閾値の下限である p=0.70 での混同行列を求めた(表 3). この設定において真の取り違え発生率を 0.1%と仮定した場合の陽性適中率は 11%であった.

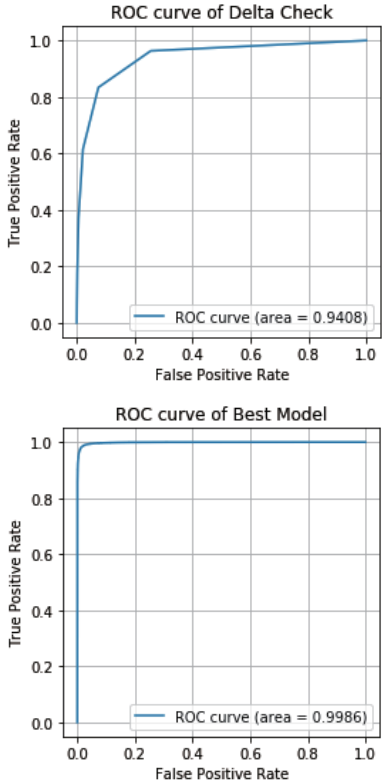


図 1. Test set における ROC 曲線
(上:baseline, 下:XGBoost を用いた最終モデル)

表 3. 最終モデルにおける 閾値を p=0.70 とした混同行列

混同行列		予測	
		取り違えなし	取り違えあり
実際	取り違えなし	48575 (99.3%)	367 (0.7%)
	取り違えあり	1526 (3.1%)	46913 (96.9%)

最終モデルにおける特徴量重要度上位 15 項目を図 2 に示した. 特徴量の重要度を計算する方法は複数知られているが, ここでは各ノードの損失減少量をノードごとに平均した値を出力した.

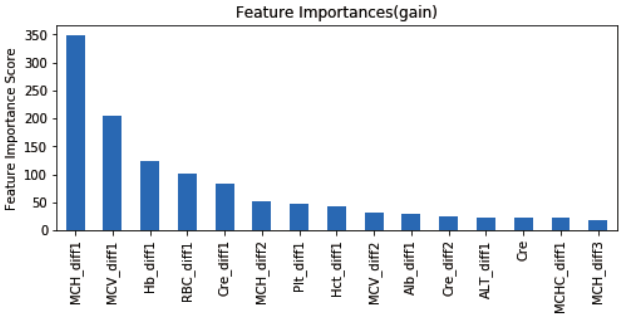


図 2. 最終モデルにおける特徴量重要度
(Suffix のついていない項目は今回値そのものを示し, suffix 末尾の数字は何回前との差分かを示す)

4.3 軽量モデルの検討

以下の実験において、learning_rate=0.3, n_estimators=200, max_depth=8 の設定で学習した.

(1) 特徴量の削減

表 4. 特徴量を減らした設定での ROC AUC

特徴量セット	ROC AUC
4 回分 (今回値+今回値との差)＋時刻・時間差	**0.9972**
4 回分 (今回値+今回値との差)	0.9959
2 回分 (今回値+今回値との差)＋時刻・時間差	0.9965
2 回分 (今回値+今回値との差)	0.9952
2 回分 (今回値+前回値そのまま)	0.9942
2 回分 (今回値+今回値との差, 血算のみ)	0.9800
2 回分 (今回値+今回値との差, 生化学のみ)	0.9701

(2) データ量の削減

表 5. 学習データ量を減らした設定での ROC AUC

学習データ量	ROC AUC
380 万件	**0.9972**
100 万件	0.9971
10 万件	0.9953
1 万件	0.9903
1000 件	0.9804

5. 考察

XGBoost は欠損値に対応したモデルであり, 適用可能なデータ数を維持しながら高精度の判別モデルを構築することができた. デルタチェック(baseline)の ROC AUC 0.9306, 既存研究である wCDI 法の ROC AUC 0.9781 に対し, ROC AUC 0.9980 を達成した. なお, DNN についてはいずれも正規化した 4 回分のデータをそのまま入力としており, 以前の値との差分をとって使用した XGBoost のモデルと単純に比較することはできない. 特徴量設計やネットワーク構造の工夫などで精度が改善する可能性はあるが, 欠損値への本質的な解決が難しいことから, さらなる検討は行わなかった.

wCDI は報告とほぼ同等の ROC AUC が再現された. ROC AUC は XGBoost のモデルより低かったが, 連続量で結果が得られる検査項目に対して汎用的に適用できる手法であり, 今研究のモデルでは対象としなかった腫瘍マーカー検査や抗体検

査，ホルモン検査などにも適用できるメリットがある．実運用では両者を組み合わせて使用することも検討に値する．

なお検体取り違えは稀な事象であり，一般に陽性的中率は低い．1 日に 1000 件検査があり 0.1%の確率で取り違えを生じるという状況を仮定すると，デルタチェックによる baseline では毎日 277 件のアラートのうちの 0.96 件が実際の取り違えであったという状況に相当し，陽性適中率は 0.35%にとどまる．閾値を 2 項目にあげると陽性適中率は 1.1%となるが感度は 83.7%に低下する．低い陽性的中率は不要なカルテレビューや再度の採血検査などを招くうえ，またここから取り違え検査を特定することに困難を伴うことが予想される．XGBoost による最終モデルで閾値を baseline と同等の感度 96%を維持できる p=0.70 に設定した場合，同様の条件として毎日 8.5 件の検出アラートのうち 0.97 件が実際の取り違えという状況に相当し，感度は 97%で陽性適中率は 11%である．なお，閾値を p=0.95 とすると感度は 92%に低下するものの，陽性適中率は 36%となる．これらはデルタチェックにより生じていた人手での確認による労力の削減や，再検査の減少などによる患者負担の減少に繋がりうる結果である．

特徴量としては，MCV や MCHC，Cre といった個人内変動の少ない項目の差分が重要であった．Cre のみ今回値そのものが重要な特徴量として TOP15 に入ったが，これは Cre の変化において差よりも比が意味を持つためと思われ，前回値との差分ではなく比を使用した方がよかったかもしれない．検査時刻や前回との時間差は，シミュレーションデータにおける人工的な取り違えの有無に独立な特徴量であり，これらの特徴量追加によって ROC AUC 値が向上したことは，XGBoost によって他の特徴量との交互作用がモデルに組み込まれたことを示唆する．血算のみ・生化学のみとスピッツごとのデータに分けると ROC AUC は低下し，特に生化学のデータのみとすると大きく低下した．実用的な精度を得るには血算と生化学を組み合わせるか，特に欠損値の多い生化学検査においては例えばいくつかの特定の項目は全例でルーチンに測定するなどの何らかの工夫が必要と思われる．

データ量については，1 万件～10 万件程度でも 0.99 以上の ROC AUC を達成できており，一般の病院が自施設で収集したデータからも実用的なモデルを構築可能と考えられる．なお，実際のデータには同一患者からのデータが多く含まれるが，今回の実験設定では train set 380 万件からランダムに抽出しており，データ量が等しくても異なった患者からのデータがより多く含まれる．データの多様性が増すため，実データから同等の精度を得るためにはより多くのデータを必要とするかもしれない．

本研究の limitation としては，SS-MIX2 標準化ストレージ内のデータのみを用いたため輸血や手術といった臨床情報を組み込めなかった点が挙げられる．ROC AUC はデルタチェックや wCDI 法に比べ改善したものの，陽性適中率は前述の設定で 11%である．柔軟な特徴量設計が可能という GBDT のメリットを活かして直前の輸血や手術の有無，緊急検査かなどの特徴量の追加を試み，陽性適中率の向上を図りたい．また，実運用に向けた課題として個々の結果に対する判断根拠の可視化などを検討している．

6. まとめ

今回の研究では，機械学習による患者取り違え採血の検出を試みた．これまでは前回値との単純な比較であるデルタチェックが推奨されていたが，機械学習の手法を用いることで感度・特異度ともに大幅に向上した．

参考文献

[Chen 2016] Chen, T. and Guestrin, C.: XGBoost: A Scalable Tree Boosting System. arXiv:1603.02754, 2016.

[Dunn 2010] Dunn, E. J. and Moga, P. J.:Patient misidentification in laboratory medicine: a qualitative analysis of 227 root cause analysis reports in the Veterans Health Administration, Archives of Pathology & Laboratory Medicine, 2010.

[Fawaz 2018] Fawaz, H. I., Forestier, G., Weber, J., Idoumghar, L. and Muller, P. A.: Deep Learning for time series classification: a review. arXiv:1809.04356, 2018.

[Miller 2015] Miller, I.: Development and Evaluation of a Logical Delta Check for Identifying Erroneous Blood Count Results in a Tertiary Care Hospital., Archives of Pathology & Laboratory Medicine, 2015.

[Pedregosa 2011] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., … Duchesnay, E.: Scikit-learn: Machine Learning in Python, Journal of Machine Learning Research, 2011.

[Rendall 2019] Rendall, E. W. and Yenice, S.: Delta Checks in the clinical laboratory (Review), Critical Reviews in Clinical Laboratory Sciences, 2019.

[Schifman 2017] Schifman, R. B., Talbert, M. and Souers, R. J.: Delta Check Practices and Outcomes: A Q-Probes Study Involving 49 Health Care Facilities and 6541 Delta Check Alerts, Archives of Pathology & Laboratory Medicine, 2017.

[Sourati 2015] Sourati, J., Erdogmus, D., Akcakaya, M., Kazmierczak, S. C. and Leen, T. K.: A Novel Delta Check Method for Detecting Laboratory Errors. IEEE 25th International Workshop on Machine Learning for Signal Processing (MLSP), 2015.

[Yamashita 2013] Yamashita, T., Ichihara, K. and Miyamoto, A.: A Novel Weighted Cumulative Delta-Check Method for Highly Sensitive Detection of Specimen Mix-up in the Clinical Laboratory. Clinical Chemistry and Laboratory Medicine, 2013.

General Session | General Session | [GS] J-13 AI application

[2N4-J-13] AI application: medicine

Chair:Koji Morikawa Reviewer:Yoshikuni Sato

Wed. Jun 5, 2019 3:20 PM - 5:00 PM Room N (Front-right room of 1F Exhibition hall)

[2N4-J-13-01] Advantages of 3D-ResNet in Cerebral Aneurysm Detection using MRA Images

○Terasaki Yuki[1], Hajime Yokota[2], Hiroki Mukai[2], Shoma Yamauchi[2], Ryuna Kurosawa[3], Joji Ota[3], Takuro Horikoshi[2], Yasukuni Mori[4], Hiroki Suyari[4] （1. Graduate School of Chiba University, 2. Dept. Radiology, Chiba University Hospital, 3. Dept. Radiology, Chiba University , Hospital, 4. Graduate School of Engineering, Chiba University）

3:20 PM - 3:40 PM

[2N4-J-13-02] Classification of esophageal cancer CT images using deep learning

○Takumi Seto[1], Masashi Takeuchi[2], Masahiro Hashimoto[2], Yui Ito[1], Naoaki Ichihara[2], Hirohumi Kawakubo[2], Yuko Kitagawa[2], Hiroaki Miyata[2], Masahiro Jinzaki[2], Yasubumi Sakakibara[1] （1. Keio University Faculty of Science and Technology, 2. Keio University School of Medicine）

3:40 PM - 4:00 PM

[2N4-J-13-03] Development of Epileptic Seizure Prediction Algorithm by Combining Heart Rate Variability Analysis and Autoencorder

○Koichi Fujiwara[1,2], Fumiya Sakane[2], Miho Miyajima[3], Toshitaka Yamakawa[4], Taketoshi Maehara[3] （1. Nagoya University, 2. Kyoto University, 3. Tokyo Medical and Dental University, 4. Kumamoto University）

4:00 PM - 4:20 PM

[2N4-J-13-04] Diagnosis of head CT image by on-premise deep learning

○Tetsuya Shiraishi[1], Yuriko Hijikata[1] （1. Saitama Sekishinkai Hospital）

4:20 PM - 4:40 PM

[2N4-J-13-05] Lesion Detection in Computed Tomography Images using YOLOv3 and Domain Knowledge

Akira Saigo[1], ○Naoki Hayashi[2], Kotaro Ito[2] （1. Recruit techonologies Co.,Ltd., 2. NTTDATA Mathematical Systems Inc.）

4:40 PM - 5:00 PM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

MRA 画像を用いた脳動脈瘤検出における 3D-ResNet の優位性

Advantages of 3D-ResNet in Cerebral Aneurysm Detection using MRA Images

寺崎 優希 *1 Yuki Terasaki　横田 元 *2 Hajime Yokota　向井 宏樹 *2 Hiroki Mukai　山内 昌磨 *2 Shoma Yamauchi　黒澤 隆那 *3 Ryuna Kurosawa　太田 丞二 *3 Joji Ota
堀越 琢郎 *2 Takuro Horikoshi　森 康久仁 *4 Yasukuni Mori　須鎗 弘樹 *4 Hiroki Suyari

*1千葉大学大学院 融合理工学府 情報科学コース Graduate School of Science and Engineering, Chiba University
*2千葉大学 医学部附属病院放射線科 Dept. Radiology, Chiba University Hospital
*3千葉大学 医学部附属病院放射線部 Dept. Radiology, Chiba University Hospital
*4千葉大学 大学院工学研究院 Graduate School of Engineering, Chiba University

Cerebral aneurysms are the preliminary stage of serious diseases such as subarachnoid hemorrhage, and it is required to discover them as early as possible in advance. Several studies to automatically detect cerebral aneurysms from MRA images have been proposed, and recently aneurysm detection using CNN has been also extensively undertaken. In some previous studies, two-dimensional images applied the maximum intensity projection (MIP) method to the MRA images were used as input to the CNN. In this study, we take three-dimensional voxels as input for ResNet-based CNN to detect cerebral aneurysms, and compare its sensitivity with conventional 2D-input network. As results of some experiments, we found that our 3D-input network can archive higher advantages in its sensitivity over the 2D-input network.

1. はじめに

脳動脈瘤はくも膜下出血と呼ばれる重大疾患の主要因であり，医師の診断による早期発見が求められる．現場の医師は，診断の初期段階においては磁気共鳴血管画像（Magnetic Resonance Angiography; MRA）に対して最大輝度値投影法（Maximum Intensity Projection; MIP）と呼ばれる画像処理手法が適用された画像を見て，脳動脈瘤を探す．MRA 画像に MIP を適用することで脳動脈を強調した画像が得られるが，このような画像の細部を見て脳動脈瘤を探す作業には多くの時間を要している現状がある．こうした医師の診断を手助けするために，MRA 画像から脳動脈瘤を自動で検出する試みはこれまでにいくつか提案されている．

近年では機械学習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 Networks; CNN）を用いて，人手で設計した特徴量を用いることなく脳動脈瘤を検出する研究が行われており，高い精度で脳動脈瘤を検出できることが報告されている．[Nakao 18] では，医師による診断で用いる画像と同様に，MRA 画像に対して様々な角度から MIP を適用し連結した 2 次元画像を CNN への入力データとして与えているが，動脈の屈折点に隠れた瘤は映らないこと，連結した 2 次元画像の接続点に不要な情報が存在することといった問題がある．

本研究では CNN をベースとしたネットワークに対し，3 次元ボクセルで学習した場合と，従来手法と同様に MIP を適用した 2 次元画像で学習した場合でテストを行い，その検出精度を比較し評価する．

連絡先: 寺崎優希，千葉大学大学院 融合理工学府数学情報科学専攻 情報科学コース，263-8522 千葉市稲毛区弥生町 1-33，email：y_terasaki138@chiba-u.jp

2. 関連研究

これまでに脳動脈瘤を自動検出する手法はいくつか提案されており，MRA 画像を利用した脳動脈瘤検出を行なった例として，Arimura et al. による研究がある [Arimura 04]．この研究では Selective Enhance Filter[Li 04] と呼ばれるフィルターにより脳動脈瘤の候補点を抽出したのち，ルールベースのアルゴリズムで瘤であるかどうかを判定している．Selective Enhance Filter は画像中の塊状部位，線状部位を選択的に強調するフィルタであり，Arimura et al. はこの塊状部位を強調するフィルタを用いて脳動脈の候補箇所を抽出しており，本研究においてもこのフィルタを用いて脳動脈瘤と判定しうる候補箇所を抽出している．

脳動脈瘤検出において [Nakao 18] では，3.0T の MRA 画像に MIP を適用した 2 次元画像で 2 層の CNN を学習し，100 名分のテストデータに対して検出感度 94.2%（at 2.4FP/case）という高い精度を達成している．

本研究では，[He 15] で提案されている ResNet18 をベースとしてネットワークを構成し，各実験を行う．本研究で使用するデータセットは 1.5T, 3.0T 両方の MRA 画像を使用し，かつ撮影機器の設定も各データごとに異なっているものを用いる．

3. データセット

3.1 概要

ネットワークの学習とテストには千葉大学附属病院放射線科より提供していただいた，計 85 名分の患者の MRA 画像を用いる．このうち 60 名分で学習と検証を行い，残りの 25 名分をテストデータとして利用する．学習と検証に用いる 60 名分のデータセットには 62 個，テストに用いる 25 名分のデータセットには 26 個の動脈瘤が含まれている．

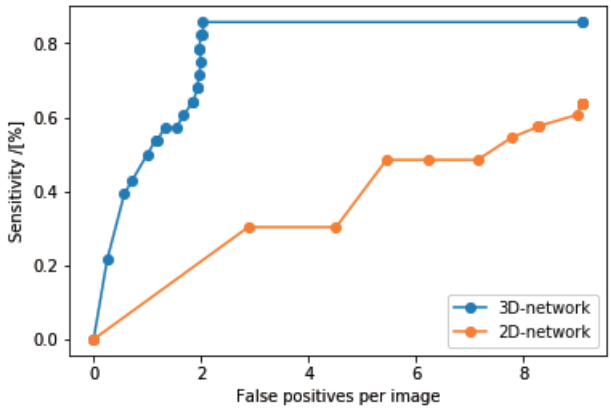


図 1: FROC 曲線

3.2 作成方法

まず，閾値処理をした 3 次元の MRA 画像から，Selective Enhancement Filter により動脈の屈折点や分岐点，瘤状の箇所を抽出する．続いて，抽出した点の周囲で 32 × 32 × 32 のボクセルを取り，瘤を含むボクセルを陽性，全く含まない場所を陰性としてラベル付けする．以上の手順で作成したボクセルは陰性のボクセルが大多数となるため，学習時には陽性のボクセル数が陰性のボクセル数と同数になるようにデータ拡張を行う．また，テスト時についてはデータ拡張は行わない．3D のネットワークに対しては上記手順で作成したボクセルをそのまま入力するが，2D のネットワークに入力する場合は，ボクセルに対して最大輝度値投影法（Maximum Intensity Projection; MIP）を適用した画像を入力とする．

4. 実験

4.1 実験条件

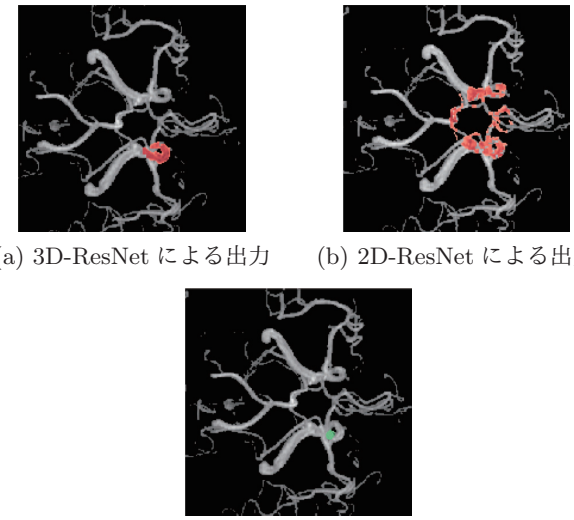
本研究では，[He 15] で提案されている ResNet18 をベースとして層を浅くした，ResNet14 を用いて実験を行う．学習は 3 節で作成した 60 名分のデータを用いて行い，残りの 25 名分のデータでテストを行う．

4.2 FROC による評価

2D-ResNet14 と 3D-ResNet14 のテストデータに対する FROC を図 1 に示す．2D-ResNet14 は 63.6%（at 9.09FP/case）であり，3D-ResNet14 は 85.7%（at 2.0FP/case）となった．同じ深さのネットワークで比較した場合，3D-ResNet14 は 2D-ResNet14 よりも検出感度が高く，かつ偽陽性も少ない結果となった．

4.3 指摘箇所の比較

2D-ResNet14 と 3D-ResNet14 による，同一患者における指摘箇所の例を図 2 に示す．2D-ResNet14 の指摘箇所は偽陽性が多いため画像の全体に渡って分布しているのに対し，3D-ResNet14 による指摘箇所は脳動脈瘤の好発部位である内頸動脈付近にある真陽性の場所を正確に指摘している．現場での医師の診断を支援するシステムとして考えた場合，2D-ResNet14 のように偽陽性が多いとどこに注目すればよいかわからず実用性に乏しいため，2D-ResNet14 では得られた出力からいかにして偽陽性を減らすかが重要な点となる．



(a) 3D-ResNet による出力　(b) 2D-ResNet による出力

(c) Ground Truth

図 2: ネットワークによる指摘箇所の比較

5. まとめ

本研究では MRA 画像から脳動脈瘤を検出するタスクにおいて，3 次元ボクセルによって学習したネットワークと 2 次元 MIP 画像で学習したネットワークでテストし，その検出感度と誤検出率を比較した．実験の結果，3D のネットワークでは検出感度 85.7%，2.0FP/case と 2D のネットワークと比較して高い検出感度で低い誤検出率を得られた．今回の実験では 3D ネットワークの方がより良い結果が得られたが，2D ネットワークは入力する画像の正規化や動脈以外のノイズ除去といった細かい前処理を加えることで精度が大きく変わるため，今後はそうした前処理を加えた場合でも 3D のネットワークと比較する必要がある．

参考文献

[Nakao 18] Nakao T, Hanaoka S, Nomura Y, et al. : Deep neural network-based computer-assisted detection of cerebral aneurysms in MR angiography. J Magn Reson Imaging 2018, 47(4), 948-953.

[Arimura 04] Arimura H, Li Q, Korogi Y, et al. : Automated computerized scheme for detection of unruptured intracranial aneurysms in three-dimensional magnetic resonance angiography. Acad Radiol 2004, 11(10), 1093-1104.

[He 15] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun : Deep residual learning for image recognition, ” CoRR, vol. abs/1512.03385, 2015.

[Li 04] Li Q, H. Arimura, K. Doi : Selective enhancement filters for lung nodules intracranial aneurysms and breast microcalcifications, Int. Congress Series, vol. 1268, pp. 929-934, 2004.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

深層学習を用いた食道癌CT画像の分類

Classification of esophageal cancer CT images using deep learning

瀬戸卓弥 *1 Takumi Seto
竹内優志 *2 Masashi Takeuchi
橋本正弘 *2 Masahiro Hashimoto
伊藤惟 *1 Yui Ito
一原直昭 *2 Nao Ichihara
川久保博文 *2 Hirofumi Kawakubo
北川雄光 *2 Yuko Kitagawa
宮田裕章 *2 Hiroaki Miyata
陣崎雅弘 *2 Masahiro Jinzaki
榊原康文 *1 Yasubumi Sakakibara

*1慶應義塾大学理工学部 Keio University Faculty of Science and Technology
*2慶應義塾大学医学部 Keio University School of Medicine

The prognosis of esophageal cancer is poor, because esophageal tumor can easily penetrate the esophageal wall and directly invade the surrounding organs, in addition to its high malignancy.Therefore, in this study, by performing image recognition learning a CT image of a patient diagnosed as esophageal cancer in the past with a convolution neural network (CNN) and a recurrent neural network (LSTM), it is aimed to construct a system for discriminating the presence or absence of cancer from a new CT image. As a result, we succeeded in a classification model of esophageal cancer using CNN and LSTM, and it to classify with more than 80% accuracy.

1. はじめに

食道癌は、咽頭と胃を繋ぐ管状の臓器である食道に発生する悪性腫瘍であり、膵癌や肝臓癌と並んで予後不良な悪性腫瘍と報告されている。これは、自覚症状が少なく発見が困難なことに加えて、他の多くの臓器を覆っている漿膜が食道には存在しないために、他の臓器への浸潤が比較的早いこと、また早期のものでも悪性度が高く、リンパ節や他の臓器に転移を来たしやすいためである。そのため、食道癌を早期に発見することができる診断支援システムを構築することによって、死亡率を減少させることができる可能性があると考えられる。

食道癌の診断は、主に内視鏡検査、食道造影検査と CT 検査によって行われる。特に CT 検査は、内視鏡検査と比較して簡便であり患者への負担も大きくないため、食道癌の他にも数多くの疾患の経過観察や健康診断によって行われている検査である。CT 検査は多角的な X 線の照射によって行われる。組織によって X 線吸収係数が異なり、X 線の透過量が異なることを利用することで身体の内部構造を撮像することのできる方法であり、体軸方向に連続的に撮像することで、内部構造を 3 次元で表現することが可能である。そのため、単一スライス CT 画像を用いた 2 次元情報のみの診断ではなく、複数枚 CT 画像を用いた 3 次元情報を考慮した診断を行うことができる。

深層学習を用いた診断支援システムは数多く構築されてきた。画像認識に優れた深層学習手法の 1 つである畳み込みニューラルネットワーク (CNN) を用いた CT 画像の分類モデルはその中でも著名なモデルの 1 つである。そこで本研究では、前述の CNN の応用モデルの 1 つである VGG16[Simonyan 14] と再帰型ニューラルネットワーク (RNN) の 1 つである LSTM(Long Short Term Memory) を組み合わせることで、CT 画像のセグメンテーションを行わず、複数枚 CT 画像を用いて学習を行うことのできる学習モデルを提案する。

連絡先: 慶應義塾大学理工学部生命情報学科
〒 223-8522 横浜市港北区日吉 3-14-1
E-mail: yasu@bio.keio.ac.jp

2. 方法

本研究においては、単一 CT 画像による解析、複数枚 CT 画像による解析の 2 つの解析を行うことで比較を行なった。また、本研究においては、慶應義塾大学病院で撮像された CT 画像データのみを用いている。具体的には、食道癌の確定診断がなされた患者 457 人分と、異常所見が見られなかった患者 1,000 人分の合計 1,457 サンプルを使用した。なお、体軸方向に連続的に撮像されているため 1 サンプルにつき複数枚の CT 画像が含まれている。また、本研究は慶應義塾大学医学部および理工学部の倫理委員会より承認を得ている。

2.1 単一スライス CT 画像による解析

2.1.1 作成モデル

作成したモデルは図 1 のような VGG16 をモデルとした学習モデルである。既存の VGG16 に対して Batch Normalization 層を付け加えた VGG16 改変モデルを作成し、全結合層を付け加えることで食道癌か正常かの 2 値分類を可能にした。また、モデルの初期値には、既存の VGG16 を ImageNet で学習したパラメータを用いることで転移学習を行なった。

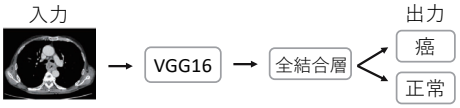


図 1: VGG16 を用いた学習モデル

2.1.2 データの前処理

CT 画像は一般的なデジタル画像と異なり各画素が CT 値と呼ばれる値で表現されている。CT 値は図 2 のように組織によって表現されている。通常は目的組織によって CT 値を制限することでグレースケール画像として学習を行うが、本研究においては、表 1 のように組織によって 3 つの異なる範囲に CT 値に分割することで仮想的に RGB 画像とみなすことで 3 チャネルに入力し、学習を行なった。

2.1.3 正例・負例の選出

単一スライス CT 画像による解析を行うため、1,457 サンプルのそれぞれから 1 枚の CT 画像を選出する処理を行なった。

まず正例については、専門医によって食道癌診断への寄与度

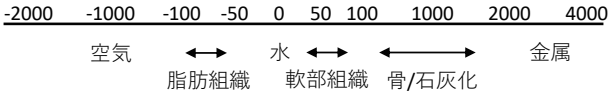


図 2: CT 値と組織

表 1: CT 値の制限

	CT 値の範囲 / HU	対応組織
仮想 R	-70〜50	脂肪・水
仮想 G	-10〜110	水・軟部
仮想 B	50〜170	軟部・骨

の高い CT 画像を選出することで、食道癌判別に重要だと思われる 457 枚の CT 画像を選出し正例とした。

次に負例については 2 つの方法で選出を行なった。1 つ目の手法では、それぞれのサンプルからランダムに 1 枚ずつを選出することで 1,000 枚の CT 画像を選出し負例とした。2 つ目の手法では、選出した 457 枚の正例画像と類似の正常画像を選出した。ImageNet で学習済みの VGG16 を特徴抽出機として正例 1 枚をベクトル化し、正常患者の 1 サンプルに含まれる複数枚 CT 画像も 1 枚ずつベクトル化を行った。その後、ベクトルの cos 類似度がもっとも高い画像を選出した。これによって負例を 1 枚選出した。同様の手法を繰り返し用いることで 1,000 枚の CT 画像を選出し負例とした。

2.1.4 判断根拠の可視化

画像分類を行う深層学習手法においては、判断根拠がわからないという問題点が指摘されてきた。そこで本研究では判断根拠の可視化手法の 1 つである SmoothGrad[Smilkov 17] を用いて判断根拠の可視化を行なった。

2.2 複数枚 CT 画像による解析

2.2.1 作成モデル

作成したモデルは図 3 のようになっている。図中の VGG16 は前節で学習済みのモデルであり、特徴抽出機として用いることで入力である複数枚 CT 画像をそれぞれベクトル化し、軸方向に連続的に撮像された複数枚 CT 画像を ”時系列データ” とみなすことで LSTM の入力とすることで 2 値分類を行うモデルを作成した。本モデルでは VGG16 の学習は行わず、LSTM と全結合層のみ学習を行なった。

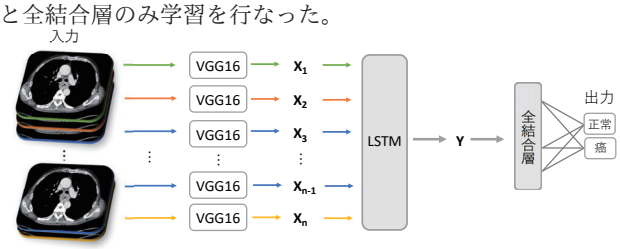


図 3: VGG16 と LSTM を用いた学習モデル

2.2.2 正例・負例の選出方法

まず正例については、前節と同様に食道癌診断への寄与度が高い CT 画像をサンプルごとに 1 枚選出した。その後、選出した画像に対して、体軸方向に上側 3 枚と下側 4 枚の CT 画像を付け加え、1 サンプル当たり 8 枚で構成されたデータを作成した。これにより 457 個の正例を作成した。次に負例については、サンプルごとにランダムで 1 枚ずつ合計 1,000 枚の CT 画像を選出した後、正例と同様の方法で 1 サンプル当たり 8 枚の CT 画像により構成されたデータを作成した。これにより 1,000 個の負例を作成した。

3. 結果

分類結果の比較は表 2 のようになった。表 2 を参照すると、学習データに単一スライス CT 画像を用いた場合、負例をランダムで選出した方がより高精度で分類できていることがわかる。これは、類似画像を負例として選出する場合、より難しい問題設定になっているためだと考えられる。また、学習データに複数枚 CT 画像を用いることでより高精度で分類を行うことができていることがわかる。これは 3 次元情報を考慮した分類を行うことができたためであると考えられる。

また、SmoothGrad による判断根拠の可視化を行なった結果は図 4 のようになった。図中の左には入力画像を添え食道部分にアノテーションを付けてあり、図中の右に可視化画像を提示した。これにより、食道部だけでなく他の臓器や身体の概形も合わせて判断根拠としていることがわかった。

表 2: 分類結果の比較

手法	データ種類	仮想 RGB	負例	AUC	F 値
VGG16 ベース	単一枚	なし	ランダム	0.921	0.820
VGG16 ベース	単一枚	あり	ランダム	0.957	0.875
VGG16 ベース	単一枚	あり	類似画像	0.961	0.827
VGG16+ LSTM	複数枚	あり	ランダム	0.980	0.876

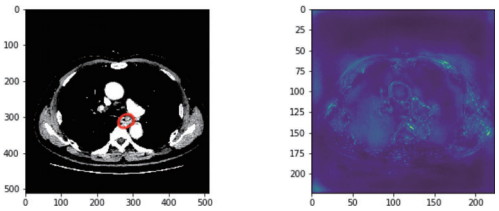


図 4: 判断根拠の可視化

4. 終わりに

食道癌 CT 画像データと正常胸部 CT 画像データを用いて CNN(VGG16) と LSTM により構成された学習モデルの学習を行うことで、食道癌診断支援システムの構築を行なった。単一スライス CT 画像を用いた場合と複数枚 CT 画像を用いた場合の比較を行うことで、複数枚 CT 画像を用いて 3 次元情報を考慮する有効性を示した。また、判断根拠の可視化を行うことで、深層学習が食道だけでなく他の臓器の概形などにも注目して判断していることが示唆された。

参考文献

[Simonyan 14] Simonyan, Zisserman: Very deep convolutional networks for large-scale image recognition, arXiv preprint arXiv:1409.1556, 2014.

[Smilkov 17] Smilkov, Daniel and Thorat, Nikhil and Kim, Been and Viégas, Fernanda and Wattenberg, Martin: Smoothgrad:removing noise by adding noise, arXiv preprint arXiv:1706.03825,2017

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

心拍変動解析とオートエンコーダによるてんかん発作予知アルゴリズムの開発

Development of Epileptic Seizure Prediction Algorithm by Combining Heart Rate Variability Analysis and Autoencorder

藤原 幸 *1*2 Koichi FUJIWARA　坂根 史弥 *2 Fumiya SAKANE　宮島 美穂 *3 Miho MIYAJIMA　山川 俊貴 *4 Toshitaka YAMAKAWA　加納 学 *2 Manabu KANO
前原 健寿 *3 Taketoshi MAEHARA

*1名古屋大学 Nagoya University　*2京都大学 Kyoto University　*3東京医科歯科大学 Tokyo Medical and Dental University　*4熊本大学 Kumamoto University

Epileptic seizures should be predicted before their onsets to avoid injuries or accidents of patients. The RR interval (RRI) fluctuation in an electrocardiogram (ECG), called heart rate variability (HRV), is a well-known phenomenon which reflects the autonomic nervous function, and changes in HRV in preictal phase have been reported. We developed an epileptic seizure prediction algorithm by combining HRV analysis and an anomaly detection technique. This work adopted autoencoder for anomaly detection. The application result to clinical data collected from 66 patients with focal epilepsy showed that the average sensitivity was 75.3%, and the average false positive rate was about 2.49 times per hour, which was worse than a previous report. However, the proposed algorithm functioned well for almost all patients, and did not apply for specific a few patients. The future work will clarify in which types of patients the epileptic seizure prediction algorithm does not function.

1. はじめに

てんかんとは，大脳ニューロンの過剰な放電に由来する反復性の発作を特徴とする慢性の脳疾患である．てんかん患者は全国に約 100 万人おり，このうち 30%以上のてんかん患者は，抗てんかん薬を服薬しても，てんかん発作を抑制できない難治性てんかんを患っている [1]．てんかん発作を発作起始前に予知できれば，即効性抗てんかん薬や迷走神経刺激療法を用いた発作抑制あるいは軽減ができると期待される．これにより，てんかん発作に伴う重大な事故や怪我が予防できるため，難治性てんかん患者の生活の質 (quality of life; QoL) の改善が期待できる [2]．このように発作予知に基づいて発作起始の前に介入をすることで，発作を抑制または軽減する治療法を Closed-Loop てんかんケアと呼ぶ．

脳波 (electroencephalogram; EEG) を用いたてんかん発作予測は，これまでも試みられてきた [3, 4]．しかし，EEG はアーチファクトに弱く，その測定のために身体の動きは制限されてしまうために日常的に用いることは難しい．てんかん患者の約 80%は長時間 EEG 電極をつけたくないとする報告もある [5]．一方，心拍パターン変化は，ウェアラブルデバイスなどを用いることで容易に測定できる [6]. 焦点性発作では，臨床上のてんかん発作が起始する前に，てんかん発作に伴って発生するてんかん放電が自律神経系を支配する脳幹に影響を与え，その影響が心拍パターン変化として表れるという報告 [7, 8] がなされている．これに基づき Fujiwara らは，心拍変動（heart rate variability; HRV）解析と異常検出手法のひとつである多変量統計的プロセス管理 (multivariate statistical process control; MSPC) とを用いた，覚醒時てんかん患者のてんかん発作予測アルゴリズムを開発した [9]．

難治性てんかん患者は，発作予測技術を用いても予測できない発作を恐れているという報告がある [5, 10]．また，Closed-Loop てんかんケアにおいては，偽アラームによる投薬や神経刺激などの患者への不必要な介入は好ましくない．そのため，包括的なてんかんケア実現には，よりてんかん発作の予知精度を改善していく必要がある．

そこで本研究では，HRV 解析と autoencoder (AE) とを用いた，新たなてんかん発作予測アルゴリズムを提案する．さらに，従来法である MSPC，One-class サポートベクターマシーン (One-class support vector machine; OCSVM) および Local outlier factor (LOF) による発作予測アルゴリズムと，提案法による発作予測精度を臨床データを用いて比較する．

連絡先: 藤原幸一, 名古屋大学工学研究科物質プロセス工学専攻, 名古屋市千種区不老町, fujiwara.koichi@material.nagoya-u.ac.jp

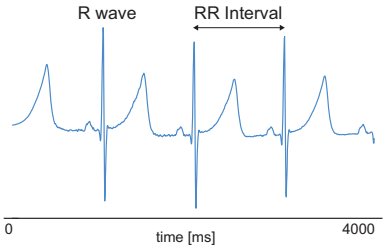


図 1: 典型的な ECG 波形

2. 心拍変動解析

本節では，HRV 解析 [11] について紹介する．

2.1 RR 間隔

典型的な ECG 波形を図 1 に示す．ECG 波形はいくつかのピークから構成されているが，最も高いピークを R 波と呼び，R 波と次の R 波の間隔 [ms] を RR 間隔（RRI）という．

2.2 時間領域指標

時間領域指標は，RRI データより直接計算できる．

- **meanNN**: RRI の平均値．

- **SDNN**: RRI の標準偏差.
- **RMSSD**: 隣接する RRI の差の根平均二乗.
- **Total power**: RRI の分散.
- **NN50**: ある時間内に隣接する RRI の差が 50 msec を超えるペアの個数.

2.3 周波数領域指標

RRI データは等間隔に取得されていないため，そのまま周波数領域指標を計算することは難しい．そこで，スプラインなどを用いて RRI データを補間し，等間隔にデータをリサンプリングする．周波数領域指標は，リサンプリングされた RRI データのパワースペクトル密度（power spectrum density; PSD）より求めることができる．ここで，RRI データの PSD の計算には，Fourier 変換または自己回帰（autto regression; AR）モデルを用いることができる．

- **LF**: PSD の低周波領域 (0.04Hz - 0.15Hz) のパワー． 交感神経活動を反映しているとされる．
- **HF**: PSD の高周波領域（0.15Hz - 0.4Hz）のパワー．副交感神経活動を反映しているとされる．
- **LF/HF**: LF と HF の比． 交感神経活動と副交感神経活動のバランスを表す．

医学的な HRV 解析ガイドラインでは，周波数解析を正確に行うには，RRI データを少なくとも 2 分間計測すること，および ECG サンプリング周波数は 200Hz 以上とすることが推奨されている [11]．本研究では周波数領域指標の算出のため，RRI の補間には 3 次スプラインを用い，AR モデルにて PSD を計算した．時間窓は 3 分とした．

3. HRV データによるてんかん発作予知

てんかん発作予知では，発作のない期間（発作間欠期）のデータを正常データとして，異常データは発作前後の期間（発作周辺期）のデータとなるが，てんかん患者からモデル構築に十分な量の発作周辺期データを収集するのは容易ではない．その一方で，てんかん患者の発作間欠期データや健常者データは，発作周辺期データと比較して容易に収集できる．

このような問題は，正常データに混入している一部の異常なデータを検出する異常検出というタスクとして考えることができる．異常検出の場合は，正常なデータがあればモデルが構築できるため，発作などの異常データを大量に収集しなくてもよい．異常検知アルゴリズムは任意のものを使用できるが，本研究ではこれまでに，発作予知モデル構築に多変量統計的プロセス管理（multivariate statistical process control; MSPC），one class support vector Machine (OCSVM)，local outlier factor (LOF)，オートエンコーダ（AE）などを適用，比較した．

本稿では，AE を用いた発作予知モデル構築について述べる．

3.1 autoencoder

AE とは，学習データのみを用いて，入力と等しい出力が得られるように学習させるニューラルネットワークの一種である．Figure 2 に AE の概念を示す．Figure 2 で $x_1, \cdots, x_4$ は入力変数，$\hat{x_1}, \cdots, \hat{x_4}$ は出力変数であり，図中の丸をユニットと呼ぶ．各ユニットでは，複数の入力の線形和にバイアスと呼ばれる定数を加え，さらに活性化関数を作用させることで出力が得られる．

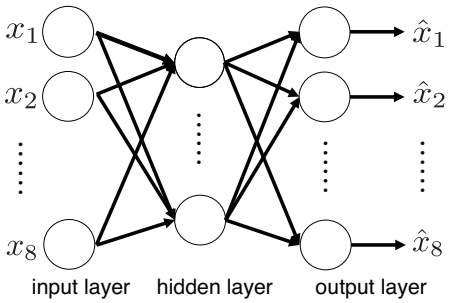


図 2: Autoencoder

学習プロセスでは出力を入力値に近づけるように，コスト関数の最小化を目指す．コスト関数を最小にする重みとバイアスは，確率的勾配降下法によって求める．本研究では，以下の式 (1) で表される変形された平均二乗誤差関数をコスト関数として採用している．

$$E = \frac{1}{K}\sum_{k=1}^{K} \|\boldsymbol{x_k} - \hat{\boldsymbol{x}}(\boldsymbol{x}_k)\|^2 + \lambda \times \Omega_w + \beta \times \Omega_s \qquad (1)$$

ただし，K はサンプル数，$\boldsymbol{x}_k$ と $\hat{\boldsymbol{x}}(\boldsymbol{x}_k)$ はそれぞれ k $(1 \leq k \leq K)$ 番目のサンプルの入力変数ベクトル，対応する出力変数ベクトルである．λ，β はそれぞれ $L2$ 正則化項，スパース正則化項の係数である．コスト関数にスパース正則化項を追加することで，隠れ層からの出力のスパース性に制約を課すことができる．しかし，重み $w_{ij}^{(1)}$ の値を大きく，$z_i^{(1)}$ の値を小さくすることで，スパース正則化項は小さくできる [17]．そのため，$L2$ 正則化項をコスト関数に追加することで，重みが過度に大きくなることを防いでいる．

AE は入力とできるだけ近い出力を得るモデルであるから，入力と出力の誤差が著しく大きくなったときは，学習させた入出力間の関係が変化したと考えられる．すなわち，AE ではそのような変化を異常として検出できる．本研究では，再構築誤差 RE として入力と出力の誤差の L_1 ノルムを採用し，RE が予め定められた管理限界を超過したときに異常が発生したとみなす．

$$RE = ||\hat{\boldsymbol{x}} - \boldsymbol{x}||_1 = \sum_{k=1}^{K} |x - x_k| \qquad (2)$$

3.2 発作予知アルゴリズム

HRV 解析と AE を組み合わせることで，てんかん患者の自律神経機能を監視する．Algorithm 1 に，モデル構築手順を

Algorithm 1 AE による発作予知モデル構築

1: i 番目のてんかん患者 $(i = 1, \cdots, I)$ の発作間欠期に採取した RRI データ $\boldsymbol{y}_i$ より HRV 指標 $\tilde{\boldsymbol{X}}^{\{i\}}$ を計算する．
2: $\tilde{\boldsymbol{X}}^{\{1\}}, \cdots, \tilde{\boldsymbol{X}}^{\{I\}}$ をひとつの行列 $\tilde{\boldsymbol{X}}$ にマージする．
3: $\tilde{\boldsymbol{X}}$ を適切に標準化し，標準化後の行列を $\boldsymbol{X}$ とおく．
4: AE の学習を行う．
5: 患者ごとに適切な RE の管理限界 $\overline{RE}$ を決定する．

Algorithm 2 HRV によるモニタリング

$\tau[0] \longleftarrow 0$，$C[0] \longleftarrow \mathcal{N}$ と設定する．
while do
　センサより t 番目 RRI $y[t]$ を取得する．
　HRV 指標 $\tilde{\boldsymbol{x}}[t]$ を算出する．
　$\tilde{\boldsymbol{x}}[t]$ を標準化し，これを $\boldsymbol{x}[t]$ とする．
　AE を適用し，式 (2) より再構築誤差 $RE[t]$ を求める．
　if $(RE[t] > \overline{RE}) \wedge (C[t-1] = \mathcal{N}))$
　　$\vee((RE[t] \leq \overline{RE}) \wedge (C[t-1] = \mathcal{A}))$ **then**
　　$\tau[t] = \tau[t-1] + y[t]$.
　else
　　$\tau[t] = 0$.
　end if
　if $\tau[t] \geq \mathrm{T}$ **then**
　　$C[t] = \neg\, C[t-1]$ and $\tau[t] = 0$.
　end if
　$t+1$ 番目の RRI データ $y[t+1]$ が取得されるまで待機する．
end while

示す．$\boldsymbol{y}^{\{i\}}$ は i 番目の患者の発作間欠期に採取した RRI データである．そして RRI データから 2 節に記載の HRV 解析手法を用いて HRV 指標 $\tilde{\boldsymbol{X}}^{\{i\}}$ を算出し，それらを I 人分集めて AE を学習させる．HRV 指標には個人差が存在するため，それぞれの患者に適した管理限界を設定する必要がある．

発作予知は，Algorithm 2 の手順で実施される．ここで，$y[t] \in \Re$ はセンサで取得された t 番目の RRI である．τ はカウンタ，C は 2 値の状態 $C = \{\mathcal{N}, \mathcal{A}\}$ であり，$\mathcal{N}$，$\mathcal{A}$ はそれぞれ正常と異常を表す．すなわち，$\neg\mathcal{N} = \mathcal{A}$ であり，本アルゴリズムでは予め定めた時間 T 以上連続して再構築誤差 RE が管理限界 $\overline{RE}$ を超過しない限り，状態 C は $\mathcal{A}$ に遷移しないものとする．これはアーチファクトが ECG に混入すると，RE が大きく変動するためである．最終的に HRV データより異常が検出されると，患者に通知される．

4. 臨床データへの適用

東京医科歯科大学病院，東北大学病院，国立精神・神経医療研究センター，大阪大学病院，東京大学病院，奈良医療センタにおけるてんかん外科手術の術前検査時に，局在関連てんかん患者の発作間欠期および発作周辺期 RRI データを収集した．また，一部，ヨーロッパてんかんデータベースからもデータを収集した [20]．本臨床データ収集および解析は，東京医科歯科大学倫理委員会ほか各施設において倫理委員会の承認を受けて行った．ビデオ脳波モニタリングシステム（日本光電製 Neurofax EEG-1200）を用いて，てんかん患者の発作ビデオ，ECG，EEG データを記録した．これらの検査はシールドルームにて実施した．アーチファクト混入など解析に適さない区間のデータを除外した上で，EEG データと発作ビデオに基づいて，日本てんかん学会認定医 2 名が発作起始時刻を正確に同定した．次に発作起始前 15 分から発作起始後 5 分の計 20 分の ECG データを，発作周辺期 ECG データとして切り出した．一方，発作予知アルゴリズム構築のために，発作間欠期に記録された ECG データをいくつか切り出し発作間欠期 ECG データとした．

最終的にてんかん患者 66 名（男性 45 名，女性 21 名，年齢 13-67 歳）より合計約 270 時間分のデータを収集し，44 名の患者から 85 回の発作が記録された．収集された ECG データより R 波を検出して RRI を計算，さらに HRV 指標を求めた．約 78 時間分の発作間欠期データを学習データとして，AE を用いた発作予知を試みた．ここで中間層は 6 層とし，ハイパーパラメータは $\rho = 0.0033$，$\lambda = 0.0022$，$\beta = 0.97$ とした．中間層，出力層における活性化関数はそれぞれ，ロジスティックシグモイド関数，線形関数とした．

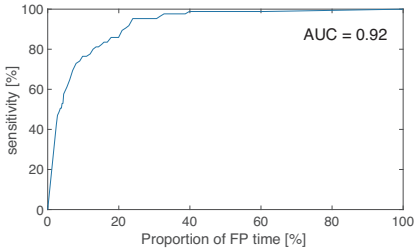


図 3: ROC curve for all patients

この結果，全患者平均で感度は 75.3%，擬陽性頻度は 2.49 回/h であり，この成績は先行研究と比較して低下している [9]．発作が記録された 44 名の患者における受信者動作特性（receiver operating characteristic; ROC）曲線と AUC（area under the curve）を図 3 に示す．縦軸は感度 [%] であるが，擬陽性率時間率 [%]，すなわち予知対象時間に対して擬アラームが発報した時間の割合を表している．

しかし，実際には患者によって，発作予知が成功するかが異なっている．図 4 に発作が記録された 44 名の患者ごとの AUC の分布をまとめた．この図より 44 名の患者のうち 37 名が AUC が 0.9 以上であり発作予知が有効であるが，7 名の患者において発作が予知ではないことがわかる．図 5，6 に発作予知が有効な患者 A と有効でない患者 B の，発作予知結果を示す．図上段が発作間欠期，図下段が発作周辺期における予知結果であり，破線は管理限界，縦線が発作起始時刻を表している．図 6 からわかるように，患者 B では多くの擬陽性が発生している．先行研究で高い発作予知性能を達成していた理由として，解析に用いている臨床データの患者数が，症例を注意深く選択していたため 14 名と少なく，発作予知が困難な患者があまりデータに含まれていなかったためだと思われる．

今回の解析結果より，多くのてんかん患者では将来的に発作予知が有望な治療法となりうることがわかった．その一方で，少数の患者では発作予知は有効ではない．このような患者がてんかん発作予知システムを使用すると，発作の見逃しによって事故や怪我につながりかねず，誤アラームが頻発すると煩わしさを感じてしまう，また，Closed-Loop てんかんケアにおいては，偽アラームによる投薬や神経刺激などの患者への不必要な介入の原因となりかねない．したがって，今後は性別や年齢，てんかん症候群，服薬している抗てんかん薬など，どのようなタイプの患者であれば発作予知が有効であるか，臨床データのみならずてんかん発作と HRV の生理学的関係からも解明する必要がある．

5. まとめと今後の展望

本研究では，HRV 解析と AE を用いたてんかん発作予知アルゴリズムを提案した．提案法を臨床データに適用したところ，多数の患者では有効であるが，一部患者において発作が適切に予知できないことが明らかとなった．今後は，発作予知が有効である患者群を確認していく必要がある．

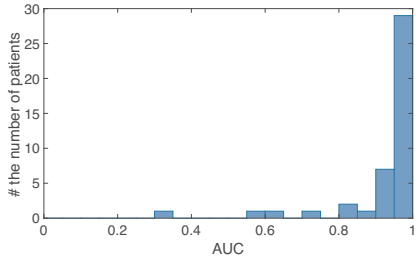


図 4: AUC Distribution

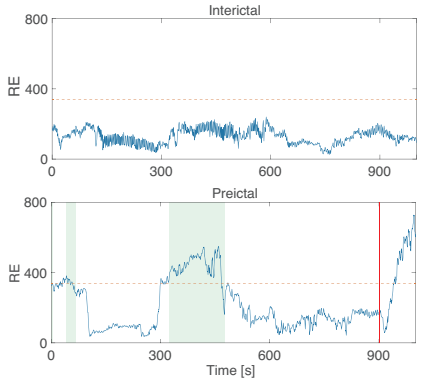


図 5: Seizure prediction result of Patient A

すでに我々の開発したてんかん発作予知システムは，2014 年より東京医科歯科大学付属病院などで臨床試験を開始している．また，2017 年度より AMED 先端計測プログラム（要素技術開発タイプ）に採択され，開発を加速している．本稿ではアルゴリズム面を中心に述べたが，シャツ型電極など HRV を容易に取得するためのセンサの開発も並行して実施している．

てんかん発作予知システムは，医療機器の一般的名称として「てんかんアラーム」という認証基準のないクラス 2 の医療機器に該当する．このため，上市には治験を行い有効性および安全性について確認し，規制当局によって承認を受ける必要がある．すでに規制当局とは将来の治験に向けて薬事相談をしており，数年内に治験を開始したいと考えている．

謝辞

本研究の一部は，AMED 先端計測プログラム #171122，JST さきがけ #JPMJPR1859，JSPS 卓越研究員制度，セコム科学技術振興財団，住友電工グループ社会貢献基金から助成を受けて実施された．

参考文献

[1] P. Kwan and M. Brodie: Early identification of refractory epilepsy, *NEJM*, **342**(5), 314-319 (2000)

[2] S. Ramgopala et al.: Seizure detection, seizure prediction, and closed-loop warning systems in epilepsy, *Epilepsy Behav.*, **37**, 291-307 (2014)

[3] F. Mormann et al.: Seizure prediction: The long and winding road, *Brain*, **130**(2), 314-333 (2007)

[4] K. Gadhoumi et al.: Seizure prediction for therapeutic devices: a review, *J Neurosci Methods*, **260**, 270-282 (2016)

[5] A. Schulze-Bonhage et al.: Views of patients with epilepsy on seizure prediction devices, *Epilepsy Behav.*, **18**(4), 388-396 (2010)

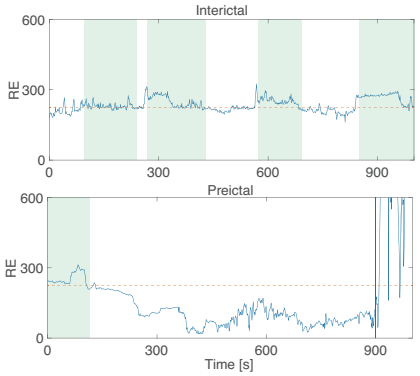


図 6: Seizure prediction result of Patient B

[6] T. Yamakawa et al.: Real-time heart rate variability monitoring employing a wearable telemeter and a smartphone, *Proc. Asia-Pacific Signal Inf. Process. Assoc. Annu. Summit Conf., Kaohsiung, Taiwan, Oct. 29, 2014-Nov. 1*, 1-4 (2014)

[7] F. Leutmezer et al.: Electrocardiographic changes at the onset of epileptic seizures, *Epilepsia*, **44**(3), 348-354 (2003)

[8] K. Kato et al.: Earlier tachycardia onset in right than left mesial temporal lobe seizures, *Neurology*, **83**(15), 1332-1336 (2014)

[9] K. Fujiwara et al.: Epileptic seizure prediction based on multivariate statistical process control of heart rate variability features, *Bio-Med Eng. IEEE*, **63**(6), 1321-1332 (2016)

[10] D. T. Quiroga et al.: Patient and caregiver view on seizure detection devices: A survey study, *Seizure*, **41**, 179-181 (2016)

[11] A. J. Camm et al.: Guidelines heart rate variability: standards of measurement, physiological interpretation, and clinical use, *Eur. Heart J.*, **17**, 354-381 (1996)

[12] E. Abe et al.: Development of drowsiness detection method by integrating heart rate variability analysis and multivariate statistical process control, *SICE JCMSI*, **9**(1), 010-017 (2016)

[13] B. Schölkopf et al.: Estimating the support of a high-dimensional distribution, *Neural Comput.*, **13**(7), 1443-1471 (2001)

[14] M. Breunig et al.: LOF: Identifying Density-Based Local Outliers, *Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data*, **29**(2), 93-104 (2000)

[15] M. Kano et al.: A new multivariate statistical process monitoring method using principal component analysis, *Comput Chem Eng.*, **25**(7-8), 1103-1113 (2001)

[16] P. Momikos, J. MacGregor: Monitoring batch processes using multiway principal component analysis, *AIChE J.*, **40**(8), 1361-1375 (1994)

[17] B. A. Olshausen and D. J. Field: Sparse Coding with an Overcomplete Basis Set: A Strategy Employed by V1, Vision Res., **37**(23), 3311-3325 (1997)

[18] N. Gosselin et al.: Age difference in heart rate changes associated with micro-arousals in humans, *Clin Neurophysiol*, **113**(9), 1517-1521 (2002)

[19] S. M. Oppenheimer et al.: Cardiovascular effects of human insular cortex stimulation, *Neurology*, **42**(9), 1727-1732 (1992)

[20] `http://epilepsy-database.eu/`

オンプレミス深層学習による頭部 CT 画像診断の試み

Diagnosis of head CT image by on-premise deep learning

白石　哲也[*1]　　土方　友莉子[*2]
Tetsuya Shiraishi　　Yuriko Hijikata

[*1] 埼玉石心会病院ﾘﾊﾋﾞﾘﾃｰｼｮﾝ科　　[*2] 同診療部
Rehabilitation Medicine, Saitama Sekishinkai Hospital　　Clinical Department

We studied whether cerebral hemorrhage can be diagnosed correctly by deep learning with convolutional neural network using CT images taken at our hospital. Data processing techniques such as trimming-off and augmentation improved the precision rate of image classification. Generally, a large amount of image data is required for deep leaning. However, it is often difficult to collect many cases in one hospital. Our results suggest the possibility of on-premise medical image recognition with deep learning in the future.

1. 概要

当院で撮影された頭部 CT 画像を用い、CNN(Convolutional Neural Network)を用いた教師あり学習により、脳出血を正しく画像診断できるかどうかを検討した。データを加工せずに解析を行った場合の認識率は低かったが、データのトリミング、データの水増しそして活性化関数や畳み込み層の最適化によって高い認識率が得られた。一般的に深層学習には大量の画像データが必要とされているが、少ない画像データでも高い認識率が得られた事は、今後オンプレミスでの人工知能開発の可能性を示唆するものである。

2. 目的

深層学習（Deep Learning：以下 DL と略す）を用いた人工知能(AI)アルゴリズムの中でも、CNN(Convolutional Neural Network)[Krizhevsky, 2012]は非常に高い画像解析能力を持っており、医療画像診断分野への応用が期待されている[Chartrand, 2017]。深層学習を画像認識分野に適応するにあたっては、大量の教師ありデータが必要とされている。そのため、保険医療分野 AI 開発加速コンソーシアムでは、高いセキュリティを持つ「厚労省認定メディカルクラウド」の設立を通して、全国の病院からの症例データ蓄積を目指している。どんなに高度なセキュリティであっても、破られる可能性が皆無ではないため、院内の個人データを院外に持ち出すことに躊躇する病院がたくさん出てくるのではないかと考えられる。個人情報及びメンテナンスの観点からは病院内で完結するオンプレミス型の開発が望ましいと考えられる。

オンプレミス型の開発には、少量のデータであっても高い画像認識率を得られる工夫が必要である。本研究では、当院で実施された頭部 CT 画像を用い、少量の画像データに対して、各種データ加工技術を加えることと、データ解析法を工夫することにより、画像診断に耐えられるだけの高認識率が得られるかどうかを検討した。

3. 方法

3.1 倫理面の配慮

当院の画像データを安全な個人情報管理のもとで使用するために、当院倫理委員会の承認(承認番号：30-37 号)を得た上で、個人を特定できる情報を除いたデータの選定と診療情報管理室におけるダブルチェックを行った。また解析に用いる個人用 PC は外部ネットワークと遮断した状態でコマンドを実行した。

3.2 対象症例

対象症例は 2017 年 11 月 1 日から 2018 年 10 月 31 日に当院で撮影した頭部 CT 画像の中で、脳出血あるいは脳出血疑いと診断された症例を用いた。頭部 CT のスキャンレベルは、脳出血の中でも頻度の高い視床出血及び被殻出血が描出されるモンロー孔レベルを選択した。頭部 CT で次の所見が認められる症例は除外した。すなわち陳旧性脳梗塞、複数病変、中等度以上の脳萎縮、著明なアーチファクトである。

今回の研究で用いた症例のカテゴリー識別番号と症例数を 2 クラス分類問題と 8 クラス分類問題に分けて表 1 に示した。

表 1　対象症例の識別番号、カテゴリー名および症例数

識別番号		カテゴリー名	症例数
2 分類	8 分類		
0（正常）	0	正常	145
1（異常）	1	被殻出血	33
	2	視床出血	26
	3	皮質下出血	13
	4	慢性硬膜下血腫	61
	5	くも膜下出血	9
	6	脳室内出血	8
	7	混合型基底核出血	8

連絡先：白石哲也，埼玉石心会病院リハビリテーション科，
tetsuya-shiraishi@saitama-sekishinkai.org

3.3 画像データ加工と深層学習開発環境

頭部 CT 画像データの加工には Adobe Photoshop CC 2019 を使用した。図 1 のようにオリジナル画像(左)の頭蓋周辺の背景をトリミングし、解像度を 64x64 に変更した。

次に、データ水増し(Data Augmentation:以下 DA)処理を図 2 に示す。オリジナル画像(上段左)を時計方向(上段中)および反時計方向(上段左)に 2° 回転した。さらにオリジナル画像を左右反転した画像(下段左)に対して同様の画像回転処理を行った。

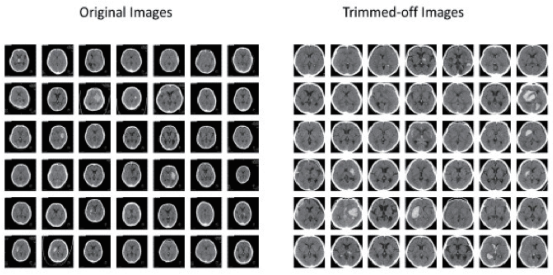


図 1　オリジナル画像とトリミング処理をした画像

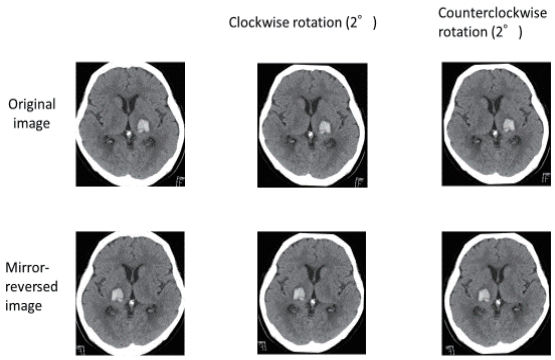


図 2　オリジナルおよび左右反転画像と回転画像

データセットの作成、ニューラルネットワークの構築そして学習・評価には、深層学習プログラム生成統合開発環境である SONY の Neural Network Console(windows 版)ver.1.20 を使用した。

4. 結果

4.1 2 クラス分類問題

解析には 3 層の畳み込み層/プーリング層を有する畳み込みニューラルネットワーク CNN を用いた。中間層の活性化関数は tanh 関数を、出力層にはシグモイド関数を用いて 2 値分類を行った。オプティマイザーは Adam を用い、パラメータは Learning Rate α=0.001, β1=0.9、β2=0.999、ε=1e-08 とした。オリジナル画像とトリム画像に対して DA の有無別に、合計 4 種類の画像入力データを用いて解析を行った。

y:label=0(正常)の認識率は 0.9825、y:label=1(異常)の認識率は 0.9787 であった.

データ加工と認識率の関連については、オリジナル画像のみの認識率が 0.6666 であったのに対し、DA を行ったデータの認識率は 0.9472 と大幅に上昇した。またトリム画像のみの認識率は 0.8166 であったが、DA を追加した場合データの認識率は 0.9805 と認識率の改善を認めた。

4.2 8 クラス分類問題

解析には 3 層の畳み込み層/プーリング層を有する畳み込みニューラルネットワーク CNN を用いた。中間層の活性化関数は Swish 関数あるいは LeakyReLU を用い、2 層目の畳み込み層には Depthwise Convolution を用いた。出力層にはソフトマックス関数を用いて 8 値分類を行った。オプティマイザーは Adam を用い、パラメータは Learning Rate α=0.001, β1=0.9、β2=0.999、ε=1e-08 とした。

認識率は、0.983(ラベル 0:正常)、0.977(1:被殻出血)、1.000(2:視床出血)、1.000(3:皮質下出血)、0.973(4:慢性硬膜下血腫)、1.000(5:くも膜下出血)、1.000(6:脳室内出血)、0.889(7:混合型基底核出血)であった。

データ加工と認識率の関連については、オリジナル画像データに DA を追加したデータの認識率が 0.9065 であったのに対し、トリム画像に DA を追加したデータの認識率は 0.9807 であり、トリム画像を使用した方が、認識率の改善が得られることが示された。

5. 考察

8 分類課題では、10 例前後と非常に少ない症例数でも、トリミングやデータ水増しの前処理を行い、さらにネットワーク構造をチューニングする事で、高い認識率を達成することが出来た。このことは、一つの病院で経験されるデータのみを用いても、精度の高い画像診断 AI を構築することが出来る可能性があることを示唆している。

このように少数のデータで高い認識率を達成出来たのは、頭部 CT 画像がもつ特徴が関係していると思われる。すなわち、画像ノイズが少ないこと、左右反転した画像も同じ価値を持つこと、頭部の位置の微妙なズレによりもともとある程度の回転画像になっていることなどである。

医用画像には撮像部位の違いや用いる物理パラメータの違いにより様々なものが存在する。しかし、それぞれの画像の特徴に応じた、データ加工技術を用いることで、画像認識の適応範囲を広げることが出来ると思われる。

参考文献

[Krizhevsky 2012] Krizhevsky A, Sutskever I, Hinton GE: ImageNet classification with deep convolutional neural networks. Advances in Neural Information Processing System 25 (NIPS 2012), 2012.

[Chartrand 2017] Chartrand G, Cheng PM, Vorontsov E, et al.: Deep learning: a primer for radiologists. RadioGraphics 37:2113-2131, 2017

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

YOLOv3とドメイン知識を用いたCT画像の病変部位検出

Lesion Detection in Computed Tomography Images using YOLOv3 and Domain Knowledge

西郷 彰 *1　林 直輝 *2　伊藤 孝太朗 *2
Saigo Akira　Hayashi Naoki　Ito Kotaro

*1株式会社 リクルートテクノロジーズ アドバンスドテクノロジーラボ
Recruit Technologies Co., Ltd. Advanced Technology Lab.

*2株式会社 NTTデータ数理システム シミュレーション&マイニング部
NTTDATA Mathematical Systems Inc. Simulation & Mining Division

Lesion detection in computer tomography (CT) images using deep neural networks (DNN) have been researched in computer-aided detection area. A dataset of large-scale annotated CT images, called DeepLesion, has also been published. However, the conventional lesion detection method needs many false positives per a image (FPI) to realize high sensitivity. Besides, it uses a constant CT value for all images in DeepLesion, thus there is a divergence from the medical site. On the other hand, one after another object detection methods have been proposed in the DNN community. In this study, we carried out experiments for FPI to decrease using You Only Look Once version 3; a novel object detection method. We also use medical setting CT value each image to bring it closer to the site. The experimental results show that our method is more accurate than conventional one in the sense of the sensitivity given same average FPI.

1. はじめに

画像解析分野において，畳み込みニューラルネットワーク（convolutional neural network, CNN）[2] が成功を収めている．CNN は多層のニューラルネットワークと畳み込み演算を用いて，入力画像から特徴量を自動抽出することが可能で，従来の人手による特徴量設計を用いた統計的画像認識技術を上回る認識性能を持つ．医療画像解析においても応用されており，皮膚可視画像 [1]，レントゲン画像 [3]，計算機断層撮影（computer tomography, CT）画像 [6]，磁気共鳴画像（Magnetic Resonance Imaging, MRI）[7] などが挙げられる．CNN の学習には大量の画像データが要求されるが，CT 画像については DeepLesion と呼ばれる大規模データセットが公開されており，これを用いた病変部位検出手法が提案されている [6]．しかし，検出対象の CT 画像 1 枚につき多くの偽陽性のバウンディングボックス（bounding box, BB）の出現を許容しなければ高い感度 *1 を実現することはできなかった．

深層学習を用いた物体検出（深層物体検出）の手法が今日盛んに研究されており，CADe にも応用されている．近年の深層物体検出手法の 1 つとして You Only Look Once version 3 (YOLOv3) が挙げられる [4]．本研究では，YOLOv3 を DeepLesion データセット内の胸部画像に適応する．実際の医療現場で用いられる CT 値ごとにモデルを作成し，先行研究を上回る FROC 曲線 *2 が得られた，すなわち感度あたりの偽陽性数を削減したことを報告する（図 1 参照）．また，放射線医師が立体的な情報を利用して正常組織とよく似た病変を識別することを参考に，DeepLesion において病変部位がラベル付けされている CT 画像の近傍のスライスも考慮するように YOLOv3 を改変しての実験も実施した．

本論文の構成は次の通りである．第 2 節で関連研究として，DeepLesion データセットとその病変部位検出モデルと，立体情報考慮について概説する．第 3 節で，本研究における実験方法を説明し，第 4 節でその結果を述べる．第 5 節では，実験結果に対する考察を行い，第 6 節で本論文を結ぶ．

2. 関連研究

本節で関連研究について述べる．まず，2.1 及び 2.2 小節で DeepLesion データセット及びそれを用いた物体検出手法の概要を説明し，次に 2.3 小節で先行研究の課題を述べる．2.4 小節では，偽陽性 BB 対策として提案された，3 次元コンテクストを考慮した場合の手法を概説する．

2.1 DeepLesion データセット

DeepLesion[6] はアメリカ国立衛生研究所（national institutes of health, NIH）において集められた CT 画像のデータセットである．4459 人の患者から検出した 32,735 の病変がアノテートされた CT 画像と，その CT 画像の近傍スライスで構成されている．総計 500GB 近い大規模なデータセットであり，頭部から脚部に至るまで様々な部位の病変画像が収録されている．学習データ以外の評価・検証データについては，各病変のおおよその部位が”just reference”程度の確度でアノテートされており，骨，腹部，縦隔，肝臓，肺，腎臓，軟部組織，骨盤の 8 種類がある．

各 CT 画像には DICOM_windows というそれぞれ既定の CT 値が定められており，ある画像は肺野用の $[-1500, 500]$，別の画像は縦隔用の $[-175, 275]$，といったように既定 CT 値は画像ごとに一般に同じではない．CT 値の場合の数は 55 通りだが，全体の 97%は $[-1500, 500]$ または $[-175, 275]$ である．この CT 値は肺野や縦隔といったそれぞれの部位を読影する際に実際に医療現場で用いられる数値がアノテートされている．各 CT 画像は容量削減のために低いコントラストに変

連絡先: 西郷 彰，株式会社 リクルートテクノロジーズ アドバンスドテクノロジーラボ，東京都千代田区丸の内 1-11-1，saigo@r.recruit.co.jp

*1 感度 (sensitivity) は再現率 (recall) と同値である．医療分野では感度という表現がされる．

*2 Free-response Receiver Operating Characteristic 曲線．横軸に画像 1 枚当たりの偽陽性数の平均値を，縦軸に感度をプロットして描画する．

換された形で収録されており，DICOM_windows のアノテーションを用いて再変換することで復元できる．

また，各病変部位の位置情報として，人体内における相対座標が与えられている．この相対座標は，直立しているヒトを正面から見た時に左から右の方向を x，腹から背の方向を y，頭から足の方向（頭尾方向）を z としている．

2.2 先行研究

DeepLesion データセット構築の論文 [6] において，それを学習した物体検出手法の提案もされている．以下，この DeepLesion に対する物体検出手法を本論文では DLDet と書く．この先行研究の主な貢献は，これまで限られた状況でしか入手できなかった CT 画像について，大規模なデータセット DeepLesion を整備・公開したこと，そして実際にそのデータセットに対する検出手法 DLDet を提案したことである．この DLDet は DeepLesion 全体という包括的な病変を対象としている．

DLDet では評価データのおおよその部位情報を用いて病変クラスの擬似ラベルを学習データに割り振り，人体内の相対的な頭尾方向座標を自己教師付き学習による回帰で推定してから物体検出の学習を行っている [6]．包括性を持つために，DeepLesion データセットについて，医療現場で用いる上述の既定 CT 値ではなく $[-1024, 3071]$ という広範囲の値で統一して指定した CT 画像を用いて学習している．このように学習した DLDet の FROC 曲線はおおよその部位ごとに報告されており，感度 0.9 を達成するには肝臓で 10，肺で 15 以上の画像 1 枚当たりの偽陽性数 (false positives per a image, FPI) が必要になる [6].

2.3 課題

先行研究には次の問題点がある：

- 高感度を実現するために必要な FPI が少なくない．

  CADe のユーザは大量の CT 画像を読影する医療サイドであり，真陽性の見逃しを減らした際の大量の偽陽性 BB は予測結果の視認性を下げることになる．

- 医療現場とは異なる CT 値を学習している．

  $[-1024, 3071]$ という固定された CT 値を用いて復元している [6, 5]．これは医療現場で DeepLesion の元画像にアノテーションが付けられたときの CT 値（肺野 $[-1500, 500]$ や縦隔 $[-175, 275]$ など）とは異なり，現場で使われている値ではない．そのため，CADe が直面する実際的な状況と乖離したデータを学習している．

- DeepLesion のアノテーションは完全ではない．

  DeepLesion データセットのアノテーションはすべての病変と疑われる部位を網羅していない [6]．非専門家には正常組織との区別が困難な病変へのアノテートの有無が混在しており，FPI の多さの原因になっていると考えられる．

以上の点が，DLDet を検出モデルとして医療現場で実践するにあたって課題となる．このうち，偽陽性 BB を削減する手法として，次小節で挙げる立体情報の利用という方法がある．

2.4 立体情報を考慮した先行研究

CT 画像での病変検出は，専門家は立体的な情報を利用して正常組織か異常かを識別している．例えば，血管や気管は連続している管上組織であるので，近傍スライスにも似た位置に同じ組織があることが多く，近傍スライスに写っていないかどうかで管上の組織ではなく病変と判断される．単体の CT 画像

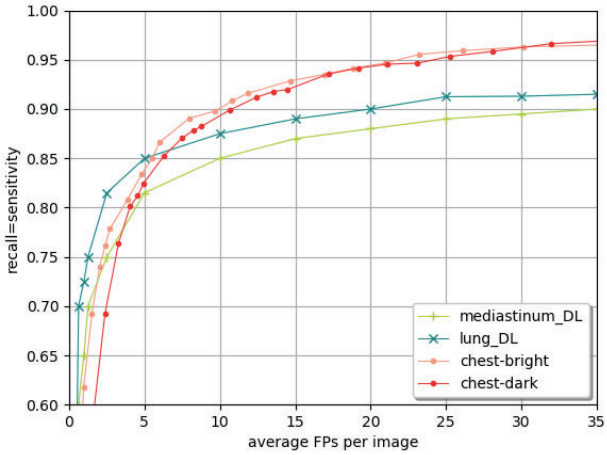


図 1: 平面情報のみを用いるとき，検証データについての各条件下での FROC 曲線．縦軸が再現率すなわち感度で，横軸が FPI の検証データセット内での平均値である．各曲線は次の通りである；+記号でプロットされた黄緑の曲線：先行研究 DLDet の縦隔病変に対するもの，x 記号でプロットされた青色の曲線：先行研究 DLDet の肺病変に対するもの，・記号でプロットされた濃赤色の曲線：chest-dark を学習したモデルのもの，・記号でプロットされた淡赤色の曲線：chest-bright を学習したモデルのもの．

だけでは，正常組織と病変の画像としての見た目は似通っており，FPI が多くなりやすい．そのため，立体情報も学習させることで同じ感度を達成する偽陽性数を減少させる研究がされている．病変部位も本来立体的であるため，すべてのスライスにアノテーションを行いすべてのスライスを学習することが理想的であるが，このナイーヴな方法はメモリやストレージの消費量が激しいだけでなく，アノテーションの手間が多大なものになるという欠点がある [5]．例えば，1 回の診察結果が 30 枚のスライスからなるとすると，1 枚のスライスのアノテーション作業の 30 倍の手間がかかり，この 30 枚の画像組を 1 データとすると単純計算としてメモリ消費量も 30 倍に増えることになる．特にアノテーションは専門の放射線医が行わなければ正確なデータにならないため，十分なサンプルサイズを確保することが困難になる．

この問題を解決するために，単体の CT 画像に加えて前後数枚程度の画像組を 1 データとし，またアノテーションはその中心画像にのみに付けるという手法が提案されている [5]．CT 値は DLDet と同様の値に固定し，またスライス幅は 2mm になるように補正している [*3].

立体情報を用いたこの手法においては，偽陽性数 4 のときのおおよその部位ごとの感度と，全部位をまとめての FROC 曲線が報告されており，アノテーション付けられているスライスと前後 13 枚ずつの合計 27 枚を 1 データとした場合では DLDet における肝臓と肺の中間程度の性能が全部位まとめてであっても実現できている．前後 1 枚ずつの 3 枚の画像組を 1 データとした場合では，感度 0.9 を達成する偽陽性数はおよそ 20 である．ただし，こちらでも学習した CT 値は現場と異なる上述の固定値である．

*3 補正手法は報告されていない．

3. 方法

前述の課題を踏まえて，次に述べる方法で数値実験を行った．使用したデータと前処理，ネットワークアーキテクチャ，実験条件の順で述べる．

3.1 データ

学習・評価・検証それぞれに対応するデータの分割は，DeepLesion の設定を継承した．後述のロジスティック回帰による胸部，上腹部，下腹部の 3 クラス分類器の学習に用いたデータはこの分割に従った際の評価用データとした．

DeepLesion の CT 画像を用いたが，先行研究とは異なり各画像に対応付けられた CT 値で復元した．また，胸部の画像のみを用いた．実際の読影にあたっては，病変が存在する組織はわからなくとも，CT スキャンを行う人体の範囲は既知であるので，これを利用して胸部，上腹部，下腹部ごとに検出モデルを作成する方が高い精度が期待できるためである．本論文では胸部について実施した実験を報告する．

胸部，上腹部，下腹部の分類は次の方法を用いた．軟部組織や骨は全身に存在するため，これら以外の部位の大まかな分類として，縦隔と肺は胸部に，肝臓と腎臓と腹部は上腹部，骨盤は下腹部と定義した．縦隔などのアノテーションは評価データと検証データについているが，評価データの 6 割を学習させて 3 クラス分類器をロジスティック回帰により作成し，その Ridge 正則化パラメータを評価データの 2 割で調整した．このロジスティック回帰においては，病変の x 及び z 座標を説明変数とした．残った 2 割の評価データに対する精度（accuracy）は約 94%であった．この 3 クラス分類器を元の学習データに適応した結果を以て，胸部，上腹部，下腹部の擬似ラベルとした．このうち，胸部・下腹部はそれよりも上・下であるような z 座標のデータ（頭部や頸部・脚部）も含まれるクラスになっていたため，本研究で実際に胸部画像として用いたのは上記の胸部クラスの画像のうち，$z \geqq 0.39$ を満たすものとした．

画像のアノテーションに対して以上の前処理を実施した．画像そのものへの前処理として，各画像に DICOM_windows としてアノテーションされている CT 値をそれぞれ対応付けてコントラストを復元した．ドメイン知識として，この CT 値は DeepLesion 作成にあたって対応する病変を専門の放射線医師が読影・検出した際の数値であるため，実際的な状況で用いられる値である．こうして復元した胸部画像のうち，$[-1500, 500]$ が約 41%を，$[-175, 275]$ が約 54%をそれぞれ占めていたため，それぞれの CT 値ごとに検出モデルを作成した．以下，CT 値が $[-1500, 500]$ である胸部画像のデータセットを chest-bright，$[-175, 275]$ については chest-dark とそれぞれ呼称する．ニューラルネットワークに入力する際には $[0, 255]$ なる画素値から 127.5 を引いて 255.0 で割るという正規化を行った．また，後述するネットワークアーキテクチャが RGB 画像に対するものであったため，モノクロ画像から RGB への変換を施した．

3.2 ネットワークアーキテクチャ

ネットワークアーキテクチャは YOLOv3 を用いた．YOLOv3 には物体検出を行う層が 3 個あり，それぞれにアンカーボックスが対応付けられており [4]．そのサイズはオリジナルの YOLOv3 で用いられているものを流用した．また，オリジナルでは 80 クラスの物体を検出する [4] が，CADe においては診断を自動化するのではなく病変の疑いのある箇所を自動的に検出することが重要なため，本研究では明らかな悪性腫瘍から良性の炎症・画像だけからは確証できないが病変の疑いのある箇所のすべてを「病変 (lesion) 」という 1 クラスにまとめた．DeepLesion データセットにおいても，病変の種類はアノテートされていない [6]．一般に，クラス数 c の YOLOv3 において物体検出を行う層の直前の畳み込み層のフィルター数は $3(c+5)$ で与えられるため [4]，本実験では 18 とした．

3.3 実験

上述の方法で得られた学習・評価・検証データそれぞれの枚数は chest-bright では $(3681, 937, 785)$，chest-dark では $(5074, 994, 1010)$ となった．この分割に従って chest-bright 及び chest-dark それぞれを上記の YOLOv3 で学習して病変検出モデルを作成した．活性化函数 leaky ReLU のパラメータ，学習率，勾配法は YOLOv3 の元論文 [4] と同様とした．評価指標としては評価・検証データに対して先行研究 [6] と同様に FROC 曲線を用いた．120 エポックの学習を行い，各エポックごとで評価データに対する YOLOv3 の損失函数値を取得し，120 エポック目に最も近い損失函数極小化エポックのモデルの FROC 曲線を描画した．立体情報を利用する場合は，スライス数を 3 とし，それに合わせてネットワークの入力層のチャネル数を 3 倍した [5].

FROC 曲線の描画にあたっては，non-maximum suppression 法の閾値を 0.1 で固定し，検出物体の confidence 閾値を変化させたときの FPI 及び感度をプロットした．比較のために，DLDet の肺及び縦隔の FROC 曲線を併記した．chest-bright は肺の，chest-dark は縦隔の病変を読影する際の CT 値を学習したモデルであるので，それぞれ DLDet の対応部位の FROC 曲線と比較した．

4. 結果

本論文では平面情報のみを利用する場合について報告する．検証データに対する FROC 曲線は図 1 のようになった．DLDet では達成できない感度 0.95 を chest-bright, chest-dark のどちらも 22,24FPI 程で実現できた．DLDet では比較的感度が高い肺についてであっても，感度 0.9 の達成には 20FPI 必要とされるのに対して，実験結果では chest-bright, chest-dark のどちらも 10FPI 前後で実現できるようになった．感度 0.85 については，chest-bright は DLDet と遜色なく 5.5FPI 程度で実現することができ，chest-dark では DLDet の 10FPI よりも少なく約 6FPI で実現された．感度 0.8 については，chest-bright では DLDet の 2FPI にやや劣る約 3.5FPI であるものの，chest-dark は DLDet の約 4.5FPI よりわずかに少なくおよそ 4FPI で実現可能であった．感度ごとの実画像への検出例を図 2 及び 3 に示す.

5. 考察

感度は真陽性率であるため，この値が高いほど（偽陽性の増加を犠牲にしつつ）病変の見逃しを減らすことができる．病変の検出を目的としているため，高い感度における偽陽性数の少なさが重要であると考えられる．感度 0.85 以上の領域（高感度領域と呼ぶ）において，実現可能な最大感度を引き上げただけでなく特に感度 0.9 以上では先行研究と同程度の感度を実現する FPI を著しく削減することができた．感度が 0.85 以上 0.9 未満においても先行研究と同程度かそれより少ない FPI であった．また，感度が 0.8 以上 0.85 未満の領域（中感度領域と呼ぶ）では，先行研究よりわずかに多い FPI で同じ感度を達成できているため，FPI の少なさを重視しても中感度領域では検出性能が大きく劣化することはないと考えられる．以上から，本研究では中感度領域における検出性能をほぼ落とすこと

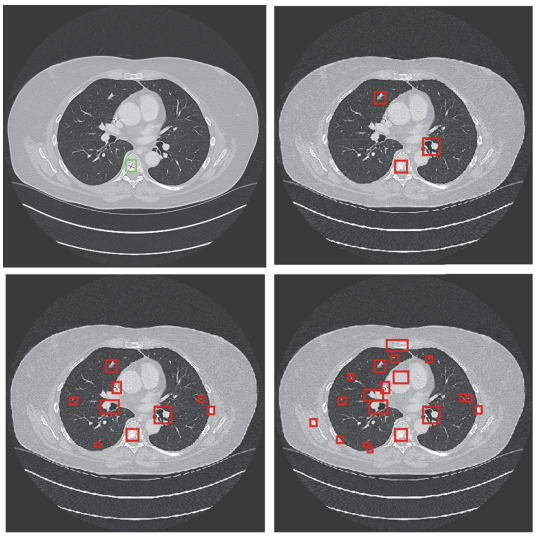


図 2: chest-bright の検出例．左上がアノテーションで，右上，左下，右下の順に感度が 0.8，0.85，0.9 となっている．

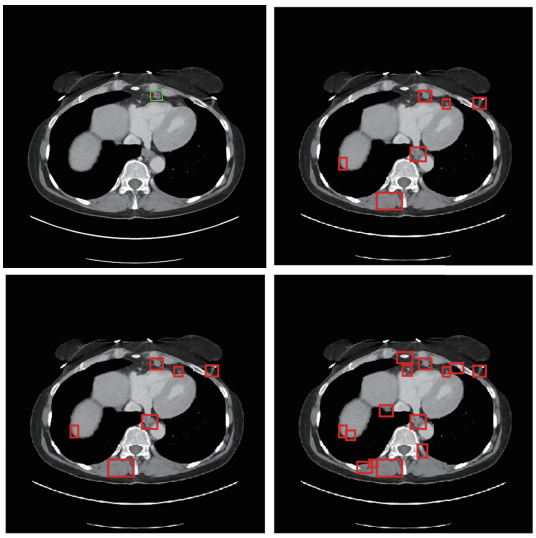


図 3: chest-dark の検出例．左上がアノテーションで，右上，左下，右下の順に感度が 0.8，0.85，0.9 となっている．

なく，高感度領域において先行研究よりも十分少ない FPI を達成するという貢献ができたと考えられる．

本研究における胸部の定義として肺及び縦隔の病変の位置座標を使った分類モデルの出力を用いた．この分類モデルは病変の位置座標のみから胸部か上腹部か下腹部かを判定する．実際の病変検出においては，CT スキャンを走査する範囲は既知でもどの部位に病変が存在するかは事前にはわからず，かつ胸部の骨や軟部組織の病変も存在する可能性がある．chest-bright 及び chest-dark はどちらもそれぞれ肺と縦隔の病変に限るわけではなく，軟部組織や骨や一部肝臓も含む病変が混在しており，胸部範囲の CT スキャン結果のデータセットとして現実的であると考えられる．また，先行研究において軟部組織や骨の病変の検出の困難さが報告されている [6]．このように，実際的かつ検出困難な病変も含んだデータセットで，肺や縦隔のみで描画した先行研究の FROC 曲線を上回ったことは，現場での応用に近づくことができたと考えられる．

6. 結論

DeepLesion データセットの胸部画像に対し，現場で用いられる CT 値を YOLOv3 に学習させた結果，先行研究よりも実際的な設定で同じ平均 FPI に対する感度を向上させることができた．今後の課題として，特に感度と FPI がともに小さい領域での性能向上のためには，モデルが検出した偽陽性が本当に偽陽性であるかを再検討する，すなわち DeepLesion のアノテーション不備を改善するという施策が考えられ、本稿投稿時点（2019 年 2 月 8 日現在）で検討中である。

謝辞

本研究にあたり，医療現場での読影業務と用いる CT 値について慶応義塾大学病院の荒井先生よる指導を受けた．

参考文献

[1] Andre Esteva, Brett Kuprel, Roberto A Novoa, Justin Ko, Susan M Swetter, Helen M Blau, and Sebastian Thrun. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639):115, 2017.

[2] Kunihiko Fukushima and Sei Miyake. Neocognitron: A self-organizing neural network model for a mechanism of visual pattern recognition. In *Competition and cooperation in neural nets*, pages 267–285. Springer, 1982.

[3] Pranav Rajpurkar, Jeremy Irvin, Kaylie Zhu, Brandon Yang, Hershel Mehta, Tony Duan, Daisy Ding, Aarti Bagul, Curtis Langlotz, Katie Shpanskaya, et al. Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning. *arXiv preprint arXiv:1711.05225*, 2017.

[4] Joseph Redmon and Ali Farhadi. Yolov3: An incremental improvement. *arXiv preprint arXiv:1804.02767*, 2018.

[5] Ke Yan, Mohammadhadi Bagheri, and Ronald M Summers. 3d context enhanced region-based convolutional neural network for end-to-end lesion detection. In *International Conference on Medical Image Computing and Computer-Assisted Intervention*, pages 511–519. Springer, 2018.

[6] Ke Yan, Xiaosong Wang, Le Lu, and Ronald M Summers. Deeplesion: automated mining of large-scale lesion annotations and universal lesion detection with deep learning. *Journal of Medical Imaging*, 5(3):036501, 2018.

[7] Zhijie Zhu, Ghazaleh Haghiashtiani, and Michael C McAlpine. Biophysical sensing in deep tissue via mri. *Nature Biomedical Engineering*, 3(1):11, 2019.

General Session | General Session | [GS] J-13 AI application

[2N5-J-13] AI application: medicine and healthcare

Chair:Yasutomo Yamamoto Reviewer:Koji Kozaki

Wed. Jun 5, 2019 5:20 PM - 6:40 PM Room N (Front-right room of 1F Exhibition hall)

[2N5-J-13-01] Fall Risk Evaluation Using Mahalanobis Distance and Factor Analysis

○Takao Naito[1,2], Masato Kobe[1], Makoto Kunigoh[1], Kotaro Yamasue[2], Osamu Tochikubo[2], Yoshihiro Ishikawa[2], Hiroshi Takeda[3] (1. Fuji Xerox, 2. Yokohama City University, 3. Osaka University)

5:20 PM - 5:40 PM

[2N5-J-13-02] Emotional responses of the elderly people must be realized by the artificial intelligence

○Tomoyuki Yambe[1], Makoto Yoshizawa[1], Yusuke Inoue[1], Akihiro Tamada[1], Yasuyuki Shiraishi[1] (1. Tohoku University)

5:40 PM - 6:00 PM

[2N5-J-13-03] Current Trends, Issues, and Potentiality of AI Technology in Psychiatry

○Shin Ikeda[1] (1. Okayama Psychiatric Medical Center)

6:00 PM - 6:20 PM

[2N5-J-13-04] proposal of Prediction method of ECG via 1D-CNN

○Shigeki Shimizu[1], Kouta Anai[1], Naoto Yamada[1] (1. Toyota Technical Development Corporation)

6:20 PM - 6:40 PM

©The Japanese Society for Artificial Intelligence

マハラノビス距離と因子分析を用いた転倒リスクの評価

Fall Risk Evaluation Using Mahalanobis Distance and Factor Analysis

内藤 孝雄[*1*2] 小部 正人[*1] 救仁郷 誠[*1] 山末 耕太郎[*2] 杤久保 修[*2]
Takao Naito Masato Kobe Makoto Kunigoh Kotaro Yamasue Osamu Tochikubo

石川 義弘[*2] 武田 裕[*3]
Yoshihiro Ishikawa Hiroshi Takeda

[*1] 富士ゼロックス株式会社 [*2] 横浜市立大学 大学院 医学研究科
Fuji Xerox Co., Ltd. Graduate School of Medicine, Yokohama City University

[*3] 大阪大学 大学院 医学研究科
Graduate School of Medicine, Osaka University

The purpose of this paper is to estimate people with a high risk of falls and to contribute to fall prevention by clarifying their potential factors. As a result, 6 elderly people with high risk of falling among 98 female participates were extracted using Mahalanobis distance, and 4 out of the 6 elderly people had experienced falls or nearly falls. Furthermore, we extracted 5 factors related to the balance of lower limb muscle strength, the neuromodulation function and so on using factor analysis.

1. はじめに

高齢者が ADL(Activities of Daily Living:日常生活の活動)を維持する生活は、健康寿命延伸の観点から個人にとっても社会にとっても大切である. 健康寿命を縮めてしまう要因の 1 つに、転倒骨折による寝たきりがあり、厚生労働省の調査によると要介護の原因は、認知症、脳血管疾患に次いで、第 3 位に骨折・転倒の疾患が占める[厚労省 17]. また転倒による事故は、高齢者の 5 番目(心血管系、癌、脳卒中、肺による原因に次ぐ)に多い死亡原因になっている[Rubenstein 02].

転倒の原因は多種多様で、総括して内的要因と外的要因に分けられる. 内的要因は、筋力低下、不安定なバランスなどの運動要因、視覚障害などの感覚要因、意識障害や注意力障害など脳機能要因などである. 外的要因は、障害物の存在や薬剤要因などが挙げられる[Pfortmueller 14] [日本医師会 07] .

従来、転倒の一要因であるバランス機能の評価方法は、動的バランスと静的バランスの概念に分類される. 前者の評価方法には、Timed up-and-go テスト、Get up-and-go テストなどが用いられる. これによって、歩行など運動機能の評価を行う. 後者の評価方法は、両脚を揃えて閉眼と開眼で動揺を比較する Romberg テスト[Agrawal 11]や片脚立ちテストなどがあり、開眼と閉眼で立位状態を保持時間で評価するもので、どの様な動揺で保持するか状態まで評価することは少ない. 一方、問診票などの医療データを活用して転倒リスクを評価する方法も報告されている[森田 10]. この中では病院内の入院患者に対して、転倒転落アセスメントスコアシートによる問診によって、危険度をスコアから危険度Ⅰ~危険度Ⅲの 3 段階で分類している.

今回、高齢者に身体的負荷が少ない計測として、静的バランスでの動揺状態と、握力計測での筋力評価を行った. 日常の行動は問診票から評価し、両者のデータを基に転倒リスクの評価を行った. また性別によるバラツキをなくすため女性に限定して、マハラノビス距離で転倒リスクの高い健診者を抽出し、さらに潜在的バランスの要因を分析するため、計測データと問診票から抽出した変数の影響を因子分析で検討した.

連絡先:内藤孝雄, 富士ゼロックス(株) スマートワークイノベーション事業本部 ヘルスケア事業部, 〒220-8668 横浜市西区みなとみらい 6-1 , takao.naito@fujixerox.co.jp

2. 方法

転倒リスクを抽出するために、身体の計測情報と日常の行動評価を利用した. 計測情報は、開眼片脚立ちと閉眼両脚立ちをそれぞれ 30 秒間行い、その時の動揺の計測と最も簡単に筋力を測定できる握力検査を行った. 行動情報は、問診票から年齢・BMI(Body Mass Index)・運動習慣・昨日の睡眠状況・疼痛などの項目を収集した. これら情報より、基準データに対する異常値を検知する手法としてマハラノビス距離を適用した. また多変量分析の一種である因子分析を適用して、計測情報と行動情報から潜在的な転倒リスクと共通因子の関係を検討した.

2.1 マハラノビス距離による転倒スコア

マハラノビス距離 D は多変量空間における距離尺度で、品質工学で異常値を検出する手法である MTS(Mahalanobis Taguchi System)法の中で適用されている[救仁郷 01]. この MTS 法にはデータが正規分布であることなど制約条件があり、健康診断の項目の数値データを総合的に判断する上で、極めてよく一致することが報告されている[中島 99]. 今回、バランス計測データと問診データを元に、この手法を用いてバランス機能が低下することによる転倒リスクの高い健診者を評価した.

計算方法は、項目数 k 個として、ある対象 Z の項目 i の値の任意のデータ x_{iz} に対して、項目 i の平均 m_i、標準偏差 σ_i とすると、基準化データ y_i は式 1 で表すことができる.

$$y_i = \frac{x_{iz} - m_i}{\sigma_i} \qquad (1)$$

この項目数 k 個の基準化データ y_i のマハラノビス距離 D を行列表記すると式 2 となる. $\boldsymbol{R^{-1}}$ は、項目間の相関係数行列 $\boldsymbol{R}$ の逆行列である.

$$\boldsymbol{D^2} = \frac{\boldsymbol{1}}{\boldsymbol{k}} \boldsymbol{(y_1, y_2, \ldots, y_k)\, R^{-1}} \begin{pmatrix} \boldsymbol{y_1} \\ \boldsymbol{y_2} \\ \vdots \\ \boldsymbol{y_k} \end{pmatrix} \qquad (2)$$

健診者の項目ごとに蓄積されたマハラノビス距離 D を転倒スコアとして異常値を検出することで転倒リスク判定する. このマハラノビス距離 D 算出時の基準空間とした相関係数行列は、「最近転倒した・しそうになった」で「はい」と回答した人および開眼片脚立ち 30 秒ができなかった人を除いた「正常なバランス機能を有す」と思われる人のデータを適用した.

2.2 因子分析の適用

マハラノビス距離 D はスカラーとして異常値検出を目的としたが、計測情報と行動情報の複数の因子から、潜在変数を抽出するため、因子分析を適用した. つまり、計測データと問診票からその背後にある転倒リスクなど直接計測できない潜在因子を推定する. 因子分析の基本モデルは、潜在因子 F_n、観測変数 X_i、因子負荷量(factor loading) a_{in}、それ以外の独立因子(unique factor) e_i とすると式 3 で表される. 潜在因子 F_n は、共通因子(common factor)または単に因子(factor)と呼ぶ.

$$X_i = a_{i1}F_1 + a_{i2}F_2 + \cdots + a_{in}F_n + e_i \qquad (3)$$

因子分析は最初に初期解の計算で、因子抽出と因子数の決定を行う. 因子抽出方法は、第 1 因子から順に因子寄与が最大になる様に因子を抽出する主因子法、尤度という指標を抽出しこれを最大にする最尤法、元データと因子分析のモデルから算出した共分散行列の間の差を最小にする最小二乗法などがある. 因子分析では、対象データにおいて固有値と固有ベクトルを求め、その分散が最大になるような方向を求めることになる.

次に因子 F_n 間は無相関の場合は直交回転を、そうでない場合は斜交回転を行う. 最終的に因子の解釈を人手で行い、因子名を決定する. そして因子得点、因子寄与利率で評価した.

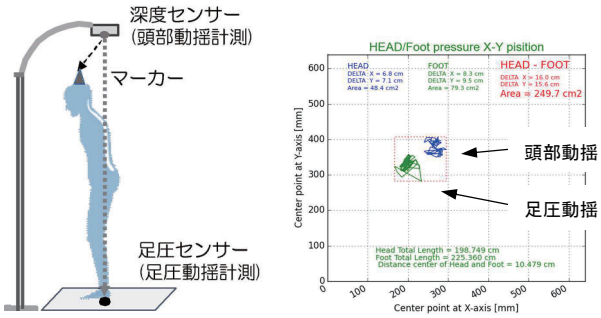
3. 実験

3.1 評価システムの概要

高齢者の身体的負荷が少なく、簡易に計測できる静的バランスを、時間をかけずに計測可能にする装置を提案する. 頭部と体幹の重心がわかる方法として、頭部上部に色画像と深度画像の撮影が可能な赤外線方式の距離センサーで、頭部につけた三角柱マーカーの動揺を検出する. 下部は、足圧シートセンサーで足圧動揺をそれぞれ算出する. 足圧シート上の立つ位置は固定し、Romberg テストや片足立ちテストなどで被験者に負荷を与え、安静時の立位状態で動揺と姿勢を計測する.

頭部中心を算出する手段は、上部に設置した深度センサー(Intel RealSense)を適用、下部には足圧センサー(住友理工製 SR ソフトビジョン)で身体全体の重心の移動軌道をモニタリングし、双方を比較することで体幹のバランスを維持できているかを可視化する. 安静立位を 30 秒間行い、頭部と身体全体の立位バランスを検証する(図 1(a)).

上下 2 つのセンサーによって頭部と足圧中心双方の動揺軌道をモニタリングし、どの程度立位バランスを維持できているか可視化する. 基本的立位姿勢の理想的アライメントは、「頭部、体幹、四肢の各体節の解剖学的指標が一直線に整列しているか否かによって判定」で定義されている[中村 03]. 従って頭部動揺中心を求めその中心を垂直に降ろした位置が身体全体の中心とどの程度離れているか求めるため、身体が前後に傾いていたり、骨格が左右にずれたりすると一致しない. この状態で求めた頭部動揺中心 COH の動揺平均座標値を COH 中心点 COHc、足圧中心 COF の動揺平均座標値を COF 中心点 COFc として、COHc – COFc 間の距離から立位姿勢判定を行う. 図 1(b)に開眼の片脚立ち 30 秒間の頭部と足圧の動揺結果を示す. この中で頭部と足圧それぞれの総動揺距離、動揺した領域の矩形面積および姿勢評価のため両動揺中心間の距離を算出する. 解析対象は、計測期間の前後 5 秒間を除いた 20 秒間とした.



a. 装置の概要　　b. 出力結果

図 1. 立位バランス計測の概要

また従来の研究より、下肢筋力の低下が転倒要因の1つとして報告されている. この下肢筋力の計測の代替として、最も筋力を簡単に計測できる握力検査を実施した.

健診者の行動情報として、過去の転倒状況、運動習慣、疼痛、計測当日の体調(昨日の睡眠時間、現時点の疲労度、昨日の飲酒量)を問診票で記入してもらった. この問診票への記入は間隔尺度で、例えば「最近転倒した・しそうになった」は 2 件法(「はい」・「いいえ」)、「当日の疲労は」は 3 件法(「いいえ」・「少し」・「はい」)など、n 件法で採取した.

これらバランス計測と問診票から抽出したデータを元に、マハラノビス距離で転倒リスクの高い健診者を抽出した. さらに因子分析を主因子法・最尤法・最小二乗法を適用し、斜交回転での因子の評価を行った. 分析には、R ver3.4.1 を使用した.

3.2 対象者

対象者は、自治体や医療機関が主催した健康測定会に参加した 65 歳以上の高齢者および情報機器メーカーA 社の就労者(20 歳代～60 歳代)とした. 補助なく歩行ができ基礎体力があり身体に麻痺のない人で、計測にはインフォームドコンセプトを得て実施した.

4. 結果

4.1 参加者の基本データ

対象者 164 名が、計測に参加した. この中から性別の影響を取り除くため、女性のみのデータを採用し、116 名を抽出した. さらに欠損値のある者を除き、最終的に女性 98 名を有効とした. 対象者の各項目の基本データ(平均と標準偏差)を表 1 に示す. 表1の最終項「片脚立ちテスト」のフラグは、片脚立ちテストが最後までできた人は“0”、途中で両脚を付いた人は”1”、このテストが出来なかった人は”2”、と重み付けを行った.

表 1 . 評価項目の基本データ(女性のみ)

項目	平均	標準偏差
年齢	68.8	12.5
BMI	21.3	2.6
本日の疲労度0疲れてない2疲れている	0.5	0.6
最近転びそうになった1はい2いいえ	1.8	0.4
運動習慣について１毎日５全く	2.1	1.3
１日の平均歩数1-10K歩以上6-２K以下	3.8	1.4
昨夜の睡眠1よく眠れた4全く	1.8	0.8
昨夜の飲酒1飲んでない4二日酔	1.2	0.4
疼痛 1腰に痛みがありますか0無1有	0.3	0.5
疼痛2膝に痛みがありますか0無1有	0.4	0.5
握力　左右高い方　　[Kg]	24.3	5.5
閉眼両脚足圧中心移動　[cm]	65.4	37.1
閉眼両脚足圧中心面積　[cm^2]	10.2	7.1
開眼片脚足圧中心移動　[cm]	137.6	89.1
開眼片脚足圧中心面積　[cm^2]	117.8	231.6
片脚立ち０保持1途中NG2できない	0.1	0.4

4.2 マハラノビス距離の評価結果

マハラノビス距離の算出に適用した基準空間は、動揺の移動距離と移動面積から算出したバランス計測の総合判定が 80 点以上で、最近転んだことがない健康な検診者より作成した.

マハラノビス距離は、各評価項目のバラツキが累積した値になり、この値を転倒スコアとした. このマハラノビス距離である転倒スコアが 200 以上を転倒リスクが高いと定義すると、6 名の高齢者が抽出できた. この抽出した 6 名の内、最近転倒した・あるいは転倒しそうになったと回答した者が 4 名(66%)であった(図 2). マハラノビス距離は大きい要因は、「片脚立ちができない、片脚立ちができても途中でバランスが保持できない」ことが共通にあった. 一方、最近転倒したことがあっても、必ずしもマハラノビス距離が大きくなかった.

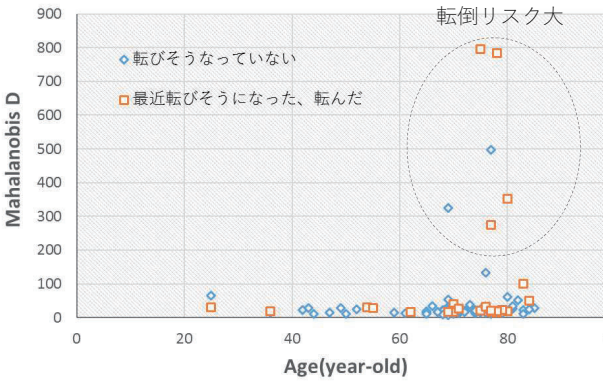


図 2. マハラノビス距離による転倒リスク大の抽出

4.3 因子分析の結果

最初に 22 項目間の相関行列を計算し、この相関行列の固有値を算出した結果、固有値の影響が小さく減衰状態になるところとして、固有値 1.5 までで、有効な潜在因子数を 5 つまでに決定した.

因子分析は最尤法を適用して、22 項目のうち身長と体重の情報は、BMI として表現できるため削除し、最終的に 20 項目に対して 5 因子に分解した結果を表 2 に示す. 第 1 の因子(ML2)は、開眼片脚立ちスコア(この値が高いとバランス良好)が低い程、またその足圧中心の動揺が大きい程バランスが悪いことを示しており、「下肢筋力に起因したバランス」と定義した.

第 2 の因子(ML1)は、同様に閉眼両脚立ちスコアと閉眼両脚立ち動揺に起因しているため、脳の平衡感覚に関連する「神経調整機能に起因したバランス」と定義した. 第 3 の因子(ML4)は、「最近転んだことがある・転びそうになった」因子が最も大きいため、転倒経験そのものに関する因子と定義した. 第 4 の因子(ML5)は、年齢と握力が反比例の関係を示しており、加齢に伴い握力が小さく、筋力に関する因子とした. 第 5 の因子(ML3)は、頭部中心と足圧中心の位置の差から算出した姿勢が最も大きかったため、姿勢の因子とした.

表 2. 因子分析の結果

項目	下肢筋力バランス ML2	神経調整機能 ML1	転倒 ML4	筋力 ML5	姿勢 ML3	共通性 h2	独自性 u2
年齢	0.03	0.04	0.05	0.81	-0.01	0.734	0.266
BMI	0	0.1	-0.13	0.26	0.02	0.079	0.921
１日平均歩数 1. 10K歩以上, 6. ２K以下	-0.03	0.07	-0.04	0.32	-0.06	0.11	0.89
運動習慣について１毎日, ５全く	0.08	0.05	-0.22	-0.08	0.15	0.085	0.915
左右高い方握力	-0.1	0.08	-0.06	-0.66	-0.03	0.494	0.506
最近転びそうになった1はい, 2いいえ	-0.27	0.02	0.54	-0.25	0.08	0.3	0.7
昨夜の飲酒 1飲んでない, 4二日酔	-0.11	-0.12	0.19	0.01	-0.07	0.052	0.948
昨夜の睡眠 1よく眠れた, 4全く	0	0.13	-0.11	-0.29	0.09	0.113	0.887
本日の疲労度 0疲れてない,2疲れている	-0.05	0	-0.25	0.01	0.23	0.127	0.873
疼痛2膝に痛みがありますか　0無,1有	-0.05	0.05	-0.39	0.41	0.23	0.255	0.745
疼痛,1腰に痛みがありますか　0無,1有	-0.07	0.07	-0.28	0.07	0.03	0.08	0.92
開眼片脚スコア	-0.93	0.02	-0.03	-0.06	0.02	0.919	0.081
開眼片脚姿勢距離	-0.17	0.01	0.8	0.05	0.05	0.622	0.378
開眼片脚足圧中心移動	0.9	0.04	0.1	0.05	0.02	0.92	0.08
開眼片脚足圧中心面積	1.02	-0.04	-0.01	-0.05	0.01	0.995	0.005
閉眼両脚スコア	0.03	-0.95	0.35	-0.03	0.02	0.886	0.114
閉眼両脚姿勢距離	0.04	0.86	0.05	0	0.52	0.995	0.005
閉眼両脚足圧中心移動	0.22	0.08	0.7	0.08	-0.27	0.825	0.175
閉眼両脚足圧中心面積	0	0.65	0.01	-0.02	-0.73	0.995	0.005
片脚立ち ０保持, 1途中NG, 2できない	0.9	0.03	-0.08	-0.03	0.01	0.772	0.228
因子負荷量(SS loadings)	3.77	2.09	1.85	1.61	1.04		
寄与率(Proportion Var)	0.19	0.1	0.09	0.08	0.05		
累積寄与率(Cumulative Var)	0.19	0.29	0.39	0.47	0.52		

因子間の相関係数は、最も強いところでは転倒経験因子(ML4)と筋力因子(ML5)で、0.39 が得られた. それぞれの因子の共通性・独自性については、年齢やバランス計測データは高い共通性があり、筋力を評価した握力は中程度の共通性であった. BMI や運動習慣、睡眠、疲労など問診票で抽出した項目には、ほとんど共通性がみられなかった. 因子分析の手法は、最尤度法・主因子法・重み付け最小二乗法で、寄与度を比較した結果を図 3 に示す. 手法を変更することで結果が大きく変わる事はなく、上位 5 つ因子の累積寄与率は 0.52 であった. 寄与率の貢献が低い項目は、飲酒の状況、昨夜の睡眠状況、その日の疲労度であった.

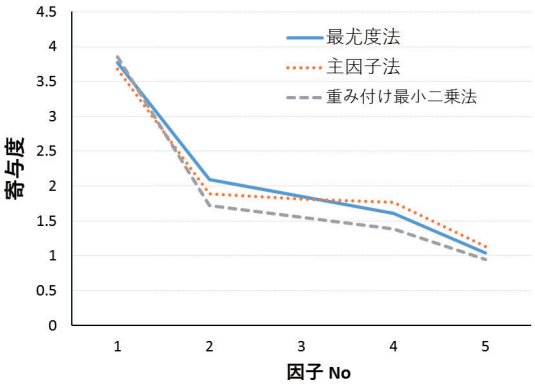


図 3. 因子分析手法毎の寄与度比較結果

5. 考察

就労者を含めた高齢者(平均年齢 68.8±12.5 歳)で、筋力など運動機能のパラメータは性別で大きく依存するため、今回は女性を対象に限定することでパラメトリックな正規分布になりMTS 法が適用できたと考える. 参加した健診者は自ら希望しており、比較的健康意識が高く、運動習慣も 2.1±1.3(スコア 2 が週 2〜3 日は運動している)高いため、比較的転倒にも意識して生活している人が多かった. 本来、転倒リスクの高い高齢者などは外出せず運動不足で、自宅の室内で転倒するケースもあり、幅広い対象者のデータ採取が必要になる.

転倒要因は、内的・外的な様々な要因があるが、異常値検知の手法であるマハラノビス距離で、6 人の転倒リスクの高い高齢者を検出した. この 6 名中 4 名は、「最近転倒した・しそうになった」人であり、「過去に転倒経験のあり人は、転倒しやすい」という従来の報告[Tinetti 10]を裏付けている. この 6 名に対応した因子分析の結果を確認したところ、全員第 1 因子(ML2)が大きいかったため、下肢筋力バランスに依存していると言える. 一方で、問診票で採取した睡眠状況、昨日の疲労感、飲酒の影響は、各因子の共通性は低い理由として、主観的評価であることやほとんどの参加者が健康的な状態であったことが考えられる.

転倒リスクを算出する上で重要なことは、マハラノビス距離の基準空間をどの様に決定するかであった. 最も転倒しにくい健康な人を基準にして、そのデータに対して異常値を累積加算するためである. 計測した結果から、「バランス動揺結果が安定している人」且つ「最近転倒したことがない、また転倒しそうになっていない」人を基準としたが、精度を上げるためには下肢筋力など他の要因も追加検討が必要である. この転倒リスクスコアによって、高齢者は転倒について意識する事が重要で、運動習慣・歩き方・注意力などの行動変容に繋がることが期待でき、健康長寿に貢献していきたい.

筋力テストは、筋力が最も簡単に評価できる握力で実施したが、バランスに直接関係する筋力は下肢筋力である. 握力と下肢筋力の1つである四頭筋筋力とは、中程度の相関があることが報告されている[池田 10]が、精度面で課題がある. そのため、さらに精度を上げるためには、参加者の測定の負担が増えるが下肢筋力の計測が必要だろう. また、問診票の項目から、身体機能・行動状況(不注意などを含む)を抽出したが、過去の病歴や服薬の種類などの関係も検討が必要かもしれない.

分析方法は、当初主成分分析を候補とした. 主成分分析は、各項目から特徴を総合的に統合していく方法であり、計測データや問診票など 20 項目の統合は、特徴が出しにくい傾向があった. そのため因子分析を採用することで、潜在的因子を 5 つに絞り、その因子の 20 項目の寄与度で、ある程度の特徴を抽出することができたと考える.

動的バランスでの評価では、歩行状態をウェアラブルセンサーで加速度データを収集し、デープラーニング(CNN など)を適用した転倒予防の可能性が報告されている[Nait Aicha 2018]. 今回の静的バランスの計測データもデープラーニングの様な機械学習の適用を検討していきたい.

課題として、バランス結果はその日の体調・疲労度にも影響するため 1 回のみの計測では限界があり、日時を変えて複数回の計測から平均を用いるなど必要と考える. また対象者のデータを増やす事、足圧動揺だけでなく、今回使用しなかった頭部動揺データも考慮した分析を行い精度向上することを考慮する必要があると考える.

6. まとめ

バランスと握力の計測情報と問診票による行動情報を元に、マハラノビス距離を閾値として転倒リスクスコアの高い参加者 6 人を抽出した. その中で 4 人は、「最近転倒・または転倒しそうになった」履歴があり、転倒履歴があるものは転倒リスクが高い可能性があることを示した. 因子分析では、バランス、神経調節、転倒履歴、加齢による筋力低下などの潜在因子を抽出し、開眼片脚立ちと閉眼両脚立ちでのバランスデータの観測因子に高い共通性がみられたが、問診票から得られた行動情報からの観測因子はほとんど共通性が低かった.

参考文献

[厚労省 17] 厚生労働省: 平成 28 年国民生活基礎調査の概況, 国民生活基礎調査, pp. 29 (2017)

[Rubenstein 02] Rubenstein, L.Z., and Josephson, K.R.: The epiderniology of falls and syncope, Clin Geriat Med, 18, pp.141-158 (2002)

[Pfortmueller 14] Pfortmueller, C.A., Lindner, G., and Exadaktylos, A.K.: Reducing fall risk in the elderly: risk factors and fall prevention, a systematic review. Minerva Medica. 105(4), pp. 275-281 (2014)

[日本医師会 07] 日本医師会: 医療従事者のための医療安全対策マニュアル, pp. 174 -175 (2007)

[Agrawal 11] Agrawal, Y., Carey, J.P., Hoffman, H.J., Sklare, D.A., and Schubert, M.C.: The modified Romberg balance test: normative data in US adults. Otol Neurotol. 32(8), pp. 1309-1311 (2011)

[救仁郷 01] 救仁郷 誠: マハラノビスの距離 入門 ーMTS 法を理解するためにー, 品質工学, 9(1), pp.13-21 (2001)

[中島 99] 中島 尚登, 高田 圭, 矢野 宏, 柴本 由香, 高木 一郎, 山内 眞義, 戸田 剛太郎: 健康診断データを用いた MTS 法による予測の研究, 品質工学, 7(4), pp.49-57 (1999)

[森田 10] 森田 恵美子, 飯島 佐知子, 平井 さよ子, 賀沢 弥貴, 安西 由美子: 転倒アセスメントスコアシートの改訂と看護師の評定者間一致性の検討,日看管会誌, 14(1), pp.51-58 (2010)

[中村 03] 中村 隆一, 斎藤 宏, 長崎 浩: 基礎運動学 第 6 版. 医歯薬出版, pp. 347-352 (2003)

[Tinetti 10] Tinetti, M.E., and Kumar, C.: The patient who falls: “It’s always a trade-off”, JAMA, 303(3), pp.258-266 (2010)

[池田 10] 池 田 望, 村田 伸, 大田尾 浩, 甲斐 義浩, 村田 潤, 富永 浩一, 溝田 勝彦: 高齢者に行う握力測定の意義, 西九州リハビリテーション研究, 3, pp.23-26 (2010)

[Nait Aicha 2018] Nait Aicha, A., Englebienne, G., van Schooten, K.S., Pijnappels, M., and Kröse, B.: Deep learning to predict falls in older adults based on daily-life trunk accelerometry, Sensors ,18(5), E1654 (2018)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

崩壊する地域医療の中では「高齢者の気持ち」を理解する人工知能が必要である

Emotional responses of the elderly people must be realized by the artificial intelligence

山家智之[*1], 白石泰之[*1]、井上雄介[*1]、山田昭博[*1]　吉澤誠[*2]
Tomoyuki Yambe、Yasuyuki Shiraishi, Yusuke, Inoue, Akihiro Yamada　Makoto Yoshizawa

[*1] 東北大学加齢医学研究所　[*2] 東北大学サイバーサイエンスセンター
Institute of Development, Aging & Cancer, Tohoku University[*1]　Cyber Science Center, Tohoku University [#2]

Abstract: What is missing in the countryside is manpower such as doctors and nurses, and artificial intelligence is necessary here. However, there is no meaning existence in medical care and nursing care that does not attract to the patient's mind. The current artificial intelligence / conversation bot can clear the Turing test, but the patient's feelings can not be read. Therefore, multi-channel subcutaneous blood flow was measured from the image of the human body surface, and a system for quantitative diagnosis of autonomic nervous function balance by frequency analysis and signal processing of nonlinear mathematical theory was developed. We developed an "understand the feelings of the elderly" algorithm to estimate higher order functions from autonomic nerves by the inverse problem. By the use of this system, clinical application had been started and the results showed that Type A behavior pattern was one of the important factors.

1. はじめに

東北地方も新潟も圧倒的な医療崩壊の波に襲われている。地域医療では病院は、もはや潰れるほうが当たり前、存続できる方が珍しいと言われる現在、人工知能に寄せられる期待は大きい。圧倒的に不足しているのは、医師・看護師・介護者などのマンパワーであり、ここに人工知能が介在すれば改善の余地はある。しかし患者側の心に、気持ちに寄り添わない医療・介護に存在の意味はない。現在の人工知能・会話ボットは、ある方向では、チューリングテストをクリアできるほど発展を認めているが、患者さんの気持ちが読めるわけではない。そこで人体表面の映像より多チャンネル皮下血流を計測し、周波数解析や非線形数学理論の信号処理により自律神経機能バランスを定量診断し高次機能を逆問題で推定する「高齢者の気持ちがわかる」アルゴリズムを開発した。

この方法論を応用すれば、これからの医療介護の世界で必ず必要になる人工知能インターフェースとして必須の方法論を提供できるものと考えられる。

2. 方法

2.1 人体表面映像自律神経解析デバイス

東北大学はこれまで、究極のマン・マシンインターフェースを目指して、パソコンの端末をいじらなくても操作できる入力の方法論、考えただけで方向を決めることができる電動車イス、集団における意思決定の脳科学など、ユーザーフレンドリーシステムを開発してきた。次世代における理想の人間と機械のインターフェースでは、人間が考えただけで、機械はその心を読み、稼働し、課題が遂行されなければならない。そのためには、ユーザの心が読めることが、最適解であることは自明である

例えはあまり良くはないが、犯罪捜査への自律神経機能解析の応用の歴史は 1920 年代のカリフォルニア州バークレイの警察における、脈波・呼吸検査にその嚆矢を見ることができる、と、いう記録があり、その後、血圧や脈波、皮膚電気抵抗による発汗などの反応も加えたキーラー型ポリグラフが、犯罪捜査における定量診断基準の一環を構成してきた歴史がある。

東北大学はこれまで光電脈波計等の簡易センサで簡単に計測できる脈波信号に基づいて自律神経機能を表わすいくつかの指標を計測する方法に関する技術を開発し、特許を申請し取得してきた。

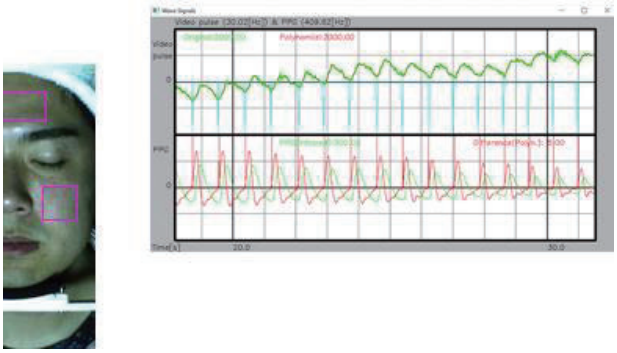


図 1　人体表面からの脈波解析による自律神経機能診断と医療機器による脈波の比較

連絡先：山家智之、東北大学加齢医学研究所、仙台市青葉区青陵町 4-1、022-717-8513, yambe@tohoku.ac.jp

これらは、家庭で手軽な自律神経機能モニタリングに応用できる技術であり、最近、さらに、光電脈波計の代わりにビデオ撮影した身体映像から皮下の血液中のヘモグロビ ンが吸収する緑色信号に基づいて血圧情報を反映する脈波伝搬時間差を遠隔的に推定する技術を開発してきた。身体映像信号から脈波情報を得るため，設定した 領域をモザイク状の小領域に分割し，各領域の緑色信号の うち心拍周波数近傍の成分が強いものだけを対象として選択する．これらの処理により，心拍変動に無相関な運動や 周辺光変化による雑音成分をリアルタイムにキャンセルす るアルゴリズムを開発している。

この方法を応用すれば、家庭でも気軽に計測できる映像情報から、例えば、これまでの犯罪捜査の歴史が示すように、犯罪者の嘘も見抜けることになるが、一般の、ユーザの心も、当然のごとく同じアルゴリズムで、評価、予測できる定量診断システムが実装化できることになる。

2.2 対象と方法

顔面の血流変化を映像脈波から計測することで自律神経活動を解析し、簡便に健康状態や精神心理状態を推定するシステムを構築する。本研究では、人工知能（AI）との会話が、血行動態や心理状態に与える影響を解析した。

東北大学医学系研究科倫理委員会の審査を経て、認可された後に(2013-1-291)、20 歳以上の健常者を対象に十分なインフォームド・コンセントを書面で取得、本研究の趣旨を説明し参加の同意を得た上で、当日、計測実施前に被験者の身長、体重、健康状態、睡眠時間、食習慣、既往歴、アレルギーなどに関する問診を実施し、被験者の心理傾向調査のための検査を実施した。

本研究では「人工知能との会話」を、「人間との会話」と、比較するために、人間との会話セクションでは、普段通り、外部のチャット要員（試験官）と、チャットを行った。被験者と Chat 要員とは、別室で実験を行った。AI との会話では、被験者が入力したコメントを、AI ソフトに入力し、Chat 要員が AI の回答を LINE に入力し、チャットを成立させた

3. 結果

ほぼ全症例において、顔面の映像からの多次元脈波解析が具現化し、自律神経機能評価が可能であった。また、被験者の心理傾向によって多彩な血行動態変動が認められることも判明し、きめ細かい医療介護の必要性を示唆する結果も得られている。心筋梗塞親和性行動パターンのスケーリングとして知られるタイプ A 行動パターンの被験者は、その他の対象と比較すると、異なる自律神経反応を示している。

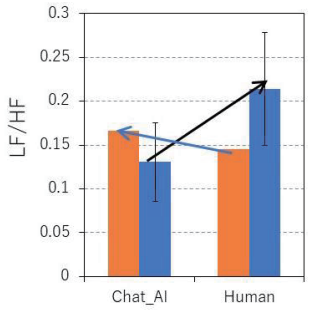


図 2 被検者の映像から得られた脈波の LF/HF 比と、人工知能・人間との会話との比較。

すなわち、Type-A 群においては、人工知能との会話時にやや高いストレスを感じている一方、対照群では、人間との会話時にストレス値（LF/HF）が高値となった可能性がある。

特性不安 高値群で、会話時により高いストレスを感じ、安静時との差も大きかった一方、特性不安 低値群では、そのような傾向はなかった。

これらの結果から、これからの地域医療で求められるロボットなどの介護において、患者さん患者さんの特性に応じた「人工知能の会話」の進め方、情動反応に寄り添った医療介護の在り方が必要であると考えられる。

4. 考察

圧倒的なスピードで間違いなく崩壊する地域における医療介護の現場においては、わたくしたち医療従事者だけでは、ほとんどなすすべもない惨状となっている。東北北海道、新潟だけでなく、すでに、救急医療にすら対応できない地方、地域は、うなぎ上りに増加しつつあり、雪や台風に見舞われる地域では患者さんの空輸もままならない。すなわち、遠隔医療は急速な導入が必要であり、救急ではない一般診療においては、医療介護ロボットの導入は待ったなしで絶対に必要な局面にある。なぜなら医師数の統計で OECD の最下位を独走する医師不足の日本では、医療介護者の圧倒的不足は今後とも継続することがすでに確定しており、医療介護の現場を少しでも維持するためには、医療介護の対象者の「気持ちに寄り添う人工知能」が、間違いなく必要になるからである。

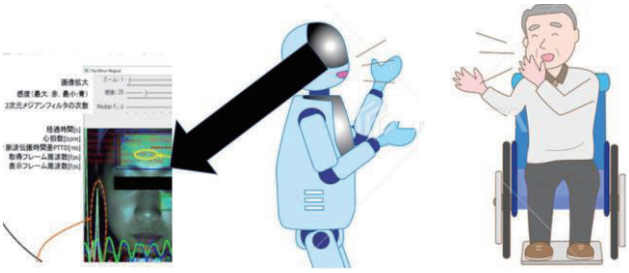


図 3 高齢医療介護対象者の気持ちに寄り添う人工知能

本研究ではその第 1 歩として、「人工知能の会話」と、「人間の会話」に対する人体の情動反応と性格分類に着目して研究を推進している。その結果、心理行動パターンと自律神経機能、高次脳機能の間における高度の関連性を見出す結果が得られている。

そもそも考えれば、世界最速で高齢化社会を迎える日本で、圧倒的に増加する高齢者の大量の人口の前で、「高齢者の気持ちのわからない人工知能」など、研究する価値があるのだろうか？

高齢者側、ユーザ側、弱者側に立ったこのようなアプローチは「人工知能の科学」の世界に新しい展開をもたらす可能性が高いものと期待されるものと考える。

参考文献

[特許 5408751]【出願人】国立大学法人東北大学他【発明者】山家 智之他

[特許 5804405]【出願人】国立大学法人東北大学他【発明者】山家 智之他

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

精神医学における AI 活用の現状，課題，そして可能性

Current Trends, Issues, and Potentiality of AI Technology in Psychiatry

池田　伸[*1]
Shin Ikeda

[*1] 地方独立行政法人　岡山県精神科医療センター
Okayama Psychiatric Medical Center

The main purpose of the current article is to survey the general condition of AI technologies utilized in psychiatry. A search on PubMed shows that the number of papers written on application of AI to psychiatric matters has been growing remarkably. “Depression”, “schizophrenia”, and “Alzheimer’s disease” are the most frequent disorders that appeared in those articles published in 2018. “Support vector machine”, “random forest”, and “logistic regression” are the top 3 machine learning models referred there. “Deep learning” still seems to be rather unusual in psychiatric researches. It is definite that AI will bring great progress not only in clinical practices, but also in theoretical bases of psychiatry. Collaboration of AI engineers and clinical psychiatrists and arrangements of the social environment which promotes clinical researches with AI are essential.

1. はじめに

AI は，医療にも革命を起こしつつある。画像診断，ゲノム医療，医薬品開発などはもちろん，患者の症状評価や予後予測，介護分野への展開，手術支援システムの開発など，様々な試みが世界各国で始まり，進行中である。

一般に，精神科は医学の中でやや特異な領域であるとみなされることが多い。実際，診断や治療の様式において，精神科には他の診療科と異なる特有の流儀があることは否定できない。診断や治療効果判定における客観性が他科に比べて乏しく，医師の主観や経験に左右されがちであるという批判を受けることも稀ではない。しかし，潜在的な患者数の多さや，精神障害がもたらす社会的損失の大きさを考慮すれば，その臨床的な重要性は決して他科に劣るものではない。

本稿では，論を進める前提としてまず，これまでの精神医学が宿命的に抱えてきた診断体系の特殊性および限界について解説する。次いで，精神科における AI 活用の現状を把握する目的で，最近の医学論文の中から精神科での AI 活用に関連するものを選別し，そこで扱われている診断概念や AI 技術について，大まかな傾向を確認する。さらに，精神科領域での AI 活用の試みが直面する課題について触れ，最後に今後の展望と可能性を提示したい。

2. 精神科おける「診断」の特殊性

2.1 精神科における「疾患」とは

通常，医療行為は患者自身が何らかの心身の不調を医療従事者に訴えることから始まる。患者本人の主観的な訴えが「症状：symptom」，客観的な所見が「徴候：sign」であり，併せて「症候：signs and symptoms」と呼ぶ。医師は，患者との面接によってまず症状を聴取し，並行して観察や身体診察により徴候を調べる。それだけで何らかの医学的判断（＝診断）に至ることもあるし，必要であれば各種の検査（検体検査，画像検査，生理学的検査など）を追加することで，正しい診断に至ろうと試みる。「診断」にも様々なレベルのものがあるが，多くの場合は患者の罹っている「疾患：disease」を突き止めることが目標となる。一般に，「疾患」が概念として成立するためには，病因（病をもたらす原因），病態（病が生じる生物学的な仕組み）に加え，症状，経過，予後などが特定されていることが原則的には必要とされ［野村 15］，疾患によっては，それと診断するための「決め手」となるような徴候や検査所見，またはそれらの組み合わせが明らかになっている。こうした診断のための知見を増やしていくことが医学の進歩の重要な一側面である。

ただし，すべての学問や科学がそうであるように，医学もまた常に発展途上である。人間を悩ませる病のうち，病因と病態が解明されているものは，むしろ少数であると言ってよい。その事情は精神科領域において特に顕著であって，精神科の主要な対象である統合失調症，双極性障害（躁うつ病），自閉症などのいずれも，病因・病態ともに現時点で未解明であり，したがって各々の診断に至るための客観的な検査法などというものも存在しない。上記の「疾患」の定義を厳格に適用すれば，現代の精神医学においてはいまだに「疾患」は存在しないとさえいえる。

2.2 「伝統的診断」から「操作的診断」へ

従来，精神科医療の現場では，医師が患者（及びその家族等）と面接し，そこから得られる情報のみを基に何らかの診断を下さざるを得ず，当然ながらその診断は当該医師の主観に左右される部分が多かった。このやり方（いわば「伝統的診断」）では，同じ患者を複数の医師が診察した場合に診断結果が一致しないということも珍しくなく，精神医学の客観性や科学性について長年疑問が呈されてきた主要因の 1 つであった。

その解決策として採用されたのが「操作的診断」である。これは，各々の診断概念について詳細な診断基準を定め，それぞれの医師がこの基準に沿って診断を行うことで，診断の「信頼性（評価者間の一致度）」を改善しようとする試みであった。そして，現在事実上の国際標準となっている診断基準体系が「DSM-5」［高橋 14］である。

連絡先：池田伸，地方独立行政法人岡山県精神科医療センター，ikedas@mbj.nifty.com

DSM-5 から，一例として統合失調症の診断基準を簡略化して表 1 に提示する。統合失調症と診断するためには，A)〜F)の全てを満たす必要がある。

表 1　統合失調症の診断基準（DSM-5 より簡略化して引用）

A) 以下のうち 2 つ以上、おのおのが 1 カ月間ほとんどいつも存在する。これらのうち少なくとも 1 つは(1)か(2)か(3)である
(1)幻覚　(2)妄想　(3)まとまりのない発語
(4)ひどくまとまりのない、緊張病性の行動　(5)陰性症状
B) 障害の持続障害の始まり以降の期間の大部分で、仕事、対人関係、自己管理などの面で 1 つ以上の機能レベルが病前に獲得していた水準より著しく低下している
C) 障害の持続的な徴候が少なくとも 6 カ月間存在する。この 6 カ月の期間には、基準 A を満たす各症状（すなわち、活動期の症状）は少なくとも 1 カ月（または、治療が成功した場合はより短い期間）存在しなければならないが、前駆期または残遺期の症状の存在する期間を含んでもよい。
D) 統合失調感情障害と「抑うつ障害または双極性障害、精神病性の特徴を伴う」が除外されていること
E) その障害は、物質（例：乱用薬物、医薬品）または他の医学的疾患の生理学的作用によるものではない
F) 自閉スペクトラム症や小児期発症のコミュニケーション症の病歴があれば、統合失調症の追加診断は、顕著な幻覚や妄想が、その他の統合失調症の診断の必須症状に加え、少なくとも 1 カ月存在する場合にのみ与えられる

このような詳細な基準に照らして個々の患者を評価する習慣が定着してきたことにより，DSM の登場後，診断の信頼性（評価者間の一致度）は向上したとされており，この点では，操作的診断基準を導入した意義は確かにあったといえる。

一方で，基準の中に生物学的な客観的指標がほとんど含まれておらず，日常言語による表現の域を脱していないため，この基準を個々の患者に適用しようとする場面で，医師の主観が相当程度作用してしまうことは依然として避けられない。例えば上記診断基準の A 項目に「妄想」という語があるが，妄想症状をもたらす生物学的機序がそもそも不明なため，その症状の存否を確定する科学的方法は存在せず，ある患者が「妄想」を有しているか否かは，患者自身の発言内容や行動様式から医師が推測するしかない。さらに突き詰めれば，「妄想」という概念自体の輪郭が不明瞭で，医学上の診断基準に用いるには曖昧すぎる，というような批判も十分可能である。

1980 年に DSM-Ⅲが導入されて以降，診断の一致度が向上することにより精神疾患の病態解明や治療法の開発が順調に進むことが期待されてきた。しかし改訂を重ねつつ 40 年近くを経た現在，結果はその期待とは程遠く，主要な診断概念のうち，病態が解明され「疾患」として確立されたものはいまだに皆無であると言ってよい。

2.3 診断体系の再構築の必要性

こうした行き詰まり感の中で，既存の「疾患概念」に根本的な疑問が付されることもここ数年増えてきている［尾崎 18］。

例えば「統合失調症」と診断されている患者は多数いるが，各患者の症状や臨床経過，治療反応性などは多種多様である。そして，臨床像が互いに似通っているからといって，それらを同一の「疾患」であると断定しうるだけの生物学的根拠は存在していない。とすれば，「統合失調症」という単一の疾患があると考えるよりも，複数の未知の疾患を寄せ集めた仮の診断概念が「統合失調症」であると想定しておく方が合理的である。

逆に，これまで別個のものと考えられていた複数の疾患に，実は共通した病因や病態が存在するという報告も現れ始めている。例えば，統合失調症，双極性障害（躁うつ病），うつ病，自閉症，注意欠如多動症の 5 つの診断すべてに共通のリスクとなる遺伝子変異が発見されたという報告もある［Cross-Disorder Group of the Psychiatric Genomics Consortium 13］）。

生物学的根拠の乏しい，あやふやな「疾患」概念に頼ることはむしろ医学研究を誤った方向へ導くことになりかねない。精神障害の本態に迫るためには，統合失調症，躁うつ病といった伝統的な概念は一旦棚上げにして，遺伝子，細胞生物学，神経生理学，症候学などの各レベルにおいて，頑健な科学的知見を立体的に積み上げ，そこから新たな疾患概念や診断体系を再構築することが必要である。こうした考え方に基づくプロジェクトの代表例が，米国の National Institute of Mental Health (NIMH) の Insel 博士によって提唱された Research Domain Criteria (RDoC)であり，我が国でも徐々に認知度が高まっている［橋本 18］。

3. 精神医学における AI 活用の現状

精神科領域における AI 活用の現状について改めて俯瞰する。医学系論文の検索サイトである“PubMed“で精神科（psychiatry）と AI 関連の幾つかのキーワード（artificial intelligence, machine learning, natural language processing, text mining, deep learning）を用いて検索を実行してみると，ヒットする論文数は（絶対数としてはまだ少ないものの）年々増加しており，精神科においても，AI 技術の活用が徐々に浸透しつつあることが窺える（図1）。

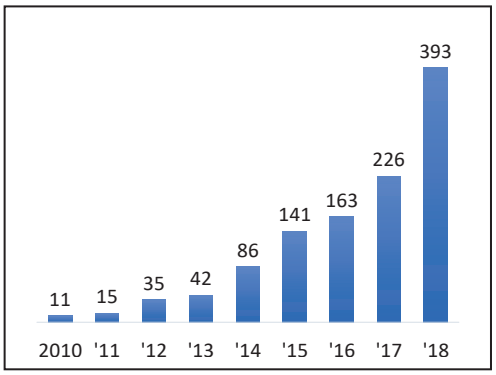


図1　精神科領域における AI 関連の論文数の推移

3.1 研究対象となった診断や症状

この検索を実行した時点（2019 年 1 月 4 日）では，2018 年の論文 393 編のうち abstract が公開されているものは 382 編であった。この 382 の abstract において，精神科の診断用語の出現頻度を調べた（各用語の出現文書数をカウント）。5 文書以上に出現した用語の一覧を表 2 に示す。なお depression と major depressive disorder，schizophrenia と psychosis，Alzheimer’s disease と dementia と mild cognitive impairment，autism spectrum disorder と autism には，それぞれ概念的な重複があることに留意されたい。

これを見ると，抑うつ depression，統合失調症 schizophrenia，アルツハイマー病 Alzheimer’s disease といった，精神科における主要な対象疾患が順当に上位を占めており，全体としても診断の種類は多岐に渡っていると言える。また“suicide”は診断名

ではないが，患者の自殺関連行動は精神科における重要なテーマの 1 つであって，患者の潜在的なリスクを評価したり，行動そのものを予測したりする試みがなされている。

表 2 abstract 中の精神科診断用語の出現数

depression（抑うつ）	42
schizophrenia（統合失調症）	35
Alzheimer's_disease（ｱﾙﾂﾊｲﾏｰ病）	27
major_depressive_disorder（大うつ病性障害）	19
psychosis（精神病症状）	15
autism_spectrum_disorder（自閉ｽﾍﾟｸﾄﾗﾑ症）	14
anxiety（不安）	12
autism（自閉症）	12
dementia（認知症）	11
bipolar_disorder（双極性障害）	11
suicide（自殺）	9
mild_cognitive_impairment（軽度認知機能障害）	8
obsessive-compulsive_disorder（強迫性障害）	5
posttraumatic_stress_disorder（PTSD）	5

3.2 研究内容

研究目的は，概ね以下の 4 領域に分類が可能であった。

①診療精度の向上（診断支援，治療効果・副作用の予測など）
②病因・病態の解明（ゲノム解析，画像解析など）
③新しい治療法の開発（医薬品，医療機器など）
④診断概念・診断体系の再構築

最もよく見られるタイプの研究は，何らかの疾患を有する患者群とその対照群（別疾患の患者や健常者）を設定し，それぞれの臨床データ（多くは画像情報）を用いて機械学習による分類を試行するという類のものであった（上記の①または②に該当する）。

画像情報以外に解析対象となったデータとしては，生理検査（脳波など），遺伝子情報，検体検査（血液など），心理検査，テキストデータ（カルテ記載内容）などがあった。

AI を用いた研究の，従来の医学研究にはない強みは，一言でいうと「個別性」である。ある診断を受けた患者たちを一塊にして全体的な傾向を論ずるのではなく，個々の患者ごとに，臨床経過を予測したり最適な治療法を選択したりといったことが可能になると期待されている。こうした発想は「精密医療 precision medicine」と呼ばれ，精神科に限らず，現代医学の潮流の一つを形成しつつある。

3.3 活用された AI 技術

表 2 と同様の手法で，AI（特に機械学習）関連用語の出現頻度を表 3 に示す。

最も多く出現した用語は“support vector machine”で，“random forest”，“logistic regression”と続いた。近年のニューラルネットワーク系技術の隆盛を考えると，表中の”deep learning“や”convolutional neural network”の出現数は意外に少ないという印象があり，今後の増加が期待される。

“Natural language processing”が比較的上位に来ているのは，身体所見や検査結果よりも患者の言語的情報（発話内容など）を重視するという精神科医療の特徴が現れている部分と考えられる。自然言語処理の技術は，精神科において今後特に重要な役割を果たす可能性がある。

表 3 abstract 中の AI 関連用語の出現数

support_vector_machine	27
random_forest	22
logistic_regression	20
deep_learning	12
natural_language_processing	11
decision_tree	10
convolutional_neural_network	9
naive_bayes	5

4. 現時点での課題

精神科領域における AI 活用を促進する上で，現時点での課題を 3 つ指摘しておきたい。

4.1 臨床医の AI に関する知識の乏しさ

私感ではあるが，少なくとも国内の精神科臨床医の多くは AI 技術と精神医学とを結びつける発想に乏しく，積極的な興味が示されることは少ない。マスコミを介した AI についての断片的なイメージはあるものの，その技術内容や成果に関する実質的理解には欠けており，「機械的」「非人間的」という連想から，どちらかというと漠然と拒否感を抱いている場合が少なくない。この現状を変えるためには，臨床現場あるいは学術研究において，AI の有用性を具体的成果として示していくことが必要だろう。

4.2 既存の診断概念への依存

前述したように，精神科の診断は生物学的な根拠（病態）に基づいてではなく，表面的な現象（症候）に基づいてなされるのが長年一般的であった。しかしこの方法に拘泥していては真に科学的といえる診断概念・診断体系に到達することはできない。AI を活用した精神医学研究は増加しつつあるが，その大部分は既存の診断体系の枠組みを十分に相対化できておらず，画期的といえるほどの成果はまだあがっていない。AI・機械学習という有力なツールを用いても，あやふな前提からはあやふやな結論しか出てこないというのは，ある意味当然ではある。

近年ようやく，既存の「精神疾患」について疾患概念そのものに疑問を投げかける言説が立場を得つつある。AI 技術を用いることで，生物学的根拠に基づいた新しい診断体系の構築が進むことが期待される。

4.3 個人情報保護

医療情報は非常にプライバシー性が高く，カルテの記載内容や検査結果などはほとんどが要配慮個人情報に該当するため，取り扱いには細心の注意が必要である。しかし一方で，個人情報の扱いに慎重になるあまり，AI 研究において萎縮効果が生じることも危惧されている［新保 17］。患者の個人情報保護に最善を期することは当然としても，人々の生命と健康を守るために不断の進歩を追究するという医学本来の役割が忘れられてはならない。新しいテクノロジーの恩恵を人々が正当に享受できるようにするために，行政，法律，医学など複数の視点から議論を行い，安全を確保しつつ研究を促進するような社会的環境を整えることが重要であろう。

5. おわりに —今後の展望・可能性—

冒頭に述べたように，医療の中でやや特殊な領域とみられることの多い精神科であるが，治療対象となる患者数は非常に多い。厚生労働省の医療統計によれば，2016 年の時点で全国の病床総数 166 万のうち，精神病床は 33 万床（20%）を占める。また，精神科病院の 1 日平均外来患者数は 57,000 人を超え，さらに増加傾向にある[厚生労働省 17]。AI 技術導入の対象分野として見た場合，診断様式や治療文化において独自の特徴を有する精神科医療は，それ自体が巨大な未開拓領域であるといえる。

AI 導入の必然性とそれがもたらすであろう革命的な変化を身近なことと実感している精神科医は，残念ながらまだ少数である。有用な技術を生み出すためには，臨床経験が豊富で医療データへのアクセスが容易な医療従事者と，優れた技術者との協働が不可欠である。また，患者のプライバシーが保証された上で自由な研究開発が可能になるような社会環境の整備も望まれる。

最後に，比較的低コストで試行可能と思われる具体例の一部を表 4 に示す。

表 4　AI 技術適用可能な試み（一部）

- Clozapine（『難治性統合失調症』治療薬）の副作用リスクの投与前評価
- 入院患者の自殺・暴力リスクのリアルタイム評価
  ⇒総合的な病棟管理システムへの発展
- ECT（電気けいれん療法）の患者ごとの有効性予測
- ADHD 治療薬の選択サポート
- 児童虐待リスクの評価
- 各精神障害の治療最適化
- 自閉症特性の病態仮説（ベイズ予測モデル）の検証

表中の最下段の例に関連して付言しておきたい。近年，「自閉症」や「統合失調症」の病態が，感覚刺激の処理プロセス（特に「予測機能」）の障害として一元的な視点から説明可能なのではないかという有力な仮説が提出されている[van Schalkwyk 17]。「予測: prediction」は，ヒトの知能の中核機能（少なくともその一つ）であると同時に，AI 研究の中心的な課題でもある。われわれは，AI の技術や知見が精神障害の解明に直接的に役立つ可能性，あるいは，（究極的には）ヒトの精神機能の全体を人工的に再現しうるという可能性すら視野に入れておくべきだろう。ここに，人工知能と精神医学との深いレベルでの接点があると筆者は考えている。

AI は，単に現行の医療の質を向上させるだけでなく，精神医学に理論的パラダイムシフトをもたらす主要な駆動力となるはずである。精神科医として，有為なエンジニア・データサイエンティストの参画を切望している。

参考文献

[Cross-Disorder Group of the Psychiatric Genomics Consortium 13] Cross-Disorder Group of the Psychiatric Genomics Consortium: Identification of risk loci with shared effects on five major psychiatric disorders: a genome-wide analysis, Lancet, 2013.

[橋本 18] 橋本亮太，山森英長，安田由華ら: Research Domain Criteria (RDoC) プロジェクトの概念，精神医学，医学書院，2018.

[厚生労働省 17] 厚生労働省: 平成 28 年医療施設（動態）調査・病院報告の概況，2017.

[野村 15] 野村総一郎，樋口輝彦: 標準精神医学 第 6 版，医学書院，2015.

[尾崎 18] 尾崎紀夫:「診断」という「線」を引くこと，精神医学，医学書院，2018.

[van Schalkwyk 17] van Schalkwyk, G.I., Volkmar, F.R., Corlett, P.R.: A predictive Coding Account of Psychotic Symptoms in Autism Spectrum Disorder, J Autism Dev Disord, Springer, 2017.

[新保 17] 新保史生: AI の社会実装に向けた法的課題と国民の意識変容，AI が創造する次世代型医療，日本医療企画，2017.

[高橋 14] 高橋三郎，大野裕: DSM-5 精神疾患の診断・統計マニュアル，医学書院，2014.

1 次元畳み込みによる心電位予測手法の提案

Proposal of prediction method of ECG via 1D-CNN

清水 茂樹[*1]
Shimizu Shigeki

穴井 晃太[*1]
Anai Kouta

山田 直人[*1]
Yamada Naoto

[*1] トヨタテクニカルディベロップメント株式会社
Toyota Technical Development Corporation

Recently, the ECG (Electro Cardio Gram) has attracted to estimate human condition, such as fatigue and stress. Measuring the human biological data for a long time it takes physical and mental load. In this paper, we propose a method to predict long-term ECG data based on short-term data. The typical methods such as LSTM are generally used to predict time series data. The target ECG is characterized by fluctuation in period and voltage, and it is required to predict fluctuating data. So, we evaluated a 1 Dimension Convolution Neural Networks method using a filter size that matches the frequency characteristic of ECG. We showed that the method can be predicted more accurately than the LSTM. This result suggests that it can be an effective means when predicting long-term data.

1. まえがき

近年,人間の疲労やストレスを測るために心電位が注目されている[森 2009].疲労やストレスは,大量の心電位を用いて機械学習や深層学習のアルゴリズムによる推定が行われている. [下田 2016]このアルゴリズム開発には,心電位の時系列データを必要とするが,心電位を計測するセンサは長時間装着している場合,人の動きを制限し身体的・精神的負担が大きくなる. [濱谷 2015]そこで,短時間データから長時間データを予測生成する技術が求められている.

一方,時系列データの予測生成には,深層学習による予測生成が注目されている.これまで予測生成に用いられている深層学習は LSTM (Long Short Term Memory)などの手法が一般的である. [松井 2017] [Chen 2015]しかし,これらの手法は学習データが長時間データで行われているケースであり,短時間データで学習,予測されているケースは少ない.

そこで本研究の目的は,短時間データの特徴を学習し,特徴を保持した長時間データの予測生成を行うこととする.本研究で予測生成する対象データは,心電位とし,心電位の周波数的特徴を活用し,周波数特性に応じたフィルターを使用する 1 次元畳み込み手法を提案する.

2. 実験方法

本実験の流れを示す. 被験者の心電位を計測する.被験者は 20 代成人男性 1 名で実施した計測時間は 5 s とし,5 s 間のデータの学習を実施した.被験者にはなお,実験に先立ち,当社内でプロジェクト実施許可申請の許可を得た上で,各被験者に対し実験に際するリスクを説明し,インフォームドコンセントを得た.

2.1 計測器

図. 1 に示すようにセンサは市販のディスポーサブル電極を使用し, その取り付け位置は被験者の左胸部近辺に心臓を挟むように取り付けた. 学習データを一度に多く獲得するため, 電極を 3 つ貼り付けた. 無線アンプは自社開発製品の Livo(生体信号記録システム)を使用し, 計測は 100 Hz のサンプリングレートで実施した. 計測された心電信号について, 0.4 ～ 50 Hz のバンドパスフィルタを用いて前処理を行い, 筋電由来のノイズや呼吸由来のノイズを低減させた.

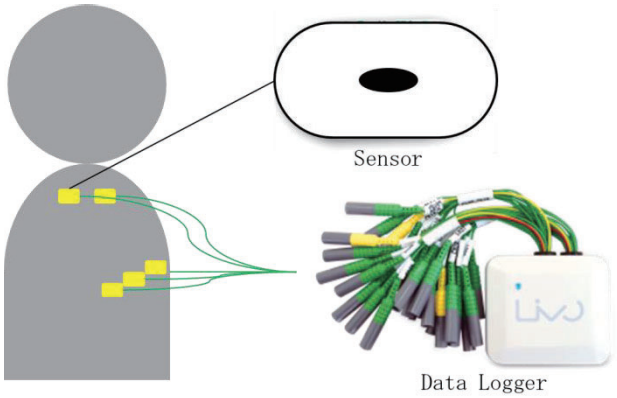


図.1 生体センサ装着 イメージ図

2.2 学習データ

本研究では取得データを以下のステップで解析を実施した. (1)筋電や呼吸由来のノイズ除去のため,0.4 Hz～50 Hz のバンドパスフィルター処理を行う.(2)心電図の波形を 0~255 までの 256 点と 256~271 の 16 点に分離する. (3)256 点と 16 点をそれぞれ学習データと正解データとして格納する.(4)データを 1 サンプリングごとにシフトする.

3. 従来手法

これまで時系列データの学習には RNN が一般的に用いられてきた. RNN は,前回の出力を現在の入力に追加するものである.LSTM は RNN の発展系であり,長時間データの学習を可能にしている.[Hochreiter & Schmidhuber 1997] LSTM のネットワークは,入力層, 中間層, 出力層から構成され, 中間層が LSTM から構成されるものである. 本報告では LSTM のブロックを 1 層導入したモデルを用いて評価を実施した.

4. 提案手法

本研究で提案する 1 次元畳み込みによる予測手法は、畳み込みにおけるフィルターサイズを決める必要がある.フィルターサ

連絡先: トヨタテクニカルディベロップメント株式会社 清水茂樹
〒 470-0334 愛知県豊田市花本町井前 1-9
E-mail: shigeki.shimizu@mail.toyota-td.jp

イズは、ターゲットとなる心電位の周波数解析による結果と照らし合わせ決定した.今回は 50,25,12.5,6,4 Hz 相当の 1 次元畳み込みフィルターを設定し、それぞれ独自に畳み込みを行うように Inception モジュールを設計した.モデル概要を図.2 に示す

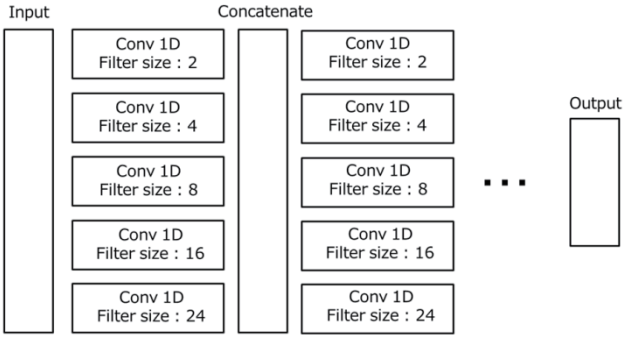
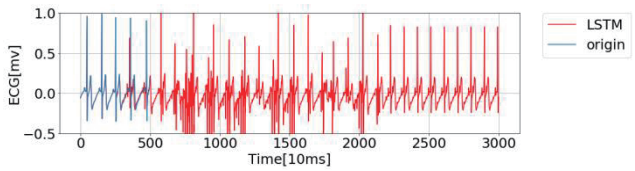


図. 2 1 次元畳み込みネットワークモデル概要

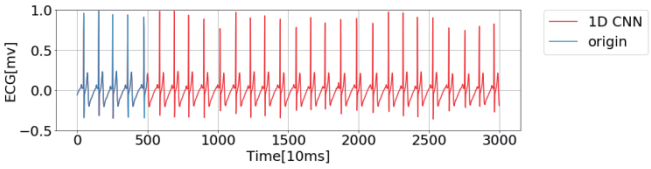
従来手法と提案手法を確認する検証方法として、人間の実測値との比較を実施した.心電位の解析は一般的にピーク波となる R 波の間隔である RRI (Rwave Rwave Interval)を用いられる.RRI の逆数が心拍数となるため、心拍数の平均・ゆらぎを用いて比較を実施した. [Akselrod 1981]予測生成したデータの平均・ゆらぎが人間のデータに近いほど優勢であると判断をする.

5. 結果

各手法を用いた心電位の学習,予測結果を図.3(a)(b)に示す.



(a) LSTM



(b) 1-D CNN

図.3 各手法における予測結果

LSTM による予測結果では,心拍ゆらぎは発生せず,一定の周期で信号生成されている.これは,学習データに用いるデータ数が短時間分(5 s≒4~5 波形)による影響が大きいことが考えられる.1 次元畳み込みによる予測結果は,ピーク間隔のゆらぎを保持したデータ生成が出来ている様に見受けられる.また,心電位のピーク値についてもゆらぎを確認することが出来た.

表.1 LSTM と 1 次元畳み込みにおける比較

	心拍数平均	心拍数分散
LSTM	62.5	0.3
1 次元畳み込み	56.3	6.3
(参考)人間実測値	58.8	4.0

人間の実測値との比較結果を表.1 に示す.LSTM では,短時間データによる学習ではゆらぎが発生しない.一方,提案手法である 1 次元畳み込みによる手法では, 5 s≒4~5 波形の短時間データで学習,予測を行った結果,ゆらぎを保持したデータの予測生成が行われている.この結果が示すように,人の心拍数平均,ゆらぎと比較しても同程度の平均,分散と遜色ない結果となった.

6. まとめ

本研究における提案手法である 1 次元畳み込みによる時系列データの予測生成は、従来手法の LSTM より高精度にゆらぎを持ったデータの生成が行える可能性があることを示した.長時間データを用いた学習・推論である場合には LSTM の方が優位な場面も想定されるが、今回のターゲットのように短時間データで長時間データを予測生成する場合に有効な手段となりうることを示唆する.本研究では被験者 1 名のデータでの実験のため、今後は被験者数を増やし検証していく必要がある.

参考文献

[森 2009] 森 信彰: 心拍変動による精神ストレスの短時間解析に関する研究, 年次大会講演論文集, 日本機械学会,2009.

[下田 2016] 下田 宏: 生理指標計測による心理活動推定の問題, 人間工学 52(Supplement), 日本人間工学会, 2016.

[濱谷 2015] 濱谷尚志: 種々のセンサを併用した集中度センシング法の検討, 研究報告高度交通システムとスマートコミュニティ(ITS),情報処理学会, 2015.

[松井 2017] 松井 藤五郎: LSTM を用いた株価変動予測, 人工知能学会全国大会論文集, 人工知能学会, 2017.

[Chen 2015] K.Chen: A LSTM-based method for stock returns prediction: A case study of China stock market, 2015 IEEE International Conference on Big Data (Big Data), Santa Clara, CA, pp. 2823-2824, 2015.

[Hochreiter 1997] Hochreiter:Long Short Term Memory, Neural Comput., Vol. 9, No. 8, pp.1735 - 1780, November 1997.

[Akselrod 1981] Akselrod: Power spectrum analysis of heart rate fluctuations: quantitative probe of beat-to-beat cardiovascular control, Science, 213, 220-222, 1981.

[2O4-J-7] Agents: human interaction

Chair:Hirotaka Osawa Reviewer:Yoshimasa Tawatsuji

Wed. Jun 5, 2019 3:20 PM - 4:20 PM Room O (Front-left room of 1F Exhibition hall)

[2O4-J-7-01] Fostering Empathy for Computer Agents through Synchronized Movements

○Naohiro Eda[1], Katie Seaborn[2], Seito Matsubara[3], Ken Sakuma[3], Atsushi Hiyama[2,3], Masahiko Inami[3] （1. The Faculty of Engineering,The University of Tokyo, 2. RIKEN Center for Advanced Intelligence Project, 3. Graduate School of Information Science and Technology, The University of Tokyo）

3:20 PM - 3:40 PM

[2O4-J-7-02] Drawing interaction between human and recurrent neural network

○Hikaru Yanagida[1], Shingo Murata[2,3], Kentaro Katahira[4], Shinsuke Suzuki[5], Tetsuya Ogata[1], Yuichi Yamashita[6] （1. Department of Intermedia Art and Science, School of Fundamental Science and Engineering, Waseda University, 2. Principles of Informatics Research Division, National Institute of Informatics, 3. Department of Informatics, School of Multidisciplinary Sciences, The Graduate University for Advanced Studies (SOKENDAI), 4. Department of Cognitive and Psychological Sciences, Graduate School of Informatics, Nagoya University, 5. Creative Interdisciplinary Research Division, Frontier Research Institute for Interdisciplinary Sciences, Tohoku University, 6. Department of Functional Brain Research, National Institute of Neuroscience, National Center of Neurology and Psychiatry）

3:40 PM - 4:00 PM

[2O4-J-7-03] Influence of polite greetings on attachment of a voice agent

○Ken Sasaki[1], Miho Kitamura[2], Keiichi Kurata[3], Katsumi Watanabe[1] （1. Graduate School of Fundamental Science and Engineering, Waseda University, 2. Waseda Institute for Advanced Study, 3. DENSO CORPORATION）

4:00 PM - 4:20 PM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

運動同期によるエージェントへの共感醸成に関する研究

Fostering Empathy for Computer Agents through Synchronized Movements

江田 尚弘 *1 Naohiro Eda　シーボン ケイティー *2 Katie Seaborn　松原 晟都 *3 Seito Matsubara　佐久間 顕 *3 Ken Sakuma　檜山 敦 *2*3 Atsushi Hiyama
稲見 昌彦 *3 Masahiko Inami

*1東京大学工学部 The Faculty 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 RIKEN Center for Advanced Intelligence Project
*3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

When people are synchronized in their movements - performing the same action at the same time - there can be an increase in positive emotions, for example feelings of camaraderie, similarity, and mutual liking. On the other hand, previous research exploring synchronized movements between humans and computer agents has not found such an effect. In this study, we designed and evaluated a system for exploring human empathy towards computer agents by synchronizing their movements in an audio-haptic rhythm game. Our goal was to explore the mediating effects of two social factors: adjusting the synchronization of the agent ' s movements based on the human ' s movements and modifying the social presence of the agent. Our results showed that, in contrast to previous research, synchronizing movements by adjusting the agent to the human influenced feelings related to empathy; however, modifying the social presence of the agent did not have an effect.

1. 序論

1.1 研究背景

本研究では, 運動同期という現象に注目する. 運動同期とは, あるタスク中で 2 人の体験者の動作が同期するような状況で正の感情が上昇する現象であり, 具体な状況の例としては軍隊の行進や宗教的な儀式の際, 同じ動作を全員が行う状況が挙げられる. 先行研究ではボタンを押す動作の同期や歩行の同期などにより, 被験者の仲間意識・類似性の知覚・好感度などの正の感情が上昇することが示されている [Valdesolo 11][Wiltermuth 09]. 一方で, 相手が人間ではなくエージェントであると認識している状況では, 正の感情の上昇が確認されていない [Launay 14].

1.2 本研究の目的

本研究では, エージェントとの運動同期を用いた, エージェントへの共感の誘発の確認と, その条件の検証を目的とする. 特に, 本研究ではエージェントとの運動同期に関する条件の中で, 以下の 2 つの条件に注目し, それぞれの条件に関する仮説の検証を目的とする.

1.2.1 エージェント側からの協調に関する仮説

Launay ら [Launay 14] の実験では, 運動同期の相手のエージェントがプログラムに従って動作を行っており, 被験者がエージェントに合わせるように動作しなければ全く運動同期が起こらない. そのため相手がエージェントであると被験者が知った場合, 被験者はエージェントが過去の自身の動きを全く反映していないと感じる. このことが感情変化の起こらない大きな要因の一つであると考えられる.

本研究では, 被験者に同期に関する特定の意図がなくとも, 被験者の過去の動きを参考にしてエージェントから被験者に合わせるような運動同期を行うことよって, 被験者のエージェントに対する仲間意識・類似性の知覚・好感度が上昇する, という仮説を立て, そのような運動同期を行う実験系を用意した.

1.2.2 社会的な存在としてのエージェントの提示に関する仮説

エージェントとの運動同期による先行研究においてはエージェントの社会的な存在としての知覚に注目している研究はない. 一方で, HAI における研究では, エージェントに対し, 社会的存在としての提示を行う研究は多くあり, 提示による影響が示されている.

本研究では, エージェントに対して社会的な存在としての提示がある場合の方が, ない場合よりも運動同期による効果が大きく表れる, という仮説を立て, それぞれエージェントを用意し運動同期の効果を比較した.

2. 実験系内のシステム

2.1 実装システムの概要

実験系内のシステムとして, エージェントと運動同期を行うためのタスクとエージェントの提示のためのシステムをそれぞれ別の iPad 上で実装し, タスク中に行う振動による被験者へのタップ指示のシステムを Arduino と振動子で実装した. 各 iPad および Arduino 間は情報の通信をしておらず, 実装は別々に行った. また, 実験中のそれぞれの iPad と Arduino の操作は手動で行う.

2.2 エージェントと運動同期を行うためのタスクとタスク中の指示の実装

2.2.1 運動同期を生起させるためのタスク

被験者はエージェントと一緒に iPad 上のボタンをタップするタスクを行う. ボタンはプレイヤーにつき左右に二つあり, 各ボタンをタップすることによって, それぞれボタンに対応する効果音が流れ, 対応する縦長もしくは横長のバーが iPad 上

連絡先: 江田尚弘, 東京大学稲見・檜山研究室, eda@star.rcast.u-tokyo.ac.jp

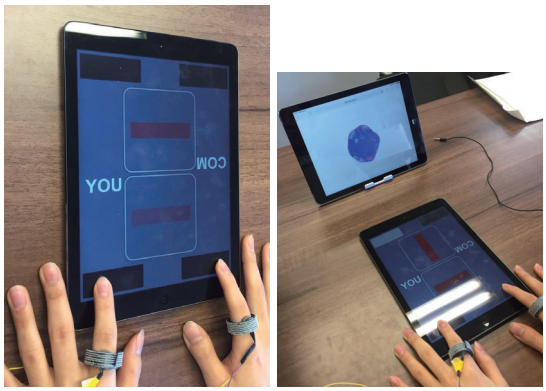


図 1: タスク中の様子. (左) 提示がない場合, (右) 提示がある場合

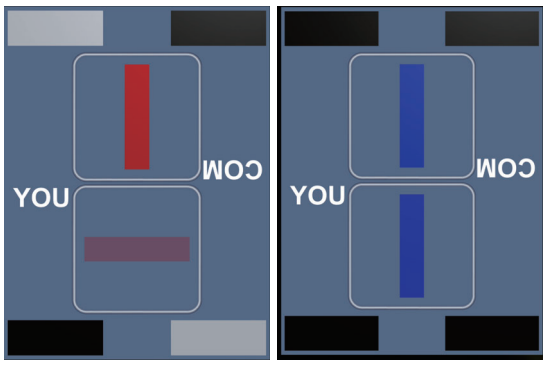


図 2: タスク画面.（左）同期していない場合,（右）同期している場合.

に提示される. バーの提示とボタンは被験者側, エージェント側の両方にそれぞれ表示される. またバーの色は被験者とエージェントが同じタイミング（前後 0.05 s 以内）で同じボタンをタップした場合, 提示のバーの色が青色になる. タスクの様子を図 1, 図 2 に示す.

2.2.2 被験者のタップ動作に関する指示

被験者にはボタンをタップする際, 左右両方のボタンを押した状態を基準として, ボタンをタップした後すぐに基準の状態に戻すように指示をした. これは指をボタンから離してから再び押すまでの時間を計測し, エージェントの行動に反映させるためである.

2.2.3 振動による被験者への動作タイミングの指示システム

被験者には左右の人差し指の根元に振動子のついた装置をつけてもらい, 振動した方の指で振動した瞬間にボタンをタップしてもらう (図 1). 振動による指示の内容は, 等間隔で 4 度左右どちらかの振動子が振動した後, 5 s 空いて再度等間隔で振動する, というのを繰り返す, というものである. 左右のどちらの振動子が振動するかはランダムで毎回決定され, 4 度の振動の間の間隔も指示が始まる前に, 500 ms, 1000 ms, 2000 ms, 4000 ms の中からランダムに選ばれる.

2.3 エージェントの実装

2.3.1 エージェントのタスク中の動作

タスク中, エージェントは, 被験者が指をボタンから離した瞬間から, 決められた秒数だけ待機し, ボタンをタップする. 待機する時間は, 正規分布の正の領域を確率分布として出力される時間とする. 正規分布の平均は被験者が指を離して再びタップするまでの時間とし, 分散は, 同期する条件では, 0.03, 同期しない条件では, 0.5 とした. また, 同期する条件では, 出力された時間に, 遅れ時間を足した時間待機した. 遅れ時間は, 初期値が 0.3 で, 被験者がボタンをタップするたびに 0.01 から 0.03 までの値がランダムに引かれ, 0 以下になると値が 0 に固定する. また, タップするボタンの種類として, 被験者と同じボタンをタップする確率を, 同期する条件では 9 割, 同期しない条件では 4 割とした.

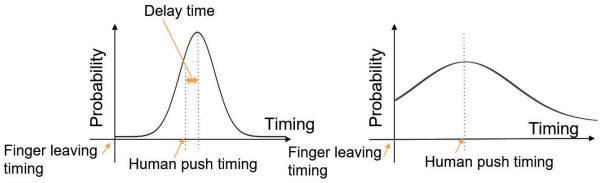


図 3: （左）動作が同期する場合の確率分布,（右）動作が同期しない場合の確率分布.

2.3.2 エージェントの提示

エージェントの社会的な存在としての提示として, タスク前のテキストによる簡単なコミュニケーションと, タスク中におけるアニメーションによる姿の提示の 2 つを実装した. アニメーションは Gleb Kuznetsov 氏の ”Art motion for AI product design”[Kuznetsov] を使用した.

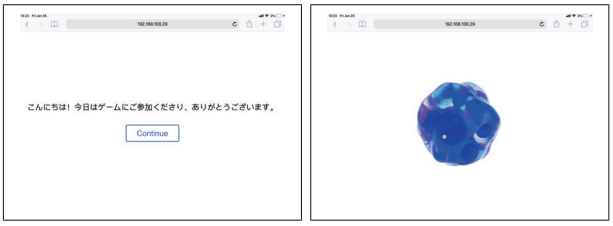


図 4: (左) タスク前のコミュニケーション, (右) 表示されるアニメーション (出典： Gleb Kuznetsov 氏).

3. エージェントに抱く感情に対しての評価

3.1 実験に関するアンケート

タスク後に被験者に実験に関するアンケートに答えてもらった. 以下項目について述べる.

エージェントへの感情の変化を調べる際に対象とする項目は, 以下の 5 項目とした.

- タスクの面白さ (q1)
- 相手エージェントへの仲間意識 (q2)
- 相手エージェントと自分との類似性 (q3)
- 相手エージェントへの好感度 (q4)
- 相手エージェントの行動に対しての好感度 (q5)

なお, タスクの面白さに関しては, タスクの面白さの知覚がエージェントへの感情の変化に影響を与える可能性があるため, タスクの面白さの主観量に関しても評価対象とした.

また, インタラクションの影響なども含め, 被験者がどれほどエージェントを社会的な存在として強く認識しているかに

ついては, 以下の 7 項目を用いて評価した. これらの項目は IJsselsteijn ら [IJsselsteijn 13] のアンケートを参考にし, 作成した.

- 自分の行動が相手 (エージェント) の行動に依存していると感じたか
- 相手の行動が自分の行動に依存していると感じたか
- 相手とのつながりを感じたか
- 自分が相手に注意を払っていると感じたか
- 相手が自分に注意を払っているように感じたか
- 自分の行動が相手に影響を与えていると感じたか
- 自分が相手の行動によって影響を受けたと感じたか

また, 本研究における仮説には直接関わらないが

- エージェントを人間らしいと感じたか

という項目も考察対象とする.

被験者には, いずれの項目も 7 段階で回答してもらう.

3.2 エージェントからの質問

エージェントが人間の意識について学びたいという状況で, 回答は任意としてアンケート後に被験者にエージェントからの質問に答えてもらった. 主観評価である, 実験に関するアンケートは異なる側面からの考察を目的として行った. 質問の具体的な内容は, 幸せの定義や生きる意味など哲学的な内容になっている. 質問と回答はエージェントの提示を行った iPad で行い, 提示がない条件においても, タスクを行う iPad とは別の iPad を使用した. なお, 質問の文章はエージェントの提示ありの条件においてタスク前のコミュニケーションにおいて用いたテキストと異なる印象を与えないように, エージェントの提示ありの場合と提示なしの場合で, 同内容で印象のみを変化させた文章を用意した. 質問は 6 問用意した. 評価は, 回答数と回答の文字数で行った.

4. 実験

4.1 実験詳細

被験者 28 名に対して実験を行った. 実験条件として, 運動同期の有無の条件を被験者内で, 社会的な存在としての提示の有無の条件とし, それぞれ 14 名ずつを提示がある条件と, 提示がない条件に分け, 実験を行った. 実験の謝金として各被験者に 1000 円を支払った. 用意したエージェントからの質問は, 運動同期の有無による前半と後半の試行で 3 問ずつに分けた. これにより, 各条件で質問は 3 問ずつとなる. また, 実験目的として,「エージェントとの音楽創造」という偽の実験目的を説明した. 図 5 に示すような実験状況で実験を行った.

4.2 結果

4.2.1 実験アンケート

実験アンケートにおける, エージェントへの感情に関する各質問に関する結果は図 6 のようになった. また, エージェントの社会的な存在としての知覚に関する 7 つの項目を合計した. その結果を図 7 に示す. 次に, 各項目に対して, 混合計画二要因分散分析を行った結果を表 1 に示す. 表 1 からエージェントへの感情に関する項目と社会的な存在の知覚に関しては, 運動同期の有無による条件で有意差が見られ, 提示の有無による条件では有意差が見られなかった. また, 人間らしさの知覚に関しては, いずれの条件でも有意差は見られなかった.

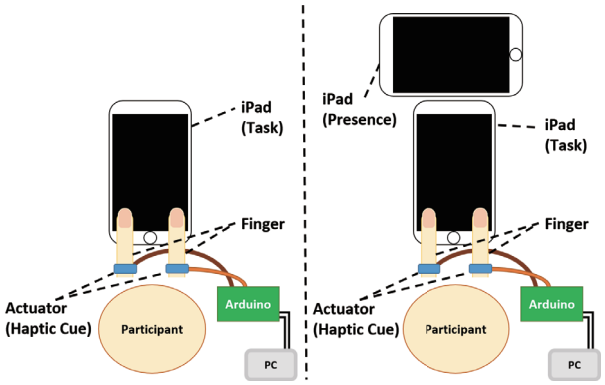


図 5: 実験の状況図. (左) エージェントの提示がない場合, (右) エージェントの提示がある場合.

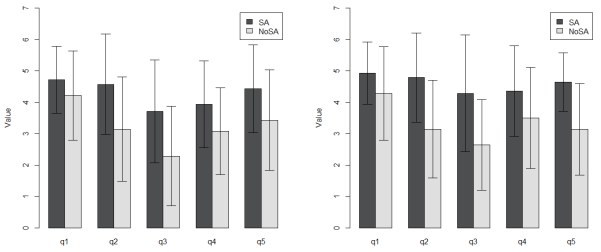


図 6: エージェントへの感情に関する各質問のグラフ. (左) 提示がある条件, (右) 提示がない条件. (SA (Shared Action): 運動同期あり, NoSA: 運動同期なし.)

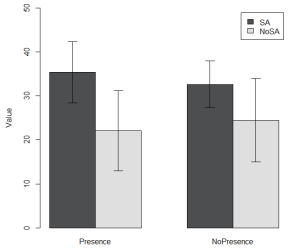


図 7: 社会的な存在としての知覚に関するグラフ. (Presence: 提示あり, NoPresence: 提示なし, SA: 運動同期あり, NoSA: 運動同期なし)

4.2.2 エージェントからの質問

被験者 28 名のうち, 実験中のエージェントからの質問 6 問すべてに回答しなかった被験者は 3 名のみであったため, 回答数による評価は行わず, 回答の文字数のみに関して評価を行った. 回答の文字数に関して, 前半の 3 問と後半の 3 問で質問の内容に大きな差はないとして, 前半と後半の回答の文字数の合計を評価した. なお, 回答していない質問に関しては, 文字数を 0 文字とした. 分散分析を行った結果, 表 1 から, 各条件に有意差は見られなかった.

表 1: 各項目に対する分散分析の結果と効果量. (c1: 提示の有無, c2: 運動同期の有無, *: p<0.05, **: p<0.01, ***: p<0.001.)

		分散比	p 値	
q1	c1	0.12	0.731	
	c2	5.6	0.0261	*
	c2:c1	0.087	0.770	
q2	c1	0.068	0.797	
	c2	13	0.00123	**
	c2:c1	0.064	0.802	
q3	c1	0.85	0.365	
	c2	18	0.000237	***
	c2:c1	0.088	0.769	
q4	c1	0.94	0.34	
	c2	6.7	0.0153	*
	c2:c1	0	1	
q5	c1	0.007	0.932	
	c2	16	0.000415	***
	c2:c1	0.66	0.426	
社会的存在としての知覚	c1	0.006	0.938	
	c2	31	8.00E-06	***
	c2:c1	1.8	0.19	
人間らしさの知覚	c1	3.858	0.0603	
	c2	0.41	0.529	
	c2:c1	0.18	0.674	
エージェントからの質問	c1	0.976	0.332	
	c2	0.024	0.879	
	c2:c1	0.053	0.819	

5. 考察

5.1 運動同期の有無

得られた結果から, 本実験におけるエージェントが被験者側に協調するという条件によって, 相手がエージェントと知覚した場合においても運動同期によって被験者の仲間意識・類似性の知覚・好感度といった感情に影響を与えることができたと言える.

一方で, 運動が同期しない場合にエージェントに対して負の感情を抱いている可能性が考えられるため, 仮説のように被験者のエージェントに対する仮説の 3 つの感情が上昇したことが示唆されることまでは言えない.

5.2 社会的な存在としての提示の有無

得られた結果から, 本研究における社会的な存在としての提示は, 被験者のエージェントの社会的な存在としての知覚に影響を及ぼさなかったと言える.

5.3 エージェントからの質問

本実験のいずれの条件に関しても有意な差は見られなかった. 一方で, 実験に関するアンケートの各項目に関してはエージェントに関するいくつかの感情に差があることが示唆されているため, 本実験におけるエージェントからの質問による評価が, 被験者のエージェントに対する共感とあまり対応していないことが考えられる.

5.4 その他の要因・傾向

5.4.1 タスクの面白さによる影響

結果からタスクの面白さの知覚による影響がないとは言えないが, 一般化イータ 2 乗で効果量を計算した値は, 0.05 程度と小さい効果を示す値となっており, 影響も小さいと考えられる.

5.4.2 人間らしさの知覚による影響

各条件で有意差は見られなかったが, 特に提示の有無による条件による影響がないとは言えない. もし, 人間らしさの知覚に差がある場合で, エージェントへの各感情に影響がなければ, 運動同期において人間らしさの知覚は必要ないことが考えられる.

5.4.3 引き込み

運動同期を行った条件において多くの被験者に, エージェントが被験者のタップに対応せず自らボタンをタップした際に, 被験者もつられてタップしてしまう現象が見られた. これは, 身体動作における引き込み現象と考えられる.

6. 結論

本研究では, エージェントとの運動同期による効果とその効果に影響を与える条件を調べるため, エージェントの協調とエージェントの社会的な存在としての提示に注目し, 実験を行った. 結果からエージェントの協調の条件に関してはアンケートによって評価された各感情の変化に有意差が見られ, 立てた仮説のように上昇したことまでは言えないが, エージェントの協調を伴った運動同期によって, 先行研究では確認されなかった, エージェントに抱く感情への影響が生じたことが示された. また, 本研究で行った提示は, 社会的な存在としての提示として不十分であったことが言える.

今後の展望として, 本実験による効果を相手が人間の場合の効果と比較することにより, 社会的存在の中でも特に人間らしさの知覚による影響に関する議論や, 効果の大きさに関する更なる議論が可能になることが期待される.

謝辞

本研究の一部は，JSPS 外国人研究者招へい事業（外国人特別研究員）および JST 国際科学技術協力基盤整備事業の支援を受けた.

参考文献

[IJsselsteijn 13] IJsselsteijn, W., De Kort, Y., and Poels, K.: The game experience questionnaire (2013)

[Kuznetsov] Kuznetsov, G.: Art motion for AI product design, https://dribbble.com/shots/4937969-Art-motion-for-AI-product-design: （参照 2018-12-07）

[Launay 14] Launay, J., Dean, R. T., and Bailes, F.: Synchronising movements with the sounds of a virtual partner enhances partner likeability, *Cognitive processing*, Vol. 15, No. 4, pp. 491–501 (2014)

[Valdesolo 11] Valdesolo, P. and DeSteno, D.: Synchrony and the social tuning of compassion., *Emotion*, Vol. 11, No. 2, p. 262 (2011)

[Wiltermuth 09] Wiltermuth, S. S. and Heath, C.: Synchrony and cooperation, *Psychological science*, Vol. 20, No. 1, pp. 1–5 (2009)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

人とRecurrent Neural Networkの描画インタラクション実験 –Web実験による大規模学習用データ収集とその解析–

Drawing interaction between human and recurrent neural network –Web-based large-scale data collection for training and its analysis–

柳田 耀 *1 Hikaru Yanagida
村田 真悟 *2*3 Shingo Murata
片平 健太郎 *4 Kentaro Katahira
鈴木 真介 *5 Shinsuke Suzuki
尾形 哲也 *1 Tetsuya Ogata
山下 祐一 *6 Yuichi Yamashita

*1早稲田大学 基幹理工学部 表現工学科
Department of Intermedia Art and Science, School of Fundamental Science and Engineering, Waseda University

*2国立情報学研究所 情報学プリンシプル研究系
Principles of Informatics Research Division, National Institute of Informatics

*3総合研究大学院大学 複合科学研究科 情報学専攻
Department of Informatics, School of Multidisciplinary Sciences, The Graduate University for Advanced Studies (SOKENDAI)

*4名古屋大学大学院 情報学研究科 心理・認知科学専攻
Department of Cognitive and Psychological Sciences, Graduate School of Informatics, Nagoya University

*5東北大学 学際科学フロンティア研究所 新領域創成研究部
Creative Interdisciplinary Research Division, Frontier Research Institute for Interdisciplinary Sciences, Tohoku University

*6国立精神・神経医療研究センター 神経研究所 疾病研究第七部
Department of Functional Brain Research, National Institute of Neuroscience, National Center of Neurology and Psychiatry

To investigate human interactive behavior, we designed a drawing interaction task between a human and a recurrent neural network (RNN). This study especially collected a large-scale dataset of drawing for training an RNN and self-report psychiatric questionnaires on the web. We visualized the drawing data and analyzed the questionnaire items collected from 1,035 participants. We found correlations between different psychiatric symptoms and the existence of three-factor solutions on the correlation matrix of all the questionnaires.

1. はじめに

インタラクションは会話，スポーツなどという形で我々の生活に深く関与している．しかし，インタラクションを苦手とする人（精神疾患患者など）も存在する．彼らを支援する方法を考えた時，まずはインタラクションそのものを理解することが大切になる．実生活におけるインタラクションの要点を考慮すると，(1) 意図を含んだ行為の双方向性，(2) リーダーとフォロワーの連続的変動の 2 要素に着目した解析を行う必要がある．

インタラクション研究の手法は大きく分けて人対人，人対人工物の 2 種類であるが，本研究では解析のしやすさから人対人工物に着目する．その中で特に参考になる研究として，人とロボットの模倣インタラクションに関する研究 [Murata 16] がある．リカレントニューラルネットワーク（RNN）を用いて人–ロボット間で模倣インタラクションを行い，参加者を自閉スペクトラム症者と定型発達者の 2 つにグループ分けをしている．インタラクションの双方向性，連続的変動という 2 要素を踏まえられているものの，サンプル数が 57 と少なく，実験結果をグループ間の違いのみで評価しているという問題がある．これら 2 つの問題点を解決している Web 上画像選択タスクによるデータ解析 [Gillan 16] では，大規模データと複数の精神疾患傾向尺度との関連について解析している．また，Web 上で人–RNN 間の描画を扱った研究として Sketch-RNN[Ha 17] がある．

連絡先: 柳田 耀，早稲田大学基幹理工学部表現工学科，〒 169-8555 東京都新宿区大久保 3-4-1，yanagida@idr.ias.sci.waseda.ac.jp

上で述べた 3 つの先行研究を踏まえ，本研究では複数の精神疾患尺度を用いたインタラクション解析を通して，人によるインタラクションの違いを理解することを目的とする．具体的には，双方向性・連続的変動があり，大規模かつ広く精神疾患に着目した描画インタラクションの解析を行う．今回は特にインタラクション実験のための 1000 人規模でのデータ収集を行った．

2. 手法

タスク設定を図 1 に示す．人と RNN はそれぞれ赤いスタート地点から緑のゴールまで、2 つの四角い中継点のうちのどちらかを通り線を描く．この時，人は事前に選択した中継点を通り，かつ RNN の描く線となるべく近くなるように線を描くことが求められる．RNN も事前に設定された中継点を通り，かつ人の振る舞いを受けた経路を描く．人と RNN とが互いに影響を与え，また，どちらが先行するかも連続的に変化しながらスタートからゴールまで経路をたどる．これは先に述べた双方向性と連続的変動を含んだインタラクションを簡略化したタスク設定であるといえる．本実験は，以下の 3 つの手順で行う．

1. Web 上軌道データ収集
   スタート，中継点，ゴールの経路をたどるタスク．クラウドソーシングを用いて 1000 人程度分集める．
2. 学習
   1 で取得したデータを RNN で学習させる．
3. 人–RNN 間インタラクション実験
   2 で学習させたモデルを用いて人とのインタラクション実験を行う．

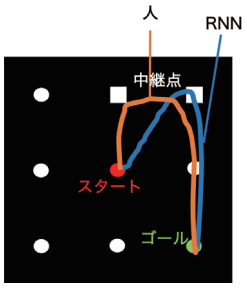


図 1: 人–RNN 間描画インタラクション

本研究では 1 段階目の Web 上軌道データ収集までを行った．データ収集の流れは以下の通りである．

i スクリーニング
クラウドソーシングで問題となる「注意を十分に割かない回答者（Satisfice 傾向）」を検出するためのスクリーニングを行う．

ii 軌道データ収集
スタートから中継点を通りゴールに行くまでの経路データを収集する．

iii 精神疾患傾向に関するアンケート
統合失調症 (SPQB)，強迫性障害傾向 (OCI)、鬱傾向 (PHQ)，状態不安 (STAI1)，特性不安 (STAI2)，自閉スペクトラム傾向 (AQ)，注意欠陥・多動性障害 (ADHD) 傾向 (ASRS) の尺度を用いる．

3. 結果

1 人あたり 28 種類，計 168 個の軌道データを 1050 人分収集した．収集した軌道パターンの例を図 2 に示す．

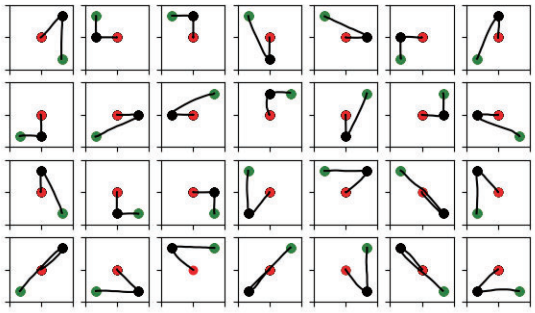


図 2: 軌道パターン

であり，そのうちの 1025 人は成功率（正しくスタート，中継点，ゴールを通ることができていた）が 95%以上であった．また，注意を十分に割かない回答者（Satisfice 傾向）を検出するために項目内容の精読を要する設問を用いた．正しく回答できなかった人は 1035 人中 5 人のみであった．

7 つの精神疾患傾向（統合失調症，強迫性障害，鬱，状態不安，特性不安，自閉症，ADHD）同士の相関分析を行った結果，各精神疾患傾向尺度間で正の相関が見られた．先行研究 [Gillan 16] と同様に，特に鬱と不安，自閉症と統合失調症との間に強い正の相関が確認された（図 3）．

また，精神疾患傾向の全質問項目間の因子分析を行ったところ，強迫性障害傾向，不安・鬱傾向，自閉傾向の 3 因子に大別された（図 4）．

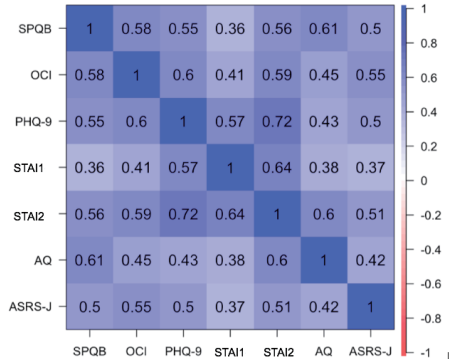


図 3: 相関分析結果

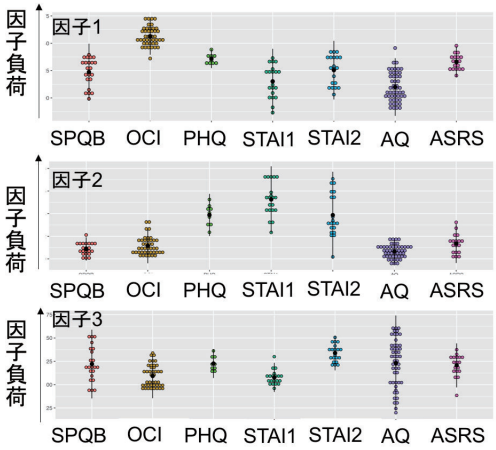


図 4: 因子分析結果

4. まとめ

本研究では，Web 上で人–RNN 間の描画インタラクション実験を行うための，タスクデザイン，学習用大規模データ収集とその解析を行った．精神疾患項目間の相関分析，因子分析の結果が先行研究の結果と概ね一致することが確認された．今後は本実験で収集したデータを用い RNN の学習を行い，人と学習させた RNN による描画インタラクションの大規模 Web 実験を行う予定である．

参考文献

[Murata 16] S. Murata, K. Hirano, H. Arie, S. Sugano, and T. Ogata: Analysis of imitative interactions between humans and a robot with a neuro-dynamical system,' in 2016 IEEE/SICE International Symposium on System Integration (SII), (2016), pp. 343-348.

[Gillan 16] C. M. Gillan, M. Kosinski, R. Whelan, E. A. Phelps, and N. D. Daw: Characterizing a psychiatric symptom dimension related to deficits in goal-directed control, Elife, vol. 5, p. e11305, (2016).

[Ha 17] David Ha, Douglas Eck: A neural representation of sketch drawings, arXiv preprint arXiv:1704.03477, (2017).

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

呼びかけ語の丁寧さが音声エージェントへの愛着に与える影響

Influence of polite greetings on attachment of a voice agent

佐々木 健[*1] 北村 美穂[*2] 倉田 啓一[*3] 渡邊 克巳[*1]
Ken Sasaki Miho Kitamura Keiichi Kurata Katsumi Watanabe

[*1] 早稲田大学大学院基幹理工学研究科表現工学専攻 [*2] 早稲田大学高等研究所 [*3] 株式会社デンソー
Graduate School of Fundamental Science and Engineering, Waseda University Waseda Institute for Advanced Study DENSO CORPORATION

Many voice agents are nowadays equipped with spoken dialogue functions. It is assumed that the user's attachment of a voice agent play an important role in promoting the voice agent. In the present study, we examined whether the degree of politeness of greeting would influence the attachment of the voice agent. Here, we compared effects of the greeting "Sumimasen" (polite "excuse me" in Japanese) with "Ano-" (inpolite "excuse me") while participants interacted with a virtual driving assistant system. We found that the polite greeting "Sumimasen" increased the perception of "moderateness" and "frankness." While, it had little effect on the user's "likability" toward the voice agent, there were significant correlations between "moderateness" or "frankness" and "likability." The present results indicate that, by selecting and using greetings appropriately, the perception of politeness may be altered and possibly affect the perception of attachment.

1. 実験背景

ユーザが情報システムを長く利用する，さらに類似のシステムへの継続利用を求めるには，情報システムに対して愛着を持ってもらう必要がある．今日，情報システムには，少なからずユーザとの音声対話機能が実装化されており，情報システムに対する愛着を高めるには，音声エージェントへの愛着形成が重要な要素のひとつとなる [内藤 19] .

これまでの研究ではユーザの声から状態を判別し，システムがまるでユーザを理解しているように振る舞ったり [小川 13]，エージェントが個人に適応した学習をおこなっているようにみせる [神田 05]など，エージェントがより人間らしい振る舞いをすることで愛着形成が促進される可能性が報告されている．一方，ユーザは会話を通してエージェントとコミュニケーションを図るため，対話の具体的な内容が愛着形成に影響するとの報告がある [Kitamura 18]. [Kitamura 18]では，対話中に名前を呼びかける際に，ユーザ側が音声エージェントを「呼び捨て」，音声エージェント側がユーザーを「さんづけ」で呼ぶという，音声エージェントがユーザをマスター (主人)，自分をサーバント (従者)として認識しているかのように振る舞う (以後，マスターサーバント関係の理解)場合に，エージェントへの愛着が増加することを報告している．これは，エージェントという存在に対するユーザの潜在的な願望や欲求が愛着形成を促す可能性を示唆しており，どのような対話条件でマスターサーバント関係が生起し，強い影響をもたらすのか，さらに検討する必要がある．そこで本研究では，名前の呼び方以外の対話要因によってユーザとエージェントのマスターサーバント関係を実験的に変化させ，愛着形成にどのように影響するか検討をおこなった．

対話場面では，名前を呼ぶ場合以外の方法でも，対話する相手への敬意や丁寧さを示すことが可能である．そのひとつに，会話を始める際の呼びかけ語がある．たとえば，『すみません』は，「すみません、お願いがあるのですが」などのように，丁寧に相手に会話をする場合に頻繁に使用される呼びかけ語である [北原 10][飯尾 17]. また，相手に自責の念がある場合も『すみません』が多く用いられ [山本 03]，対話者への丁寧さに加え，恐縮した気持ちの表現としても使われている．一方で，『おい』は，「おい、すぐに来てくれ」などのように，目下の者に会話をする場合に頻繁に使用される呼びかけ語である [北原 10]. こうした知見を考慮すると，呼びかけ語の丁寧さが，音声エージェントとユーザとのマスターサーバント関係を変化させ，それに伴ってエージェントへの愛着が変容する可能性がある．そこで本研究では，丁寧さの程度の異なる数種類の呼びかけ語を用いて，呼びかけ語が音声エージェントへの愛着形成にどのような影響をもたらすか検討した．

連絡先：佐々木健，早稲田大学基幹理工学研究科表現工学専攻，東京都新宿区大久保 3-4-1，03-5286-3335，ssk_ken@akane.waseda.jp

2. 実験方法

2.1 参加者

実験には，日本語を母国語とする日本人 54 名 (男性 27 名，女性 27 名，平均年齢 20.44 歳 (*SD*=1.83))が参加した．

2.2 呼びかけ語の選定 (予備調査)

どのような呼びかけ語がマスターサーバント関係に影響し，また対話時に違和感がないと感じられるのかを測定するために予備実験 (N=13)を実施した．実験参加者は，本実験で使用予定の文章 (「あと 5 分で終了です」)に呼びかけ語を加えた 6 種類の文章 (e.g.,「すみません，あと5分で終了です．」)を提示され，「丁寧さ」，「会話内での自然さ」，「上下関係を感じるか」について 5 件法で判断をおこなった．呼びかけ語は，『すみません』，『あのー』，『ねぇ』，『ちょっと』，『おい』，『もしもし』の 6 種類であった．その結果，『すみません』は「丁寧さ」と「上下関係を感じるか」の評定値が他の呼びかけ語よりも高いことがわかったため，『すみません』を，マスターサーバント関係を喚起する呼びかけ語として本実験で使用することにした．一方，『あのー』は丁寧さの評定値がやや低く，「会話内での自然さ」の評定値が高かったことから，マスターサーバント関係を喚起しない呼びかけ語として本実験で用いることにした．さらに会話内容を含まない『通知音』を統制条件として設定することにした．

2.3 実験環境

実験参加者の測定体勢は座位とし，目の前に出力用スピーカー (Jabra SPEAK 510, Jabra 社製)，背後に入力用スピーカー (Jabra SPEAK 510, Jabra 社製)を置き，それらを通して会話をおこなった．入力用スピーカーと入力用 PC (Macbook Air, Apple 社製)は有線で接続し，出力用スピーカーと出力用 PC

(Macbook Pro, Apple 社製)は Bluetooth で接続した. 実験者は, 参加者の発話を入力用スピーカーで聞き取り, 手動で会話のタイミングをあわせて出力用スピーカーからエージェントの音声を再生した. 実験者が音声再生しているものの, あくまで会話しているのは出力用スピーカーであるようにするため, 出入力の操作は遠隔でおこなった. 使用した音声は 3 種類でいずれも 20 代～30 代の女性の声であった (AITalk® 声の職人, https://www.ai-j.jp/201605lp).『すみません』,『あのー』,『通知音』の最大音量は, 一般的な会話程度の音量であった (すみません; 60.4～66.2db, あのー; 63.6～70.8db, 通知音; 61.2db). また, 擬似運転の際には, ハンドル (G29 DRIVING FORCE, ロジクール社製)を用い, ディスプレイ (FG2421, EIZO 社製)に出力する運転映像の動画は携帯ゲーム (Real Racing 3)で作成した. 実験風景を図 1 に示す.



図 1 実験風景

2.4 実験の流れ

実験参加者は実験参加同意書に署名をした後, 実験者に案内されディスプレイの前に座り課題の説明を受けた. 参加者は, あらかじめ用意されたシナリオに沿って対話をおこなうように教示され, 実験前に一度シナリオ全体に目を通してから実験に臨んだ. シナリオにはいくつかの自由発話部分があり, 好きな発話をおこなうことができた. 課題は, 運転前の対話, 擬似運転中の対話, 運転後の対話, エージェントへの印象計測で 1 試行とした. 参加者は, 異なる声をもつ 3 種類のエージェント (A,B,C)と対話をおこない, 計 3 試行を実施した. 各試行では, 3 種類の呼びかけ語のどれかが呼びかけ語として用いられた. 呼びかけ語と声の組み合わせは, 参加者間でカウンターバランスを取った. 実際の対話の例を図 2 に示す. なお, 試行間に 5 分ほど休憩を取った.

エージェントへの印象計測は, 先行研究 [Kitamura 18]をもとに作成した質問紙でおこなった. まず, 愛着を測定する尺度として,「好ましさ」,「信頼感」,「打ち解け感」,「関わりの持ちたさ」の 4 項目を用意した (9 段階尺度). 特に,「好ましさ」を直接的な愛着測定の尺度とした. また, マスターサーバント関係の認識に関する質問項目として,「控えめさ」の項目を用意した (9 段階尺度). さらに参加者は, 実験終了後に, 課題中に気づいたことに関する自由記述の質問紙にも回答した.

A: はじめまして、こんにちは。私はドライビングエージェントです。よろしくお願いします。
U: ドライビングエージェントってなに？
A : 私の役割はあなたの運転のパートナーとして、走行の安全性や、カーライフの快適性を高めることです。例えば渋滞や駐車場についての情報を先回りしてお知らせしたり、センサーから眠気や気分を察知して、より安全で快適に過ごせるようなサポートをします。
U: へぇ、そうなんだ。よろしくね。
A : よろしくお願いします。
A : あなたのお名前を聞いてもよろしいですか？
U: XXです。
A : 運転はお好きですか？
U: そうだね、嫌いじゃないんだけど、あまり自信が無くて・・・
A : そうなんですか。ちなみに苦手な状況などはありますか？
U: 右折とか、車庫入れとか、なんか苦手で
A : なるほど。そうなんですね。運転をより一層快適にサポートできるよう頑張ります。
A : さっそくドライブしませんか。
U: いいねぇ、しよう。
A : では出発しましょう。
(運転中)
A : すみません、あと2分で終了です。
U: (自由発話)
A : すみません、あと1分で終了です。
U: (自由発話)
A : すみません、あと30秒で終了です。
U: (自由発話)
(運転後)
A : お疲れ様でした。本日のドライブは楽しんでいただけましたか。
U: 楽しかったです。
A : では終了ですので外に出てください。ありがとうございました。

図 2 対話例
(A は音声エージェント, U は実験参加者を示す)

3. 実験結果

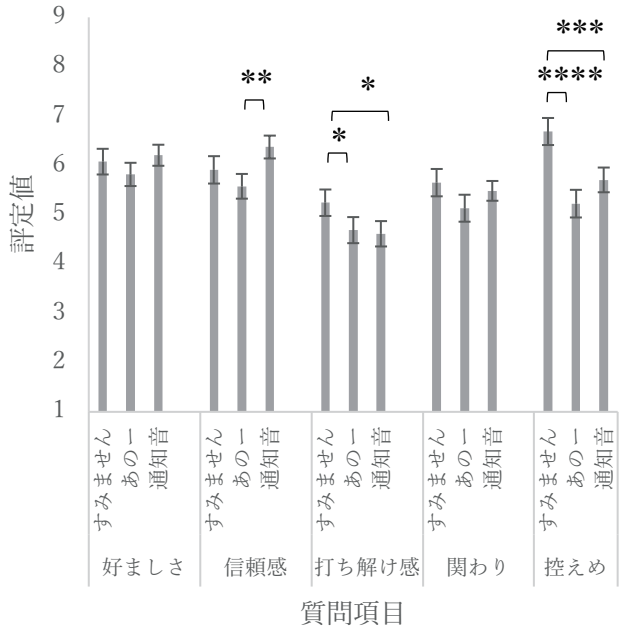
3.1 呼びかけ語の効果

呼びかけ語ごとに, 実験参加者の音声エージェントへの愛着形成に差があるか検討するため, 各呼びかけ語条件での質問項目 5 項目 (「好ましさ」,「信頼感」,「打ち解け感」,「関わりの持ちたさ」,「控えめさ」)の評定値について, 一元配置分散分析をおこなった. 図 3 は呼びかけ語に対する, 各質問項目の評定値の平均値を示したものである.

分析の結果,「好ましさ」では, 呼びかけ語の有意な主効果は得られなかった ($F(2,106)=0.90$, $p=.41$, $\eta^2=.01$). 一方,「信頼感」では, 呼びかけ語の主効果が有意であり ($F(2,106)=3.81$, $p<.05$, $\eta^2=.03$), Ryan 法による多重比較の結果,『通知音』が『あのー』に比べて有意に高い信頼感を得ることがわかった ($p<.01$).「打ち解け感」でも, 呼びかけ語の主効果が有意であり ($F(2,106)=3.60$, $p<.05$, $\eta^2=.02$),『すみません』が『あのー』や『通知音』に比べて有意に高い打ち解け感を得た (あのー; $p<.05$, 通知音; $p<.05$). また,「関わりの持ちたさ」では呼びかけ語の効果は得られなかった ($F(2,106)=1.38$, $p=.26$, $\eta^2=.01$). 以上から, 愛着を直接的に示す質問項目「好ましさ」では, 呼びかけ語の効果は確認できなかったが,「信頼感」「打ち解け感」では呼びかけ語の違いが評定値に影響を与えることがわかった.

また, マスターサーバント関係の認識に関する「控えめさ」の評定では, 呼びかけ語の主効果が有意であった ($F(2,106)=9.80$, $p<.001$, $\eta^2=.09$). 多重比較の結果,『すみません』が『あのー』『通知音』に比べて有意に高い控えめさを示す結果となった (あのー; $p<.001$, 通知音; $p<.01$). これは, 音声エージェントがユー

ザとのマスターサーバント関係を理解しているように振舞っていることを，参加者が認識していた可能性を示唆する結果である．



*: p<.05, **:p<.01,

***:p<.005, ****:p<.001

図 3 呼びかけ語に対する各質問項目
(エラーバーは標準誤差を示す)

3.2 質問項目間の相関

3.1 の呼びかけ語の効果の解析では，『すみません』が「打ち解け感」と「控えめさ」の両者の印象を高めることがわかった．そこで，「控えめさ」と「打ち解け感」が相互に関連しているかを調べるため，さらに各評定項目がそれぞれ互いにどのような関連を持つか明らかにするため，全評定項目の評定値について，相関分析をおこなった．

表 1 は質問項目間の相関係数を示したものである．分析の結果，「打ち解け感」と「控えめさ」の間では，有意な相関は得られなかった．つまり，「打ち解け感」と「控えめさ」は，互いに独立して呼びかけ語の影響を受けていると考えられる．また，3.1 で呼びかけ語の効果が認められた「信頼感」「打ち解け感」「控えめさ」は，それぞれ「好ましさ」との有意な相関が得られた．これは，呼びかけ語が「好ましさ」に直接影響しなくても，「信頼感」や「打ち解け感」，「控えめさ」を通じて「好ましさ」を変化させる可能性を示唆する結果である．

表 1 質問項目間の相互相関表

	1	2	3	4	5
1. 好ましさ	–				
2. 信頼感	.73****	–			
3. 打ち解け感	.52****	.53****	–		
4. 関わりの持ちたさ	.69****	.58****	.61****	–	
5. 控えめさ	.31****	.20**	.12	.25***	–

N=162

*: p<.05, **:p<.01,

***:p<.005, ****:p<.001

3.3 音声エージェントの声の効果

3.1 で示されたように，呼びかけ語による音声エージェントの印象変化は，部分的にしか確認されなかった．そこで，「呼びかけ語」以外の要因が影響している可能性を調べるため，次に，実験で用いた音声エージェントの種類の効果を検討した．質問項目ごとに音声エージェントの声の種類を要因とし，一元配置分散分析をおこなった．

その結果，「好ましさ」，「信頼感」，「打ち解け感」，「関わりの持ちたさ」については，声の主効果が有意であり (好ましさ; F(2,106)=13.2, p<.001, η^2=.10, 信頼感; F(2,106)=9.39, p<.001, η^2=.07, 打ち解け感; F(2,106)=8.51, p<.001, η^2=.05, 関わりの持ちたさ; F(2,106)=8.89, p<.001, η^2=.08), 多重比較の結果，エージェント B がエージェント A, C に比べて「好ましさ」，「信頼感」，「打ち解け感」，「関わりの持ちたさ」が有意に高かった (好ましさ; ps<.001,信頼感; ps<.01,打ち解け感; ps<.01, 関わりの持ちたさ; ps<.01). 一方，「控えめさ」の項目については，声の主効果は得られず (F(2,106)=0.11, p=.90, η^2=.001)，声の種類は控えめさの評価に影響を与えないことがわかった．

3.4 自由記述のアンケートの結果

自由記述の回答で最も多かったのは，約 3 分の擬似運転中に 3 度も『すみません』と呼びかけられたため鬱陶しいとの報告で，54 名中 8 名の回答があった．また，声がけに気付きやすい呼びかけ語として，機械音が多く挙げられており (54 名中 6 名)，3.1 で示した『通知音』に対する高い信頼感の評定結果と一致する回答が得られた．

また，本実験では，実験者が参加者の発話を聞き取り，タイミングを合わせて出力用スピーカーへ音声再生をしていたため，参加者が対話速度に違和感を感じている懸念があった．しかし，本実験で気づいたことに関する自由記述のアンケートに，対話の違和感を感じたとの記述はみられなかったことから，会話操作に問題はなかったと考えられる．

4. 考察

本研究は，呼びかけ語の丁寧さが音声エージェントへの愛着形成に影響を与えるかを検討した．実験の結果，「信頼感」や「打ち解け感」は呼びかけ語の影響を受けるのに対し，愛着を直接反映すると思われる「好ましさ」は，呼びかけ語の種類よりも音声エージェントの声質の影響を強く受けることがわかった．しかし一方で，全評定項目間の相関分析では，「好ましさ」と呼びかけ語の効果が認められた質問項目 (「信頼感」や「打ち解け感」，「控えめさ」)との間に有意な相関がみられたことから，呼びかけ語は「好ましさ」そのものを変化させるには至らないものの，「信頼感」や「打ち解け感」，「控えめさ」を通じて「好ましさ」を変化させる可能性があると考えられる．

実験参加者の自由記述の回答では，約 3 分の擬似運転中に 3 度も『すみません』と呼びかけられたため鬱陶しいとの報告が複数みられた．つまり，呼びかけ回数の多さが呼びかけ語の種類よりも好ましさの評定に影響した可能性がある．今後は，呼びかける回数やタイミング，実験時間を考慮し，呼びかけ語の種類以外の要因を排除して検討する必要がある．

愛着を直接的に示す質問項目「好ましさ」では大きな差が得られなかったものの，他の評価項目;「信頼感」と「打ち解け感」では，音声エージェントの声だけでなく，呼びかけ語が影響を及ぼすことが示された．「信頼感」の評価では，『通知音』への評定値が高かった．自由記述の結果でも，機械音は通知に気付きやすかったとの回答が複数みられた．これは，人の声よりも機械的な音の方が信頼されたことを意味するもので，状況によっ

ては人間的に振る舞うよりも，機械的特性を生かしたアナウンスの方がより効果的に信頼感が形成される可能性を示唆する．一方で，「打ち解け感」の評価では『すみません』の評価が高かった．『すみません』は丁寧さを示す語であるため [北原 10][飯尾 17]，一見「打ち解け感」とは離れているようにみえるが，初対面である状況から，丁寧な呼びかけ語で話しかけられたことで逆に相手との距離を縮める結果になった可能性がある．しかしあくまで推測の域を出ないので，どういった要因が「打ち解け感」の増加へ繋がったのか，今後さらに検討する必要がある．

マスターサーバント関係の認識の指標である「控えめさ」では，『すみません』の評定値が最も高かった．これは，参加者が，『すみません』がもたらすユーザとのマスターサーバント関係を理解していた可能性を示唆する．マスターサーバント関係と愛着形成の関連を示した先行研究 [Kitamura 18]では，愛着計測の指標として，更に会話を続けたい音声エージェントを選ぶという，行動指標を用いていた．一方，本研究では顕在的な主観評定のみを指標としたため，得られた差が間接的であった可能性がある．今後 [Kitamura 18]などで用いられている行動指標も含め，さらに検討する必要がある．

5. まとめ

本研究では，ユーザの音声エージェントに対する愛着に，会話中の呼びかけ語の丁寧さが影響するかを実験的に検討した．その結果，呼びかけ語の丁寧さを操作することでマスターサーバント関係の理解を変化させることが可能になり，また間接的ではあるものの呼びかけ語が愛着形成に影響する可能性が示唆された．しかしながら，呼びかけ語の丁寧さと愛着形成の密接な関わりを示すには十分な結果ではなかった．今後は，呼びかけ語の回数や，愛着の測定指標を工夫し，さらに詳細に検討する予定である．

参考文献

[内藤 19] 内藤泰嗣, 有賀義之, 倉田啓一: 車載音声対話エージェントの愛着醸成にむけたインタラクティブシステムの研究 (第 1.0 版), *研究報告ヒューマンコンピュータインタラクション (HCI)*, 2019-HCI-181(12) 1-6, 2019.

[小川 13] 小川義人, 原田花歩, 菊池英明: エージェントによるユーザ特性の把握が愛着感に与える影響, *電子情報通信学会技術研究報告*: *SP*, 112(450) 35-40, 2013.

[神田 05] 神田崇行, 佐藤留美, 才脇直樹, 石黒浩: 対話型ロボットによる小学校での長期相互作用の試み, *ヒューマンインターフェース学会論文誌*, 7(1) 27-37, 2005.

[Kitamura 18] Kitamura, M., Kurata, K., Oya, K., & Watanabe, K.: Development of Human-agent Attachment by Form of Address, *In Proceedings of the 6th International Conference on Human-Agent Interaction*, 101-105, 2018.

[北原 10] 北原保雄:明鏡国語辞典 第二版, 大修館書店, 2010.

[飯尾 17] 飯尾牧子: 感謝を表す表現「ありがとう」と「すみません」-大学生におけるコミュニケーション様式の一考察-, *東洋学園大学紀要*, 26(1) 55-68, 2017.

[山本 03] 山本もと子: 感謝の謝罪表現「すみません」-「すみません」が感謝と謝罪の両方の意味を持つわけ-, *信州大学留学生センター紀要*, (4) 1-13 , 2003.

[Li 15] Li, Z: 独立語文と共起する呼びかけ語について, *岡山大学大学院社会文化科学研究科紀要*, (39) 91-103, 2015.

[小川 93] 小川治子: 「すみません」の社会言語学的考察, *言語文化と日本語教育*, (6) 36-46, 1993.

General Session | General Session | [GS] J-13 AI application

[2O1-J-13] AI application: dynamics in finance

Chair:Setsuya Kurahashi Reviewer:Hiroto Yoneno

Wed. Jun 5, 2019 9:00 AM - 10:40 AM Room O (Front-left room of 1F Exhibition hall)

[2O1-J-13-01] Extraction of Important Sentences in Financial Documents Based on Business Confidence Information Using LSTM with Self-Attention Mechanism

○Shuhei Yamaoka[1], Seiichi Ozawa[1], Takehide Hirose[2], Masaaki Iizuka[2] （1. Kobe University, 2. Sumitomo Mitsui DS Asset Management Company, Limited）

9:00 AM - 9:20 AM

[2O1-J-13-02] Relationship between Liquidity and Costs of Arbitrage Trading for Stocks and ETF --- Investigation by Agent-Based Model ---

○Takanobu Mizuta[1] （1. SPARX Asset Management Co., Ltd.）

9:20 AM - 9:40 AM

[2O1-J-13-03] Analysis of Inter-bank Network's Temporal Change Using Clustering Structure Change Detection

○Yuta Niki[1], Kiyoshi Izumi[1], Hiroyasu Matsushima[1], Hiroki Sakaji[1], Takashi Shimada[1] （1. School of Engineering, The University of Tokyo）

9:40 AM - 10:00 AM

[2O1-J-13-04] Analysis of Limit Orders by High-Frequency Traders in Tokyo Stock Exchange

○Masanori HIRANO[1], Kiyoshi IZUMI[1], Hiroyasu MATSUSHIMA[1], Hiroki SAKAJI[1], Takashi SHIMADA[1] （1. School of Engineering, The University of Tokyo）

10:00 AM - 10:20 AM

[2O1-J-13-05] Extraction of Future-oriented Sentences from Annual Securities Reports

○Shunya Kodera[1], Yoshinori Tanaka[1], Fumihito Sato[1], Hiroaki Sakuma[1], Hiroki Sakaji[2], Kiyoshi Izumi[2] （1. NIKKO RESEARCH CENTER, INC., 2. Graduate School of Engineering, The University of Tokyo）

10:20 AM - 10:40 AM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

自己注意機構付きLSTMを用いた景況感情報に基づく金融文書の重要文抽出

Extraction of Important Sentences in Financial Documents Based on Business Confidence Information Using LSTM with Self-Attention Mechanism

山岡 周平 *1 Shuhei Yamaoka　小澤 誠一 *1*2 Seiichi Ozawa　廣瀬 勇秀 *3 Takehide Hirose　飯塚 正昭 *3 Masaaki Iizuka

*1神戸大学 大学院工学研究科 電気電子工学専攻
Department of Electrical and Electronic Engineering, Graduate School of Engineering, Kobe University

*2神戸大学 数理・データサイエンスセンター
Center for Mathematical and Data Sciences, Kobe University

*3三井住友ＤＳアセットマネジメント株式会社
Sumitomo Mitsui DS Asset Management Company, Limited

Investment trust and fund management companies have accumulated a large number of visit records that were summarized by their analysts after conducting hearings against companies. Such visit reports include crucial information of companies such as companies' financial conditions and future strategies, which are used to estimate investment values of individual companies. However, it is not easy even for skilled fund managers to derive suitable market outlooks and investment decisions from a huge amount of accumulated documents. In this research, to support investment decisions, we propose a new LSTM model with self-attention mechanism that can extract important sentences in analyst visit reports. Such extraction is conducted based on the sentence scoring, which is obtained as the weights in a self-attention mechanism. In our experiments for a set of 1,390 visit reports, we demonstrate that the proposed model has about 79% accuracy for extraction on average under the 5-fold cross-validation.

1. はじめに

ICT の普及とともに，あらゆる文書が電子化され，一組織が保有する文書資産は膨大な量となっている．組織にとって重要かつ貴重な情報が含まれているにもかかわらず，作成された文書情報が有効活用されずに眠ったままになっていることも多く，有効活用したくても，その量や情報の種類が膨大であり，データベースを駆使しても有益な情報を得ることが容易でない状況である．

投資家の資金を預かり，その資産運用を代行する運用会社も，その例外ではない．各企業にアナリストがヒアリングし，調査・分析を行った結果を記した往訪記録が運用会社には大量に蓄積されている．これらには企業の財務状況や将来計画など，個々の企業の投資価値を判断するための重要情報が詰まっており，それらの情報を総合的に分析して，ファンドマネージャーは資金の運用方法を決める．よって，アナリストが分析し，予測した景況感は運用会社の貴重な資産であるが，大量に蓄積された，これら往訪記録から適切な景況分析と投資判断を導き出すことは，熟練のファンドマネージャーであっても容易なことではない．

そこで本研究では，ファンドマネージャーやアナリストの調査分析にかかる労力を軽減し，適切な意思決定を容易にすることを目的として，往訪記録から重要文章を抽出するシステムを開発する．3 節では開発するシステムについて述べるが，このシステムでは，まずリカレントニューラルネットの一種である Bidirectional Long Short-Term Memory (BiLSTM) を用いて文章単位の埋め込みベクトルが求められる．そして，その埋め込みベクトルに対して自己注意機構による重みづけを行った結果が往訪記録に付与された景況感情報と一致するよう学習し，その自己注意の重みに基づいて，重要文章が抽出される．4 節では，三井住友 DS アセットマネジメント株式会社（旧，大和住銀投信投資顧問株式会社）から提供されたアナリスト往訪記録を用いて，トピックモデルを教師ありに拡張した Supervised Latent Dirichlet Allocation (SLDA) と提案手法との性能比較を行い，提案手法で抽出した重要文章の精度について抽出事例を示して考察する．

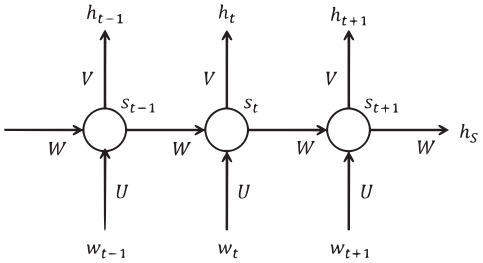


図 1: リカレントニューラルネットの基本構造

2. 関連研究

2.1 リカレントニューラルネット

リカレントニューラルネット (以下，RNN) は音声や言語，動画像等の時系列データを扱うために考案されたニューラルネットである．図 1 に RNN の基本構造を示す．時刻 t における単語の埋め込みベクトル $\boldsymbol{w}_t$ が与えられたとき，セル $\boldsymbol{s}_t$ に対する出力は，前時刻のセルの値 $\boldsymbol{s}_{t-1}$ を用いて以下のようになる．

$$\boldsymbol{s}_t = f(\boldsymbol{U}\boldsymbol{w}_t + \boldsymbol{W}\boldsymbol{s}_{t-1}) \tag{1}$$

ここで，$\boldsymbol{U}$ は入力層と隠れ層間の重み行列，$\boldsymbol{W}$ は前時刻セルと現時刻セル間の重み行列を表し，f は活性化関数を表してい

る．通常のニューラルネットワークと異なるのは $\boldsymbol{W}\boldsymbol{s}_{t-1}$ の項であり，前時刻のセルの値を考慮するこの値によって，RNN は各時刻間の入力変化の仕方を学習することが可能となっている．また，RNN には出力の獲得の仕方が 2 種類存在する．1 つは各時刻における入力の埋め込みベクトルを得る場合である．この場合，時刻 t におけるセル $\boldsymbol{s}_t$ からの出力 $\boldsymbol{h}_t$ は，隠れ層-出力層間の重みを $\boldsymbol{V}$，活性化関数を g として以下の式のようになる．

$$\boldsymbol{h}_t = g(\boldsymbol{V}\boldsymbol{s}_t) \tag{2}$$

この $\boldsymbol{h}_t$ は前時刻のセルの値 $\boldsymbol{s}_{t-1}$ を含んだ値であるため，入力 $\boldsymbol{w}_t$ に時系列情報を加えたものと解釈できる．もう 1 つは最終セルからの出力 $\boldsymbol{h}_S$ のみを用いる場合である．この場合，最終セル $\boldsymbol{s}_{last}$ からの出力 $\boldsymbol{h}_S$ は，以下の式のようになる．また，S は最終時刻を $last$ として $S = last + 1$ となる値である．

$$\boldsymbol{h}_S = \boldsymbol{W}\boldsymbol{s}_{last} \tag{3}$$

他の出力を用いず，$\boldsymbol{h}_S$ のみを用いて学習を行う場合，$\boldsymbol{h}_S$ は高次元空間上の各入力が，どのような順番で出現したかの情報を保持して出力された値である．例えば $\boldsymbol{w}$ を単語の埋め込みベクトルとすると $\boldsymbol{h}_S$ には，その文章の流れが情報として入ることとなる．

2.2 Long Short-Term Memory

Long Short-Term Memory (以下 LSTM) [Hochreiter 97] は 1997 年 Hochreiter と Schmidhuber らによって提案されたリカレントニューラルネットの一種である．一般的な RNN モデルで時系列データの長期的な時間構造を獲得するには，フィードバック結合を介した再帰的信号伝播を繰り返す必要がある．誤差逆伝播法を RNN に拡張した学習アルゴリズムでは，この再帰的信号伝播の過程で誤差情報が消失していく，いわゆる勾配消失が問題となる．LSTM はこの問題を解決するためモデルに長期記憶と短期記憶に関する項を加えている．これにより従来のモデルでは不可能であった長期依存を学習可能にしている．詳細については [岡谷 15] を参照されたい．

また，時系列データが一括して与えられる場合は，$t = 1, 2, \cdots, T$ と時間方向に対して順方向に与えるだけでなく，$t = T, T-1, \cdots, 1$ と逆方向に与えることで，時系列を未来から過去に向かって帰納的に整合を取りながら特徴量化する構造を陽に組み込むことができる．このような順方向の LSTM と逆方向の LSTM の両方を統合したものを Bidirectional LSTM (以下 BiLSTM) といい，順方向の出力 $\overrightarrow{h_t}$ だけでなく逆方向の出力 $\overleftarrow{h_t}$ も特徴量として使えるようになるため通常の LSTM よりも精度がよいとされる．

2.3 自己注意機構

まず，自己注意機構を導入した表現学習モデルである，Lin らの文埋め込み表現獲得法 [Lin 17] を説明する．本論文で提案する文書極性判定手法は，次の 2 つのパートからなる．まずはじめに，単語ごの埋め込みベクトル $\boldsymbol{w}$ を BiLSTM への入力とし，単語ごとに時系列を考慮した埋め込みベクトルを得る．次に，単語ごとに出力された埋め込みベクトルから自己注意の値を求め，それをもとに作成した文書ベクトルが SVM などのクラス分類手法で分類できるよう学習させる．図 2 にモデルを示し，以降で詳細を説明する．

Word2Vec [Mikolov 13] などを用いて得た単語ごの埋め込みベクトル $\boldsymbol{w}_t$ $(t = 1, 2, \cdots, n)$ を文章ごとにまとめたものを $\boldsymbol{S}$ とする．この $\boldsymbol{S}$ の次元は，Word2Vec で出力される単語の次元数を v として $v \times n$ で表される．

$$\boldsymbol{S} = (\boldsymbol{w}_1, \boldsymbol{w}_2, \cdots, \boldsymbol{w}_n) \tag{4}$$

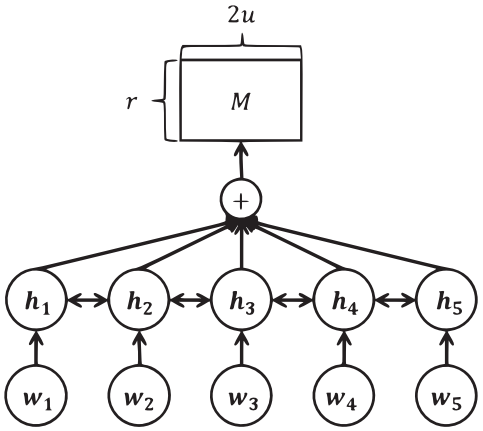


図 2: 単語の埋め込みベクトルに対する自己注意を用いた文書ベクトル生成モデル例

ここで，n はその文章に含まれる単語の数を表す．$\boldsymbol{S}$ を入力として BiLSTM から出力される t 番目の単語の埋め込みベクトルは，順方向出力を $\overrightarrow{h_t}$，逆方向出力を $\overleftarrow{h_t}$ として以下のように書ける．

$$\overrightarrow{h_t} = \overrightarrow{LSTM}(\boldsymbol{w_t}, \overrightarrow{h_{t-1}}) \tag{5}$$

$$\overleftarrow{h_t} = \overleftarrow{LSTM}(\boldsymbol{w_t}, \overleftarrow{h_{t-1}}) \tag{6}$$

各方向の LSTM によって得た埋め込みベクトルの次元数を u とする．2 つを合わせて次元数 $2u$ のベクトル $\boldsymbol{h}_s$ とし，これらをまとめてベクトル集合 $\boldsymbol{H}$ とする．この $\boldsymbol{H}$ の次元は各方向の LSTM からの出力の次元数を u とすると $n \times 2u$ で表せる．

$$\boldsymbol{H} = (\boldsymbol{h}_1, \boldsymbol{h}_2, \cdots, \boldsymbol{h}_n) \tag{7}$$

この出力ベクトル $\boldsymbol{H}$ に対して，どの単語埋め込み表現が景況感に対するラベル予想に貢献するかを即時的に求めるため，自己注意機構を導入する．各単語の出力ベクトル H に対する自己注意機構による重み行列 A は，以下で与えられる．

$$\boldsymbol{A} = softmax(\boldsymbol{W}_2 \tanh(\boldsymbol{W}_1 \cdot \boldsymbol{H}^{\mathrm{T}})) \tag{8}$$

$\boldsymbol{W}_1$ の次元数は，d を中間層の次元を表す定数として $d \times 2u$ として表せ，さらに選択的注意を与える出力数を r とおくと，$\boldsymbol{W}_2$ の次元数は $r \times d$ で表される．この自己注意の重み係数は多層パーセプトロンの結合荷重と似ており，これによりベクトル $\boldsymbol{h}$ に重みの乗算を 1 度行っただけでは表現しきれない NOR の論理演算を，再度重みを掛け合わせることによって達成できる．また，$\boldsymbol{W}_1$ を乗算した後に tanh を乗算することによって，分離境界面から大きく離れた影響を無視し，最後に $softmax$ 関数を通すことによって，各入力に対する重要度を確率で表すことが可能となる．また，注意を与える出力数 r が 1 の場合，クラスを分類するのに最適な単語一つを選び，その単語の重みのみを上げれば分類精度を上げることができる．そのため注意の大半が 1 つの単語に偏ってしまうことがある．例えば，ポジティブな文章かどうかを判定したければ，「ポジティブ」という単語の自己注意の値を 1 にすれば，それで達成される．単語は，まず Word2Vec 等で埋め込みベクトル化されているため，影響はいくらか緩和されるが，それでも注意機構を導入することで判定結果が偏ることがある．これを避けるため，あるいは複数の注意を獲得する必要がある場合は，この値

を必要な注意の数だけ用意することで対応できる．これらの操作によって得た BiLSTM からの出力ベクトル集合 $\boldsymbol{H}$，およびその注意機構の重み行列 $\boldsymbol{A}$ を用いて，文書の埋み込み行列 $\boldsymbol{M}$ は自己注意を重みとして各ベクトルを足し合わせたものとする．

$$\boldsymbol{M} = \boldsymbol{A} \cdot \boldsymbol{H} \tag{9}$$

この $\boldsymbol{M}$ の次元数は $r \times 2u$ で表せる．またこの手法によって得られた自己注意の値は「その単語がどれほどラベルに影響を与えたか」を表し，言い換えればこの手法によって「ラベルを推定する上で重要だと判断された単語」が推定できる．

3. 自己注意機構付き LSTM による重要文抽出

3.1 アナリスト往訪記録

本研究では，アナリスト往訪記録から重要文章を抽出することを目的としている．往訪記録は，各アナリストが企業へ取材に赴き，その調査結果について「日付」「会議種別」「証券コード」「会社名」「担当者」「コメント」などをまとめたものであり，どこに投資するかを決定する際には，特に「コメント」が重要となる.「コメント」には，規則としてはじめに「担当アナリストは投資に対して前向きかどうか」を「ポジティブ」,「ややポジティブ」,「ニュートラル」,「ややネガティブ」,「ネガティブ」の 5 段階評価で書き記すことになっている．そして，その後の項目では，各企業の投資価値を判断するため，ポジティブとネガティブな側面を述べ，景況予想や期待感なども交えつつ分析結果を記述する．このコメントを構成する単語数は短いときで 4，5 単語の結論のみであり，長いときで 110 単語前後である．これは論文やニュース記事などと比べれば非常に短いがツイートなどに比べれば長い．また，今回の研究の目標として重要文章抽出を挙げているが,「ニュートラル」の評価が与えられた文章はアナリストらもどこが重要なのかを明確にさせていないため，訓練データには入れないことにした．

3.2 提案モデル

ここでは既存手法を改良して金融文書から重要な文章の抽出を行うモデルを提案する．図 3.2 にその概形を示す．まず，n 個の単語からなる文章について，既存手法と同じく wrod2vec を用いて各単語の埋め込みベクトル集合 $\boldsymbol{W}_s = (\boldsymbol{w}_1, \boldsymbol{w}_2, \cdots, \boldsymbol{w}_{n_s})$ を得る．なお，$\boldsymbol{W}_s$ 及び n_s の添え字 s は，ある文書における文章数を S として $s = 1, 2, \cdots, S$ である．このベクトルを BiLSTM の入力とし，文章ごとの埋め込みベクトル $\overrightarrow{h_s}$ と $\overleftarrow{h_s}$ を得る．この $\overrightarrow{h_s}$ と $\overleftarrow{h_s}$ は各方向の LSTM に W_s を入力した際の出力であるが，ここで注意して欲しいのは単語ごとのベクトルを出力しているのではなく，文章ごとにベクトルを出力している点である．つまり，各文章における LSTM の最終出力を用いる．

$$\overrightarrow{h_s} = \overrightarrow{LSTM}(W_s) \tag{10}$$

$$\overleftarrow{h_s} = \overleftarrow{LSTM}(W_s) \tag{11}$$

各方向の LSTM によって得た埋め込みベクトルの次元数を u とする．2 つを合わせて次元数 $2u$ のベクトル $\boldsymbol{h}_s$ とし，これらをまとめてベクトル集合 H とする．また，H の次元は $N_S \times 2u$ であり，N_S は文書に含まれる文章の数をあらわす．

$$H = (\boldsymbol{h}_1, \boldsymbol{h}_2, \cdots, \boldsymbol{h}_{N_S}) \tag{12}$$

ベクトル $\boldsymbol{H}$ を入力として文書の注意ベクトル $\boldsymbol{A}$ を得る．また本研究ではコメント内に重要文章は 1 つのみあると仮定し注意の数 r は 1 としているため，その次元数は N_S である．

$$\boldsymbol{A} = softmax(\boldsymbol{W}_2 \tanh(\boldsymbol{W}_1 \cdot \boldsymbol{H}^{\mathrm{T}})) \tag{13}$$

この式が既存手法と異なる点は入力の次元数であり，既存手法は「文書内の単語数 $n_s\times$ BiLSTM の出力 $2u$」だったが提案手法では「文書内の文章量 $N_S\times$ BiLSTM の出力 $2u$」である．そのため自己注意の次元数も変化し，既存手法の自己注意 A の次元数は「注意数 $r\times$ 文書内の単語数 n_s」だったが提案手法では「注意数 $1\times$ 文書内の文章数 N_S」となっている．これにより既存手法と同様以下の文書ベクトル M を得る．

$$\boldsymbol{M} = \boldsymbol{A} \cdot \boldsymbol{H} \tag{14}$$

$\boldsymbol{A}$ は次元数 N_S の行ベクトル，$\boldsymbol{H}$ は次元数 $N_S \times 2u$ の行列であるため，$\boldsymbol{M}$ は次元数 $2u$ のベクトルとなる．最後に文書ベクトルに重み $\boldsymbol{W}_3$ を掛けて総和をとり，softmax 関数に通したものを，各ラベルに割り当てられる確率 l とする．本研究ではポジティブとネガティブの 2 クラスを想定しているため，出力層のセル数は 2 としている．

$$\boldsymbol{l} = softmax(\boldsymbol{W}_3 \cdot \boldsymbol{M}) \tag{15}$$

4. 重要文抽出の性能評価

4.1 実験設定

性能評価には，実際のアナリスト往訪記録 1,390 文書を用いた．これを提案手法で使用可能なデータとするため，以下の変換操作を行った．

1. 各コメントについて先頭 12 文字をみてポジティブ，あるいはそれに類する単語が記されていれば 1 を，ネガティブ，あるいはそれに類する単語が記されていれば 0 をコメントの正解ラベルとして付与し，そのラベルに相当する単語は訓練データから除く．
2. 形態素解析には MeCab を用い，助動詞，助詞，副詞，記号以外の単語を抽出する．
3. 形態素解析で得られた単語系列と正解ラベルを合わせて，一つの文書データとする．

学習に使う損失関数には，正解ラベルと推定結果で定義される，次式のクロスエントロピー L を導入した．

$$L = -\frac{1}{D} \sum_{d} \log l_d \tag{16}$$

ここで，$d \in D$ は文書番号，l_d は出力の正解ラベル成分である．式 (16) の L を最小化するよう誤差逆伝播法で重みを学習する．

訓練データに用いたアナリスト往訪記録 1,390 件のうち 284 件については，アナリストやファンドマネージャーによる重要文判定が行われており，この判定結果との一致度合を評価指標として採用した．また，もう 1 つの評価指標としてラベルの推定精度を採用した．1,390 文書に対して，訓練データとテストデータが 4:1 となるように分割し，5 重交差検定を行った景況感予測のテスト精度の平均と分散で評価する．なお，性能比較のモデルとして，トピックモデルを教師ありの学習へと拡張した SLDA[Mcauliffe 08] を選んだ．SLDA では，トピック分布と単語分布を学習させた後に文章ごとのラベル推定値を求め，その中で最も推定値が正解ラベルに近かった文章を最重要文とした．

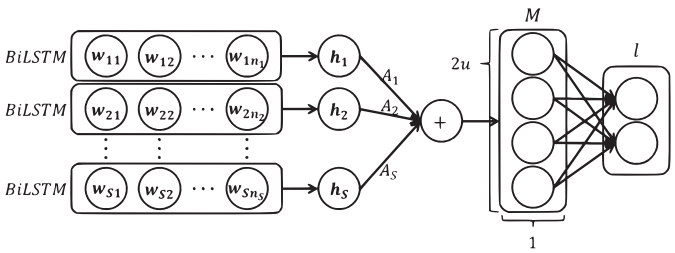


図 3: 文章ごとの埋め込みベクトルに対して自己注意機構を適用した重要文章抽出モデル．本研究では，文章ごとの自己注意 $A_i(i = 1, 2, \cdots, S)$ として獲得される．

表 1: 最重要文一致数と景況感予測精度の比較

	最重要文一致数	景況感予測精度
提案モデル	100/284	0.79 ± 0.3
SLDA	84/284	0.73 ± 0.4

4.2 評価結果と考察

アナリスト往訪記録のうち 284 件については，アナリストやファンドマネージャーによる最重要文の判定がなされており，これに基づいて最重要文の一致数を求めた．結果を表 1 に示す．

表 1 より，提案モデルが SLDA よりも優れた景況感予測が行えており，重要文一致数から，より正確に最重要文を抽出できていることがわかる．コメント文に対するスコアリング結果の例を右に示す．各文章の最初に付している数値は，自己注意機構の重み係数であり，これが高いほど重要と判定されたことを意味する．なお，下線はアナリストが重要だと判定した文章である．

この結果より，自己注意機構の重み係数が大きい文は，ポジティブな往訪記録における前向きなコメントと一致しており，ネガティブな往訪記録に対しては，ネガティブ要因を説明する文章と一致していることがわかる．しかしながら，アナリストが最重要と判定したポジティブとネガティブなコメントとは一致しておらず，この二例に対しては，専門家が要求する重要度を十分に表現できてないと言える．表 1 からわかるように，現時点における重要文一致率は約 35%であり，まだ改善の余地がある．

5. おわりに

本研究では， BiLSTM で得られた文章組み込みベクトルに対して自己注意機構を導入し，アナリスト往訪記録における重要文章の抽出を試みた．アナリスト往訪記録 1,390 文書を用いて性能評価を行った結果，5 重交差検定による提案手法のテスト性能は約 79% となり，専門家による重要文章判定の一致度合についても，SLDA に比べて約 1.2 倍高い性能を得た．

抽出された重要文章は，著者が判定した景況感におおよそ合致していたが，専門家の考える重要文章とは異なるものも少なくなかった．これは，提案手法で獲得された文章単位の組み込みベクトルと景況感ラベル情報の相関関係では，アナリスト視点の重要度を十分に反映できないことを示しており，今後，アナリスト視点の重要度を組み込んだ機械学習モデルの開発が必須と考えられる，

ややポジティブ。
(0.006)A 商品はシェアアップが明確。
(0.96)B 商品の利益も予想以上。
(0.004) ヘッドは軟調だが、C 社で 17 年以降巻き返し、D 社買収効果も見込めそう。
(0.02) 残る問題事業はマグネットのみとなった。
(0.003)16 年度は MLCC で F 商品巻き返しも。

ややネガ。
(0.13)A 国での B 社、C 社向けの部品売上高が想定を下回り、D 地域の収益が期待値を下回っている。
(0.64) オートマティック車向け部品は B 社からの設計変更が来ており、収益化が遅れそう。
(0.009) 当初は 18/3 期に収益化が見込まれていたが、今回のミーティングでは 19/3 期までずれ込みそうなコメント。
(0.003) ただし、全社 OP に占める D 地域比率は 1 割未満であり、むしろ 8 割を占める E 地域の収益改善の方が重要である。
(0.006) その E 地域に関しては、F 国は堅調も 2 輪市場の成長は鈍化傾向にある。
(0.20) 一方、G 国 2 輪向けの事業拡大への期待値は高い。

参考文献

[Hochreiter 97] Hochreiter, Sepp, and Jrgen Schmidhuber.:Long short-term memory, Neural computation 9.8 (1997)

[Lin 17] Lin, Zhouhan, et al.:A structured self-attentive sentence embedding. arXiv preprint arXiv.(2017)

[Mcauliffe 08] Mcauliffe, Jon D.; Blei, David M.:Supervised topic models. In: Advances in neural information processing systems.(2008)

[Mikolov 13] Mikolov, Tomas, et al.:Efficient estimation of word representations in vector space. arXiv preprint arXiv.(2013)

[岡谷 15] 岡谷貴之:機械学習プロフェッショナルシリーズ・深層学習.(2015)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

株式とETFの裁定取引にかかるコストと流動性の関係 —人工市場によるシミュレーション分析—

Relationship between Liquidity and Costs of Arbitrage Trading for Stocks and ETF — Investigation by Agent-Based Model —

水田孝信 *1
Takanobu Mizuta

*1 スパークス・アセット・マネジメント株式会社
SPARX Asset Management Co., Ltd.

We built the artificial market model (agent-based model) that includes two stocks and one ETF (Exchange Traded Fund) and one arbitrage-agent. We investigated relationship between liquidity and arbitrage costs by the model. Our simulation results showed that when costs are smaller than volatility chances of arbitrage happen more times, number of trades by the arbitrage agent increases and the price difference between ETF and stocks becomes narrower.

1. はじめに

ETF(Exchange Traded Funds, 上場投資信託) は多くの株式や債券などに分散投資された投資信託（ファンド）であるとともに，証券取引所で取引できる．そのため近年，手軽な分散投資を提供する商品として，投資家に広く普及した．一方で，一部の ETF は注文量や取引量が少なく取引したいときに適切な価格で取引しづらい（流動性が低い）状況になっていた．ETF は組み入れている株式をすべて集めたものと交換ができる．そのため， ETF と組み入れ株式に価格差があるときに，安いほうを買い，交換を行い *1，高いほうを売って価格差を利益とすることができる．このような取引を裁定取引とよぶが，これを行う参加者が増えることが，ETF が適切な価格で取引され流動性が向上するのに重要であると言われている *2．

例えば，東京証券取引所は流動性が低い ETF の流動性を高めるため，ETF に注文を常にだしておき（マーケットメイク），利益の機会があれば裁定取引を行う専門業者（マーケットメイカー）には取引手数料を引き下げるなどの制度を 2018 年に導入した [東証 17]．

しかし，裁定取引にかかるコストによって ETF や株式の流動性がどのように変化するのか，そのメカニズムはどのようなものなのかといったことは分かっていない．

実証研究のみではこのようなまだ導入したことがない手数料体系を調べたり，その変更の純粋な効果やメカニズムを議論したりするのは困難である．このような議論をするのにすぐれた手法として，コンピュータ上で仮想的にその状況を作り出し検証する，エージェントベースドモデルの一種である人工市場モデルを用いたシミュレーションがある [LeBaron 06, Chen 12, Todd 16]．これまでの伝統的な経済学で使われてきた手法にはない強みがあるとして，Nature と Science に人工市場モデルに期待を寄せる論考が掲載されている [Farmer 09, Battiston 16]．

連絡先: mizutata@gmail.com
http://mizutatakanobu.com
当日の発表スライドは以下にあります
http://mizutatakanobu.com/201906.pdf

*1 実際にはこの交換の作業は後回しで行う．

*2 これら背景の詳しい解説として [東証 17] がある．また，ETF に限らず，株式などの流動性は社会の発展に非常に重要である．詳しい解説として [水田 18] がある．

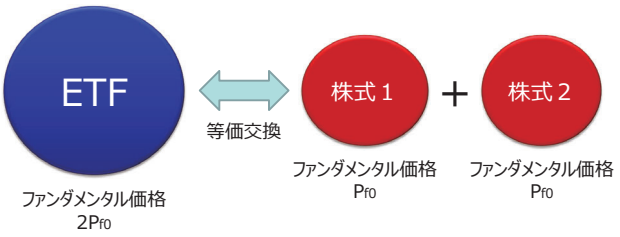


図 1: ETF1 株は，株式 1 の 1 株と株式 2 の 1 株の計 2 株と交換できる

そして，人工市場モデルを用いたシミュレーション研究はバブルや金融危機の発生メカニズムの解明に貢献したことはもちろん，現実の金融市場の規制や制度，ルールの変更の議論に多くの貢献した [Mizuta 16b, 和泉 17]．また，東京証券取引所の持ち株会社，日本取引所グループは人工市場モデルを用いて制度変更を検討した研究を “JPX ワーキングペーパー”*3 として数多く公表している．

先物や ETF と株式との裁定取引を人工市場モデルで扱った研究はあった [Xu 14, Torii 15]．しかし，裁定取引にかかるコストによって流動性がどのように変化するか人工市場モデルで調べた研究はない．

そこで本研究では [水田 13] の人工市場モデルをベースに，2 つの株式とそれら合計と同じ価値のある 1 つの ETF という 3 つの証券に拡張（図 1）し，これらの証券間の裁定取引を行うエージェントを実装したモデルを構築した．そして，株式と ETF の裁定取引にかかるコストによって流動性がどのように変化するかを調べた．

2. 人工市場モデル

[Chiarella 02] では，シンプルでありながら，実証分析で得られた長期間に存在する価格変動の統計的性質 (stylized fact) を再現できるエージェントモデルの構築に成功している．[水田 13] では，[Chiarella 02] のモデルをベースにモデルを構築し，[Chiarella 02] のモデルでは再現されていなかったミリ秒

*3 http://www.jpx.co.jp/corporate/research-study/working-paper/

	ETF			株式 1			株式 2	
売り	価格	買い	売り	価格	買い	売り	価格	買い
7	20300		30	10400		50	10400	
10	20200		44	10300		70	10300	
	20100		70	10200		90	10200	
	20000		134	10100		116	10100	
→	19900	1	→	10000	120	→	10000	154
	19800	10		9900	88		9900	60
	19700	6		9800	52		9800	55
	19600	4		9700	25		9700	31

図 2: 裁定取引の例

からマイクロ秒といった短い時間スケールでの性質 (マーケット・マイクロ・ストラクチャー) も再現した．

本研究では [水田 13] の人工市場モデルをベースに，2 つの株式とそれら合計と同じ価値のある 1 つの ETF という 3 つの証券に拡張（図 1）し，これらの証券間の裁定取引を行うエージェントを実装したモデルを構築した．本研究の目的にはモデルがシンプルであることはとても重要である．本モデルの構築の基本理念は [水田 16a] の付録 “モデル構築の基本理念” にて説明されている．

本モデルは 2 つの株式とそれら合計と同じ価値のある 1 つの ETF という 3 つの証券を取引対象とする（図 1）．いずれの証券も価格決定メカニズムは，ザラバ方式（continuous double auction）*4 とし，独立して価格の決定・売買が行われる．注文できる価格の変化幅の最小単位 (呼値の刻み) は δP とし，注文価格のそれより小さい端数は，買い注文の場合は切り捨て，売り注文の場合は切り上げる．

いずれかの証券のみを売買する多数（各証券に n 体，全部で $3n$ 体）のノーマルエージェントと，3 つの証券に対して裁定取引を行う 1 体の裁定エージェントが存在する．いずれのエージェントも保有する証券の数量に制限はなく (キャッシュが無限大)，マイナスの保有数量 (空売り) にも制限はない．

2.1 ノーマルエージェント

各証券に対してそれぞれ n 体のノーマルエージェントが売買に参加する．ノーマルエージェントは，実際の市場の価格形成の性質を再現するために導入するものであり，stylized fact や高頻度取引にかかわる統計量を再現するなるべくシンプルな，ごく一般的な投資家をモデル化したものとした．エージェント番号 $j = 1$ から順番に $j = 2, 3, 4, ...$ と注文を出す．$j = n$ が注文を出すと，次の時刻にはまた $j = 1$ から注文を出し繰り返される．注文数量は常に 1 株と一定とする．また，各証券の注文の量（流動性）を調整するため，ETF では注文は定数 $k(0 < k < 1)$ の割合でしか実行されず，実行されなかったエージェントはなにもせず次のエージェントに順番が移る．株式 1，2 ではすべてエージェントが注文を行う．そのため，ETF の注文量は株式 1，2 のそれの $k(< 1)$ 倍と少なくなる．

注文価格 $P^t_{o,j}$，売り買いの別を以下のように決める．各証券の時刻 t にエージェント j が予想する価格の変化率 (予想リターン)$r^t_{e,j}$ は，

$$r^t_{e,j} = \frac{w_{1,j} \log\left(P_f/P^t\right) + w_{2,j} r^t_{h,j} + w_{3,j}\epsilon^t_j}{w_{1,j} + w_{2,j} + w_{3,j}} \qquad (1)$$

とする．ここで，$w_{i,j}$ はエージェント j の i 項目の重みであり，シミュレーション開始時に，それぞれ 0 から $w_{i,max}$ まで一様乱数で決める．log は自然対数である．P_f は時間によらず一定のファンダメンタル価格であり株式 1 または 2 の場合 $P_f = P_{f0}$, ETF の場合 $P_f = 2P_{f0}$ である．P^t は各証券それぞれの取引価格，ϵ^t_j は各証券の時刻 t，エージェント j の乱数項であり，平均 0，標準偏差 σ_ϵ の正規分布乱数である．$r^t_{h,j}$ は各証券の時刻 t にエージェント j が計測した過去リターンであり，$r^t_{h,j} = \log\left(P^t/P^{t-\tau_j}\right)$ である *5．ここで τ_j はシミュレーション開始時に 1 から τ_{max} までの一様乱数でエージェントごとに決める．

予想リターン $r^t_{e,j}$ より予想価格 $P^t_{e,j}$ は，$P^t_{e,j} = P^t \exp\left(r^t_{e,j}\right)$ で求まる．注文価格 $P^t_{o,j}$ は平均 $P^t_{e,j}$，標準偏差 P_σ の正規分布乱数で決める．ここで，P_σ は定数である．そして，売り買いの別は予想価格 $P^t_{e,j}$ と注文価格 $P^t_{o,j}$ の大小関係で決める．すなわち，$P^t_{e,j} > P^t_{o,j}$ なら 1 株の買い $P^t_{e,j} < P^t_{o,j}$ なら1株の売り とする *6．注文を行ってからキャンセル時間 t_c だけ経過した注文はキャンセルする．

2.2 裁定エージェント

ETF1 株は，株式 1 の 1 株と株式 2 の 1 株の計 2 株と等価であり，各証券の取引価格がいくらであったとしても交換できる．そのため，ETF を買った価格が株式 1 と 2 を売った価格の合計より小さければ，その差額が利益となる（その逆もしかりである）．というのも，安く買った ETF を株式 1 と 2 に交換して高く売ればその差額が利益となるからである．このような価格差を利益とする取引を裁定取引とよばれており，裁定エージェントは裁定取引を行う．裁定エージェントはいつでも注文を出したり，変更したりできるとする．

図 2 は，各証券の注文状況の例である．株式 1 と 2 の最も高い買い注文の価格の合計は 20000(=10000+100000) である．一方，ETF の最も高い買い注文の価格は 19800 であり，19900 には買い注文は入っていなかったとする．裁定エージェントは ETF へ 19900 の 1 株の買い注文（赤字）を入れ待機する．もし，この注文が成立し，ETF1 株を手に入れたら，この ETF1 株を株式 1，2 それぞれ 1 株ずつと交換し，株式 1 と 2 を各 10000 で 1 株づつ売れば，差額の 100 が利益となる．もちろん逆の裁定取引も可能である．すなわち，まず ETF を借りてきて高く売り，株式を安く買って ETF に交換して返し，その差額が利益となる．

以上の例では，取引にかかるコストをゼロとしたが，実際にはコストがかかる．本モデルでは上記の一連の取引にかかるすべてのコストと，1 回の裁定取引で必要な利益額の合計を $C = c \times P_{f0}$ と定義する．C には必要な利益も含んでいるので，上記の価格差が C となる取引ができる場合，裁定取引を行うことができる．

今，株式 1，2，および ETF の最も高い買い注文の価格をそれぞれ B_1, B_2, B_{ETF}，それらの最も安い売り注文の価格をそれぞれ S_1, S_2, S_{ETF} とする．裁定エージェントは，$B_{ETF} < B_1 + B_2 - C$ のとき，ETF に価格 $B_1 + B_2 - C$ の 1 株の買い注文を，$S_{ETF} > S_1 + S_2 + C$ のとき，ETF に価格 $S_1 + S_2 + C$ の 1 株の売り注文を出す．両方出す場合もあることに注意．その後，ETF に出していた買い注文が成立したら，直ちに株式 1 と 2 にそれぞれ価格 B_1, B_2 の売り注文を 1 株ずつ出す．これらの注文は対当する注文がすでに存在するのですぐに取引が成立し，裁定取引が完了する．ETF に出していた売り注文が

*4 ザラバ方式は，売り手と買い手の双方が価格を提示し，売り手と買い手の提示価格が合致するとその価格で直ちに取引が成立する方式である [東証 15].

*5 ただし，$t < \tau_j$ のときは，$r^t_{h,j} = 0$ とした．

*6 ただし，$t < t_c$ のときは十分な板の厚さを確保するため，$P_f > P^t_{o,j}$ なら 1 株の買い，$P_f < P^t_{o,j}$ なら 1 株の売りとする．また，$P^t = P_f$ とする

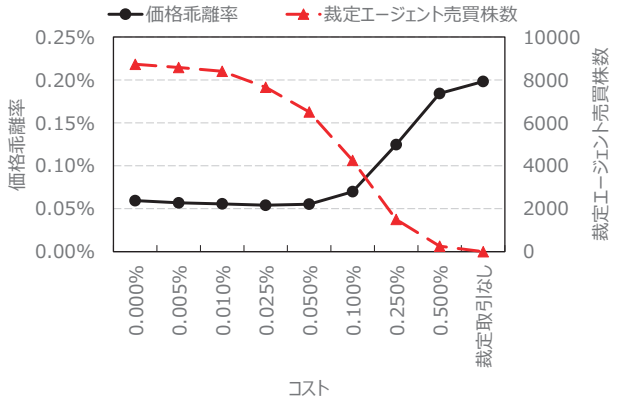


図 3: 価格乖離率と裁定エージェントの売買株数

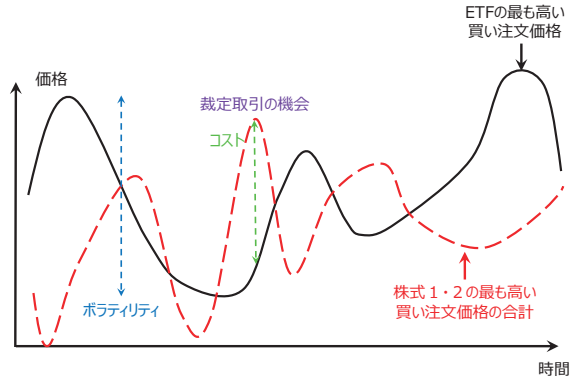


図 4: ボラティリティとコストの関係

成立したら，直ちに株式 1 と 2 にそれぞれ価格 S_1, S_2 の買い注文を 1 株ずつ出す．また，$B_1, B_2, B_{ETF}, S_1, S_2, S_{ETF}$ のいずれかが変更になれば，注文を入れなおす．

裁定エージェントのこれらの取引は必ず C だけの価格差を確保しており損失を出すことはないが，裁定取引の機会が全くない可能性はある．

3. シミュレーション結果

本研究では [水田 13] と同じ以下のパラメータを用いる．具体的には，$n = 1000$, $w_{1,max} = 1$, $w_{2,max} = 10$, $w_{3,max} = 1$,$\tau_{max} = 10000$,$\sigma_\epsilon = 0.06$, $P_\sigma = 30$, $t_c = 20000$,$\delta P = 0.01$,$k = 0.1$,$P_{f0} = 10000$ とした．つまり各証券のファンダメンタル価格は，株式 1 ，2 が $P_{f0} = 10000$，ETF が $2P_{f0} = 20000$ である．またシミュレーションは時刻 $t = t_e = 1000000$ まで行った *7． また，$c = 0\%, 0.005\%, 0.01\%, 0.025\%, 0.05\%, 0.1\%, 0.5\%$, および裁定エージェントがいない場合に対して，その他の条件を乱数表も含め全く同じにして，各種統計値を算出した．これを，乱数表を変更して 100 回行い，その平均値を用いる．

図 3 はコスト c ごとの価格乖離率と裁定エージェントの売買株数である．価格乖離率は株式 1 と 2 の価格の合計と ETF の価格がどれだけ乖離していたかを示す指標であり，$M_d = (1/te)\sum_{t=1}^{te} |P^t_{ETF} - (P^t_1 + P^t_2)|/|P^t_1 + P^t_2|$ と定義した．ここで，P^t_{ETF}, P^t_1, P^t_2 はそれぞれ時刻 t における ETF，株式 1 ，2 の価格，|| は絶対値である．

*7 これらのパラメータの妥当性検証については [水田 16a] の付録 “モデルの妥当性検証” で説明した．

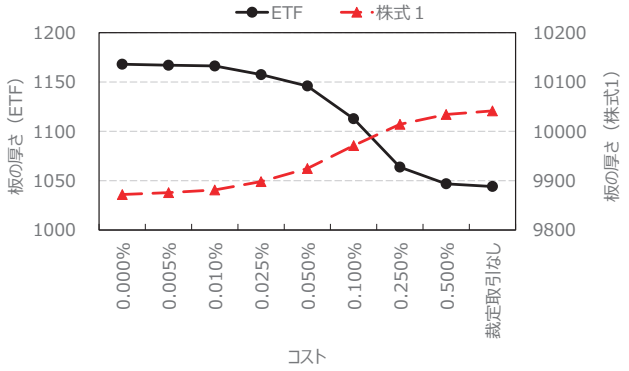


図 5: 板の厚さ

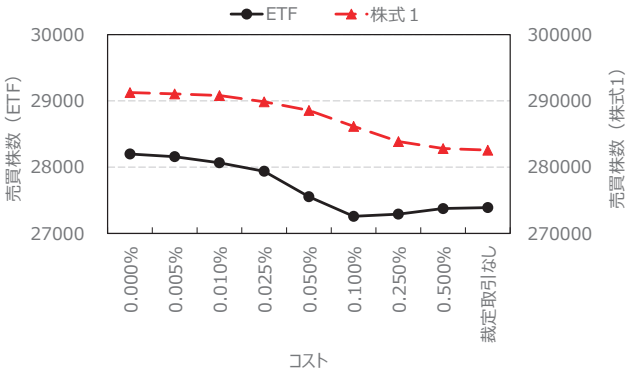


図 6: 全売買株数

コストが減少すると裁定エージェントの売買が増え，価格の乖離が減っている．価格の乖離はコストが 0.1% 付近を閾値に急激に変化している．この値はちょうど，10 期ごとの株式のリターンの標準偏差（ボラティリティ）である 0.11% に近い値である．そのため，コストがボラティリティに比べ，高いか低いかが重要な境界であることが考えられる．

図 4 は，ボラティリティとコストの関係を示した模式図である．赤い破線は株式 1 ， 2 の最も高い買い注文の価格の合計，黒い線は ETF の最も高い買い注文の価格である．そのため，赤い破線が黒い線よりコスト以上に上に来た場合のみ，裁定取引の機会がある．一方，各証券はボラティリティ程度の幅を持って価格が変動している．そのため，ボラティリティよりコストが小さければ裁定の機会が訪れやすく，裁定エージェントの売買が増え，ETF と株式の価格の乖離が小さくなる．

図 5 は ETF と株式 1 の板の厚さ (待機している注文量) を示している．板の厚さは最も高い買い注文価格と最も安い売り注文価格の平均から ±0.1% の範囲にある注文株数の合計の全時間での平均である．ETF はコストが下がると板が厚くなっており，特にコスト 0.1% 付近で大きく変化している．株式 1 は逆の傾向となっている．図 6 はノーマルエージェントも含めた全売買株数である．ETF，株式 1 ともにコストが低くなると売買が増えている．コストの減少により株式 1 の板の厚さが減少し売買が増えていることは，株式 1 の待機注文が裁定取引と対当していると考えれば整合的である．

4. まとめと今後の課題

本研究では [水田 13] の人工市場モデルをベースに，2 つの株式とそれら合計と同じ価値のある 1 つの ETF という 3 つの証券に拡張（図 1）し，これらの証券間の裁定取引を行うエージェントを実装したモデルを構築した．そして，株式と ETF の裁定取引にかかるコストによって流動性がどのように変化するかを調べた．

その結果，ボラティリティよりコストが小さければ裁定の機会が訪れやすく，裁定エージェントの売買が増え，ETF と株式の価格の乖離が小さくなることが分かった．また板の厚さを見ると，ETF はコストが下がると板が厚くなっており，株式は逆の傾向となることが分かった．また，ETF，株式ともにコストが低くなると売買が増えていることも示した．コストの減少により株式の板の厚さが減少し売買が増えていることは，株式の待機注文が裁定取引と対当していると考えれば整合的である．

ただし実際には，売買の量が増えればより多くの量を注文する市場参加者もいる．この効果を取り入れれば株式においてもコストが下がると注文量が増え，板の厚さも厚くなる可能性もあり，今後の課題である．

留意事項

本論文はスパークス・アセット・マネジメント株式会社の公式見解を表すものではありません．すべては個人的見解であります．

参考文献

[Battiston 16] Battiston, S., Farmer, J. D., Flache, A., Garlaschelli, D., Haldane, A. G., Heesterbeek, H., Hommes, C., Jaeger, C., May, R., and Scheffer, M.: Complexity theory and financial regulation, *Science*, Vol. 351, No. 6275, pp. 818–819 (2016), http://science.sciencemag.org/content/351/6275/818

[Chen 12] Chen, S.-H., Chang, C.-L., and Du, Y.-R.: Agent-based economic models and econometrics, *Knowledge Engineering Review*, Vol. 27, No. 2, pp. 187–219 (2012), http://dx.doi.org/10.1017/S0269888912000136

[Chiarella 02] Chiarella, C. and Iori, G.: A simulation analysis of the microstructure of double auction markets, *Quantitative Finance*, Vol. 2, No. 5, pp. 346–353 (2002), https://doi.org/10.1088/1469-7688/2/5/303

[Farmer 09] Farmer, J. D. and Foley, D.: The economy needs agent-based modelling, *Nature*, Vol. 460, No. 7256, pp. 685–686 (2009), https://www.nature.com/articles/460685a

[和泉 17] 和泉 潔, 川久保 佐記, 米納 弘渡：第 5 章 強靭な金融システム, 古田 一雄（編）, レジリエンス工学入門, 日科技連出版社 (2017), http://www.juse-p.co.jp/cgi-bin/html.pl5?i=ISBN978-4-8171-9624-8

[LeBaron 06] LeBaron, B.: Agent-based computational finance, *Handbook of computational economics*, Vol. 2, pp. 1187–1233 (2006), http://dx.doi.org/10.1016/S1574-0021(05)02024-1

[水田 13] 水田 孝信, 早川 聡, 和泉 潔, 吉村 忍：人工市場シミュレーションを用いた取引市場間におけるティックサイズと取引量の関係性分析, JPX ワーキング・ペーパー, No. 2, 日本取引所グループ (2013), http://www.jpx.co.jp/corporate/research-study/working-paper/

[水田 16a] 水田 孝信, 和泉 潔：人工市場シミュレーションを用いたバッチオークションの分析, JPX ワーキング・ペーパー, No. 17, 日本取引所グループ (2016), http://www.jpx.co.jp/corporate/research-study/working-paper/

[Mizuta 16b] Mizuta, T.: A Brief Review of Recent Artificial Market Simulation (Agent-Based Model) Studies for Financial Market Regulations and/or Rules, *SSRN Working Paper Series* (2016), http://ssrn.com/abstract=2710495

[水田 18] 水田 孝信：なぜ株式市場は存在するのか？, スパークス・アセット・マネジメント (2018), https://www.sparx.co.jp/report/special/2174.html

[Todd 16] Todd, A., Beling, P., Scherer, W., and Yang, S. Y.: Agent-based financial markets: A review of the methodology and domain, in *Computational Intelligence for Financial Engineering Economics (CIFEr), 2016 IEEE Symposium Series on Computational Intelligence on* (2016), https://doi.org/10.1109/SSCI.2016.7850016

[Torii 15] Torii, T., Izumi, K., and Yamada, K.: Shock transfer by arbitrage trading: analysis using multi-asset artificial market, *Evolutionary and Institutional Economics Review*, Vol. 12, No. 2, pp. 395–412 (2015), https://doi.org/10.1007/s40844-015-0024-z

[東証 15] 東証：東証公式 株式サポーター 株式取引編, 東京証券取引所 (2015), http://www.jpx.co.jp/learning/tour/books-brochures/detail/08.html

[東証 17] 東証マネ部 !: ETF が買いやすくなる「マーケットメイク」とは？, 東証マネ部！(2017), https://money-bu-jpx.com/news/article006961/

[Xu 14] Xu, H.-C., Zhang, W., Xiong, X., and Zhou, W.-X.: An agent-based computational model for China ' s stock market and stock index futures market, *Mathematical Problems in Engineering*, Vol. 2014, (2014), http://dx.doi.org/10.1155/2014/563912

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

クラスタリング構造変化検知による銀行間ネットワークの時間変化分析

Analysis of Inter-bank Network's Temporal Changes Using Clustering Structure Change Detection

仁木 裕太 *1 Yuta Niki　和泉 潔 *1 Izumi Kiyoshi　松島 裕康 *1 Hiroyasu Matsushima　坂地 泰紀 *1 Hiroki Sakaji　島田 尚 *1 Takashi Sshimada

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

In this research, a clustering structure change detection method is employed for analyzing temporal changes of the inter-bank network. The inter-bank network is constructed from data of Italian deposit trading system e-MID, and changes in the structure of the network that focused on the type of the bank are analyzed. By using clustering structure change detection, the change of the inter-bank network's structure after Lehman shock is detected, which depends on the type of bank.

1. はじめに

2008 年に起きたリーマンショックを機に, 金融システムについての研究が盛んになっている. 本研究で着目する銀行間ネットワークも, 金融システムの 1 つである. この分野に関する研究で用いられる手法は, 大きくシミュレーションとデータ解析の 2 つに分かれるが, 本研究はデータ解析の中でも複雑ネットワークの特徴量に基づく研究に当たる.

同様のアプローチの研究の中でも, 銀行間ネットワーク全体の特徴量について分析するものと, 特定の銀行に焦点を当てて分析するものがある. Finger らの研究 [Finger 13] では, 日次・月次・四半期・年次の 4 種類の集計区間で銀行間ネットワークの特徴量を計算し, リーマンショック時に特徴が変化していることを明らかにしたが, 集計区間が日次の場合, 値が安定せず分析が困難であった. Kuzubas らの研究 [Kuzubaş 14] では, トルコ金融危機が起きた 2000 年頃のトルコの銀行間ネットワークについて, 破綻した Demirbank に着目して分析がなされたが, 特定の銀行に注目すると銀行間ネットワーク全体の議論ができない.

そこで本研究では, Hirai ら [Hirai 12] によって提案されたクラスタリング構造変化検知を用いて, クラスターごとの特徴量の時系列を分析することで, 銀行間ネットワークのミクローマクロの関係性について分析することを狙いとする.

2. クラスタリング構造変化検知

各時刻 t において, 6 次元のデータが銀行間ネットワークのノードの数 n_t 個入力される. $X_t = (x_{1t}, \cdots, x_{n_t t})$ とする. このとき, $x_{it} \in R^6 (i = 1, \cdots, n_t)$ である. 6 次元のデータは, クラスター係数・入次数中心性・出次数中心性・次数中心性・媒介中心性・固有ベクトル中心性の値からなる. K_t を時刻 t におけるクラスター数とする. また, ノード i の属するクラスターを $z_{it} \in K_t$ とし, $Z_t = (z_{1t}, \cdots, z_{n_t t})$ と表す.

クラスタリングを行うモデルとして, ガウス混合分布を用いる. 各時間ステップで, モデル選択規準 MSC が最小となるクラスター数を最適なクラスター数として選択して計算を行う. MSC は, ガウス混合分布モデルについてのベイズ情報量規準 BIC[Schwarz 78] と, クラスター数の遷移確率 $P(K_t|\hat{K}_{t-1}; \hat{\alpha}_t)$ の符号長 $l(K_t|\hat{K}_{t-1}) = -\log P(K_t|\hat{K}_{t-1}; \hat{\alpha}_t)$ の和とする. クラスター数の遷移確率およびパラメータ $\hat{\alpha}_t$ は以下のように定義する;

$$P(K_t|\hat{K}_{t-1}; \alpha) = \begin{cases} 1 - \hat{\alpha}_t & (K_t = \hat{K}_{t-1} \text{ のとき}), \\ \hat{\alpha}_t / 2 & (K_t = \hat{K}_{t-1} \pm 1 \text{ のとき}). \end{cases}$$

$$\hat{\alpha}_t = \frac{(N_t + 1/2)}{t}.$$

ただし, N_t は時刻 $t-1$ までのクラスター数が変化した回数とする. また, α_t はクリシェフスキー・トロフィモフの推定法 [Krichevsky 81] によって推定するものとする.

3. 本研究で用いるデータとその処理

銀行間預金の取引をオンラインで行うプラットフォーム e-MID[emi] がある. 本研究では, イタリア銀行及びイタリア銀行と取引のある国外銀行が, 1999 年から 2016 年の間に e-MID を介して行った取引データをもとに分析を行う. 取引データから銀行間ネットワークを構築する前に, 以下の前処理を行う.

1. 取引成立から満期までの期間が 1 日である, 翌日物取引を抽出する.
2. ネットワークを構築する際のエッジの向きを資本が移動する方向に統一する.

銀行間ネットワークの構築は営業日ごとに行う. 時間幅 τ が 20 営業日の時間窓を設けて, 時刻 $t - \tau + 1$ から t の取引データを抽出し, 時刻 t の銀行間ネットワークを構築する. このとき, 抽出された取引データの中に同じ銀行間の取引が複数ある場合も, ネットワークのエッジは 1 本とし, エッジの重複は考慮しない.

次に, 構築した銀行間ネットワークについて, 以下のネットワーク特徴量をノードごとに計算する. クラスター係数は, 無向グラフに対して定義される特徴量であるため, 構築した銀行間ネットワークを無向グラフに変換してから計算する.

- クラスター係数

連絡先: 仁木 裕太, 東京大学大学院工学系研究科, 東京都文京区本郷 7-3-1, 03-5841-1867, b2018yniki@socsim.org

- 次数中心性（入次数・出次数・2 つの和）
- 媒介中心性
- 固有ベクトル中心性

4. 解析結果

4.1 クラスター数の推移

1999 年から 2016 年の全期間のクラスター数の推移を, 図 1 に示す. 全期間を通して, クラスター数は 2 から 5 の間で主に推移していることが分かる. その中で, クラスター数が 8 まで上昇した 2003 年の時点と, クラスター数が 7 となった 2008 年の時点が特徴的である. 本研究では, 2008 年の時点について詳細に分析を行う.

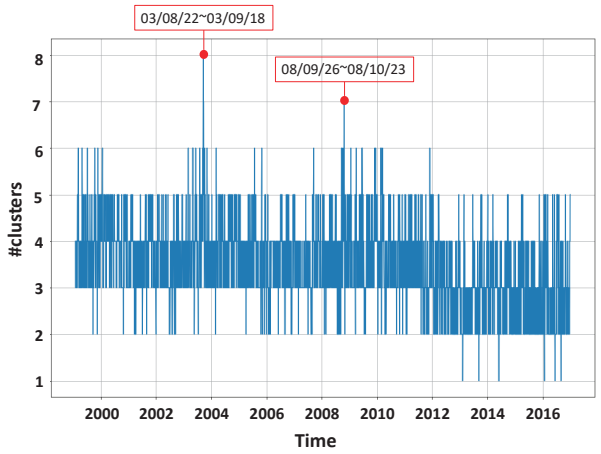


図 1: 1999 年から 2016 年の間のクラスター数の推移.

2008 年 8 月から 10 月までの期間のクラスター数の推移を図 2 に示す. クラスター数が 7 まで増えた 10 月 23 日の時点が特徴的だが, 9 月 15 日を境にクラスター数の変化のパターンが変わった様子が見える. そこで, 9 月 15 日前後でどのように変化にしたかに着目して考察する.

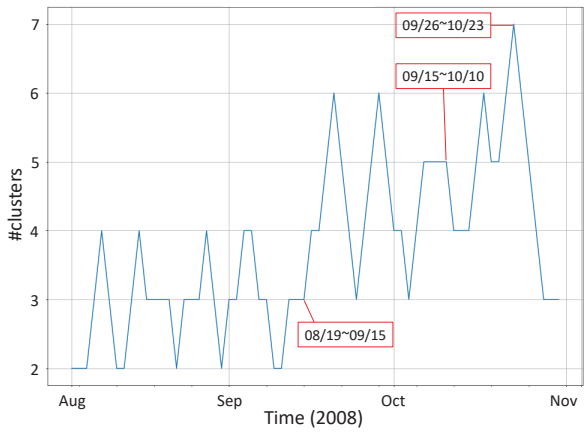


図 2: 2008 年 8 月から 10 月の間のクラスター数の推移.

4.2 次数中心性とクラスター係数

クラスターごとの次数中心性とクラスター係数の平均値について, 9 月 15 日前後の変化を図 3 に示す. Sakiyama らの研究 [Sakiyama 16] によると, 次数が低くクラスター係数が高いクラスター 1 が特定の相手とのみ取引する小銀行, 次数・クラスター係数がともに低いクラスター 3 が大銀行と取引のある中銀行, 次数が最も大きいクラスター 2 が大銀行と考えられる. 9 月 15 日前後の間の変化は, クラスターごとによって異なることが分かるがその解釈は困難である. そこで, 他の特徴量についての時系列から分析を行う.

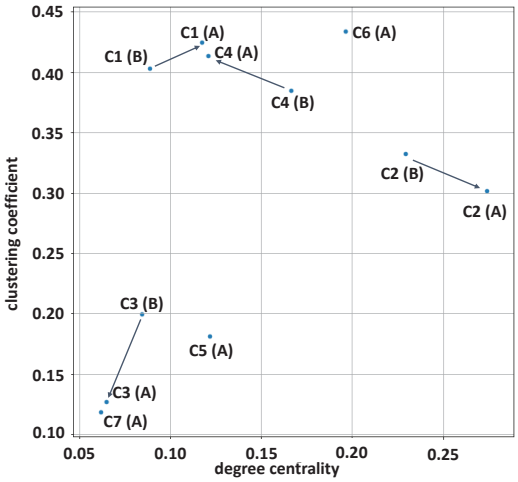


図 3: 2008 年 9 月 15 日前後についてクラスターごとの次数中心性とクラスター係数の平均値を表す散布図. 括弧内の文字は, B が 8 月初めから 9 月 15 日より前・A が 9 月 15 日以降から 10 月末までの期間を示す.

4.3 他の特徴量の時系列

まず, 入次数中心性と出次数中心性の時系列について分析する. 銀行間ネットワークにおいて, 入次数は資本流入の度合, 出次数は資本流出の度合を表す.

図 4 を見ると, リーマンショックが起きた 9 月 15 日直後にクラスター 2 (大銀行) の入次数中心性の値が急上昇したあと, すぐに大幅に減少している. その後, 大銀行の入次数中心性が以前と似た値に落ち着くのと入れ替わるように, クラスター 1 (小銀行) の入次数中心性が増加している. 小銀行の入次数中心性は, 何度か高い値を取った後, 10 月下旬に大きく減少している.

図 5 を見ると, 9 月 15 日直後はクラスター 3 (中銀行) の出次数中心性の値が上昇している. また, 9 月下旬からは大銀行の値が上昇した後, 10 月中旬まで高い値となっている.

このことから, 大銀行が 9 月 15 日直後に取引のある中銀行から資本を回収して自己資本を増強したことや, リーマンショックの影響を受けた小銀行が 9 月下旬から大銀行の資金援助を受けていることが推察できる.

次に, 固有ベクトル中心性について分析する. 銀行間ネットワークにおいて固有ベクトル中心性は, 取引相手が他の銀行にとってどれだけ重要かを反映した値である.

図 6 を見ると, 9 月 15 日の後の小銀行と大銀行の取引が活発になった期間では, 大銀行との取引が生まれた小銀行の固有ベクトル中心性の値が大きくなり, 逆に小銀行との取引が増えた大銀行の値は低くなっている. その後, 大銀行との取引が切られた時刻を境にクラスター 2 の値が大幅に減少している様子も見られる.

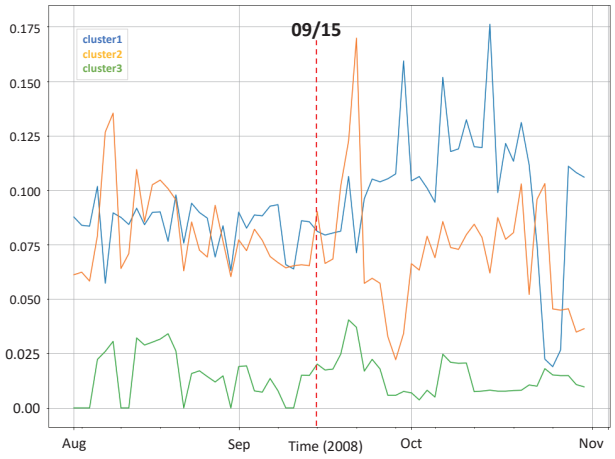


図 4: クラスターごとの入次数中心性の推移.

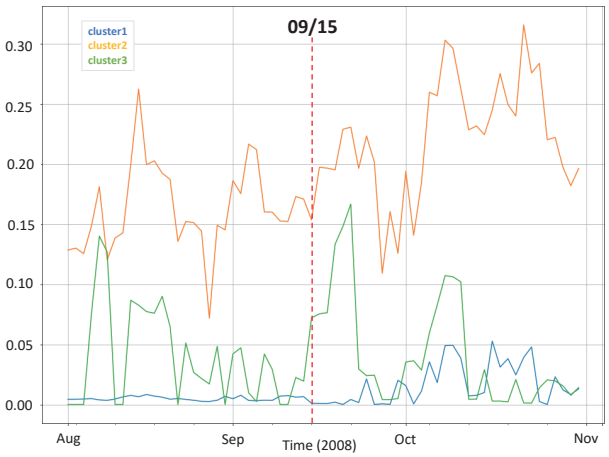


図 5: クラスターごとの出次数中心性の推移.

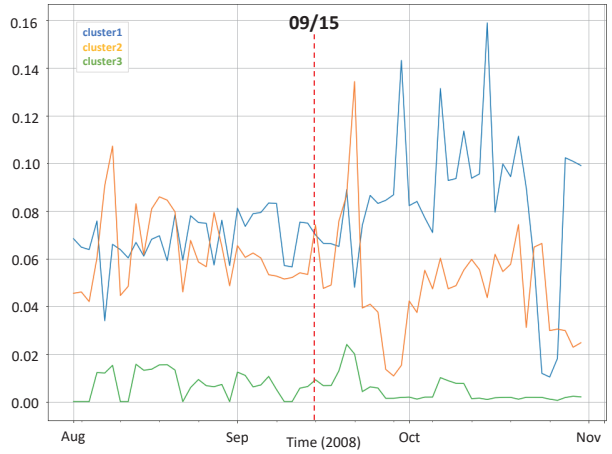


図 6: クラスターごとの固有ベクトル中心性の推移.

5. まとめと展望

本研究では, e-MID のデータを元に構築した時系列性を持つ銀行間ネットワークに対して, クラスタリング構造変化検知を用いて, 銀行の種類ごとのネットワーク特徴量について営業日単位での推移について分析を行った. 分析の結果, リーマンショック後の期間について, 銀行の種類によって異なるダイナミクスの特徴が見られた. また, この特徴の違いについて, 銀行間ネットワークに沿った解釈を与えることができた.

今後の展望としては, 本研究の分析で得られた知見をもとに, シミュレーションのモデルを設計することを考えている. 具体的には, シミュレーション開始時に強制的に銀行を倒産させた後, 銀行の種類に対応した挙動をするようにモデル化ができれば, より現実に即したシミュレーションになると考える.

参考文献

[emi] e-MID の Web ページ:https://www.e-mid.it/en/ 2019 年 1 月 17 日閲覧

[Finger 13] Finger, K., Fricke, D., and Lux, T.: Network analysis of the e-MID overnight money market: the informational value of different aggregation levels for intrinsic dynamic processes, *Computational Management Science*, Vol. 10, No. 2-3, pp. 187–211 (2013)

[Hirai 12] Hirai, S. and Yamanishi, K.: Detecting changes of clustering structures using normalized maximum likelihood coding, in *Proceedings of the 18th ACM SIGKDD international conference on knowledge discovery and data mining*, pp. 343–351ACM (2012)

[Krichevsky 81] Krichevsky, R. and Trofimov, V.: The performance of universal encoding, *IEEE Transactions on Information Theory*, Vol. 27, No. 2, pp. 199–207 (1981)

[Kuzubaş 14] Kuzubaş, T. U., Ömercikoğlu, I., and Saltoğlu, B.: Network centrality measures and systemic risk: An application to the Turkish financial crisis, *Physica A: Statistical Mechanics and its Applications*, Vol. 405, pp. 203–215 (2014)

[Sakiyama 16] Sakiyama, T. and Yamada, T.: Market liquidity and systemic risk in government bond markets: A network analysis and agent-based model approach, *IMES Discussion Papers*, No. 2016-E (2016)

[Schwarz 78] Schwarz, G., et al.: Estimating the dimension of a model, *The annals of statistics*, Vol. 6, No. 2, pp. 461–464 (1978)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

東京証券取引所における 高頻度マーケットメイク戦略の注文行動分析

Analysis of Limit Orders by High-Frequency Traders in Tokyo Stock Exchange

平野 正徳 *1 Masanori HIRANO　和泉 潔 *1 Kiyoshi IZUMI　松島 裕康 *1 Hiroyasu MATSUSHIMA　坂地 泰紀 *1 Hiroki SAKAJI　島田 尚 *1 Takashi SHIMADA

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

This study aimed to analyze the order behavior by High-frequency traders (HFT) called market making (MM) strategy. We used the order data of Tokyo Stock Exchange provided by Japan Exchange Group, Inc.. Firstly, we preprocessed the order data for merging virtual server used by the same traders. Secondly, we did a cluster analysis of traders based on some indexes indicating features of their trading strategy and extracted HFT-MM traders. Then, we calculated how many ticks their ordering price is far from the last executed price. As a result, we found some of their orders were placed at quite far (5-10 ticks) price from the last executed price for HFT-MM. This result means they mixed some strategies other than market making strategy and the strategies, possibly, will cause the unstabilizing effect when the market price is very fluctuating.

1. はじめに

近年，ICT 技術の向上などにより，金融市場において，ミリ秒単位で高頻度に注文を行う高頻度取引 (HFT) が普及してきた．

実際に HFT が市場に与える影響は諸説があり，まだ明らかになっていない．特に，価格が急落する局面においては，急落を助長する負の影響を市場に与えるという意見も存在する一方で，市場に流動性を与える正の影響があるという意見も存在する．このような現象を分析するためには，実証分析だけではなく，行動主体をモデル化し，シミュレーションを行うことが必要であると考えられる．行動主体をモデル化するにあたっては，そもそもの行動主体の行動を分析しなければならず，そのためには，大量の注文情報を分析をしなければならないが，人手では厳しい．そこで，本研究においては，HFT の行動戦略についてデータ解析の工学的アプローチから研究を行なった．

2. 株式市場における HFT の概要

東京証券取引所 (東証) における HFT について分析した研究として，[Hosaka 14] がある．Hosaka の研究では，東証における HFT の注文の多くは板に流動性を供給するメイク型の注文が多いことなどを明らかにした．

一般に，金融市場に注文を行う方法は 2 種類ある．注文者が価格を指定する指値注文と，価格を指定せず現在すぐに売買可能な価格で取引する成行注文が存在する．指値注文を行なった場合，約定 (注文成立) するか，キャンセルするまでは，板 (売買の価格と量を一覧した注文リスト．図 1 が見本である．) に表示される．図 1 の場合，1001 円に 300 株の売り注文が，999 円に 1200 株の買い注文が入っており，これがそれぞれ最も条件の良い売買の条件となり，最良気配値 (それぞれ Best bid，Best ask) と呼ばれる．

また，図 1 の場合，1000 円には注文が入っていない．Best bid と Best ask の間には 2 円の開きがある．これをスプレッドという．このスプレッドが小さいほど，適切な価格で取引ができる可能性が高く，流動性が高い板ということになる．また，スプレッドが小さくなるためには，板が厚い (より多くの注文が板に存在する) 方が良いことになる．そのため，板に乗る注文を増やす指値注文は流動性を高める注文であり，その指値注文を強制的に減らすことになる成行注文は流動性を減らす注文となる．また，前者のような流動性を高める取引をメイカー注文，後者のような流動性を下げる取引をテイカー注文という．

Sell		Buy
1200	1002	
300	1001	
	1000	
	999	1200
	998	1000
	997	2100

図 1: 板の見本．右側が買い注文で，左が売り注文のリストとなっている．

HFT の有名な取引戦略として，Spread Capturing と言われる戦略がある．簡単に説明すれば，図 1 の場合，1001 円の売り注文と，999 円の買い注文を行い続ければ，スプレッドの 2 円分の収益を得られるというものである．しかし，実際には，Best bid と Best ask で取引を繰り返せば良いわけではない．ポジションが 0 でない場合 (株式を持っていたり，空売りした株式が残っている場合) は，その在庫が価格変動のリスクに晒されている．つまり，価格が大きく変動した場合は，大きな損益を出す可能性がある．そこで，在庫や，ボラティリティー (価格変動の可能性) を加味したモデルで，注文戦略を最適化する必要が出てくる．この注文戦略の最適化についての研究としては，[Avellaneda 08] があげられる．このような戦略は一般に，マーケットメイク戦略と呼ばれている．

本研究においては，HFT のマーケットメイク戦略に注目し，大規模な注文データを解析することで，その行動を分類し，特徴を明らかにすることを目的としている．

連絡先: 〒 113-8656 文京区本郷 7-3-1 東京大学大学院工学系研究科システム創成学専攻 和泉研究室　平野正徳　HP: https://mhirano.jp E-mail: hirano@g.ecc.u-tokyo.ac.jp

3. 手法概要

本研究では，株式会社日本取引所グループから提供を受けた，板再現データと呼ばれる，上場銘柄の注文記録データを使用した．一般向けに提供されている FLEXFull よりも詳細な注文情報が含まれており，特に，仮想サーバーと呼ばれる，発注元の識別情報が匿名化された形で含まれている．仮想サーバーとは，東証の売買システム (arrowhead) に接続し，注文をやり取りするために必要な論理デバイスのことで，証券会社や機関投資家などの取引主体と売買システムをつなぐゲートのような役割のものである．ただし，一つの仮想サーバーで出せる注文は秒あたりで制限があり，その上限の問題や，接続の冗長性の必要性などから，複数の仮想サーバーを使用する取引主体が多く存在する．さらに，どの取引主体が HFT，さらに言えば，HFT の中でマーケットメイク戦略を取っている主体 (HFT-MM) なのかを識別することはデータそのものだけでは判断できない．そこで，同一の主体が使用している複数の仮想サーバーを可能な範囲で一つとする「名寄せ」と呼ばれる作業と，HFT-MM 主体のクラスタリングによる抽出を，[Uno 18] の手法を使用し，行なった．さらに，そこで抽出された HFT-MM 主体の注文の分析を行なった．

4. 分析手法と結果

2015 年 8 月の板再現データ (21 営業日分) を対象として，実験を行なった．

4.1 仮想サーバーの名寄せ

まず，[Uno 18] の手法と同様に，仮想サーバー (VS) の名寄せを行なった．同一の注文識別番号の注文に対して，複数の仮想サーバー番号 (VS-ID) が付いている場合は，それらの VS は同一の主体のものとみなした．ただ，完全に全ての取引主体を綺麗に名寄せできるわけではない．2015 年 8 月の全ての営業日のデータを対象に名寄せ作業を行った結果，全 VS 数 4616 に対して，名寄せ後 VS 数 (取引主体数) は 2664(内，名寄せされなかった VS 数:2455) となった．

4.2 クラスタ分析によるグルーピング

クラスタリングに当たって，[Uno 18] と同様のいくつかの指標を使用した．まず，高頻度に取引を行っている主体のみを取り出すために，1 銘柄あたりのアクション数 (ActionsPerTicker) を利用した．さらに，クラスタ分析に使用する指標として，在庫比率 (InventoryRatioABS)，注文取消比率 (CanceledOrderRatio)，VS あたりの取引銘柄数の対数値 (TickerPerVSLOG)，銘柄あたりの注文頻度の対数値 (ActionsPerTickerLOG) を使用した．それぞれの定義は次式の通りである．

$$(\text{ActionsPerTicker}) = \frac{(\text{newOrder}) + (\text{changeOrder}) + (\text{cancelOrder})}{(\text{numTikcer})} \tag{1}$$

$$(\text{InventoryRatioABS}) = \underset{\text{ticker}}{Median}\left(\left|\frac{(\text{soldVolume})_{\text{ticker}} - (\text{boughtVolume})_{\text{ticker}}}{(\text{soldVolume})_{\text{ticker}} + (\text{boughtVolume})_{\text{ticker}}}\right|\right) \tag{2}$$

$$(\text{CanceledOrderRatio}) = \frac{(\text{cancelOrder})}{(\text{newOrder})} \tag{3}$$

$$(\text{TickerPerVSLOG}) = \ln\left(\frac{(\text{numTikcer})}{(\text{numVS})}\right) \tag{4}$$

$$(\text{ActionsPerTickerLOG}) = \ln(\text{ActionsPerTicker}) \tag{5}$$

ここで，(newOrder)，(changeOrder)，(cancelOrder) はそれぞれ，新規注文数，注文変更回数，注文取消回数であり，(numTikcer) は名寄せ後の取引主体が取引の対象にしている銘柄の数である．さらに，$\underset{\text{ticker}}{Median}$ は全ての取引銘柄に関して計算した結果の中央値を取ることを示している．また，$(\text{soldVolume})_{\text{ticker}}$，$(\text{boughtVolume})_{\text{ticker}}$ はそれぞれ，一つの銘柄における約定済みの売付株式数と買付株式数である．(numVS) は名寄せ後の取引主体が使用している VS 数である．また，ln は自然対数を取る，つまり，$\log_e$ と同じである．

これらの指標を，取引主体ごとに 2015 年 8 月全営業日ごとに計算をし，それぞれの指標において，中央値を取ることで，取引主体それぞれの指標を計算した．さらに，アクション数 (ActionsPerTicker) が 100 以上の高頻度なものに絞った．その結果，2664 主体から 253 主体に絞られた．

この 253 主体に関して，指標を正規化し，ユークリッド距離に基づいた Ward 法による分類を行った．クラスター数については，[Uno 18] と同様の 10 を採用した．

各クラスターの代表的な指標を表 1 にのせた．結果のデンドログラムは図 2 の通りである．図 2 で色が左から順についており，この順にクラスター 1 から並んでいる．

HFT-MM の特徴は，高取消，低在庫 (ポジションを翌日に持ち越すことが少ない) であり，この条件を満たすのは，クラスター 4 である．このクラスター 4 に含まれる，10 個の主体を HFT-MM として認定し，以降，分析を行うこととした．

また，目視確認で，Best bid，Best ask の上下に綺麗に注文を並べている，HFT-MM の特徴的な戦略を確認した．ただし，ここでは，具体例を提示すると，個々の主体の取引の匿名性を損ないかねないので，割愛する．

表 1: それぞれのクラスターの代表指標

クラスター番号	新規注文回数	約定比率	取消比率	取扱銘柄数	使用 VS 数	成行注文比率	在庫比率	主体数
1	6084.2	0.6451	0.1207	12.6	1.58	0.0000	0.1307	24
2	382847.0	0.0418	0.0000	2614.2	1.00	0.0000	0.5966	4
3	65443.4	0.9127	0.2019	394.1	3.67	0.0052	0.0529	12
4	127368.6	0.1541	0.9067	95.3	15.60	0.0000	0.0399	10
5	26519.4	0.0193	0.9853	57.2	4.05	0.0000	0.9438	20
6	42106.9	0.0222	0.9779	120.3	1.00	0.0000	1.0000	68
7	72543.4	0.3264	0.6328	902.6	2.89	0.0256	0.8511	19
8	61188.3	0.3364	0.7727	466.8	9.80	0.0321	0.9954	59
9	219292.2	0.2417	0.7767	607.6	20.00	0.0003	0.2968	19
10	734.1	0.1593	0.8082	6.0	3.22	0.0207	0.9109	18

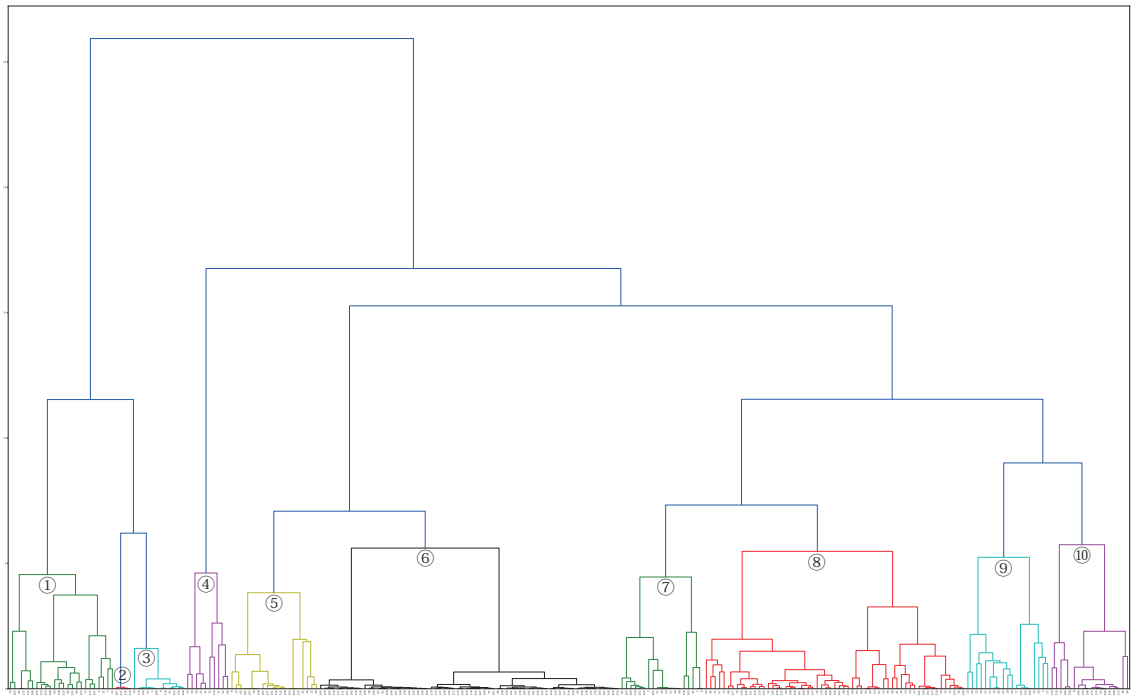


図 2: Ward 法によるクラスタリングの結果のデンドログラム

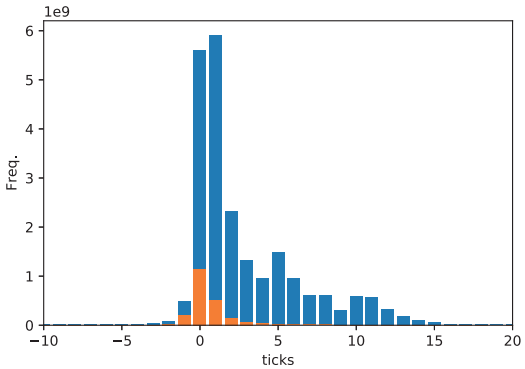


図 3: HFT-MM の注文投入位置．横軸は買い注文の場合は，価格が下がる方向を正の方向として，売り注文の場合は，価格が上がる方向を正の方向とした時の tick 数．縦軸が頻度，青が総注文数，オレンジが最終的に約定した注文数．

4.3 HFT-MM の注文位置の確認

次に，HFT-MM の注文戦略の確認を行った．HFT-MM は，Best bid, Best ask 付近に注文を置く傾向が高い戦略である．そこで，直近約定価格から何ティック (本論文ではティックは注文価格の最小刻み値の意味で使う) の位置に新規注文を入れているのかについて検証を行なった．買い注文の場合は，価格が下がる方向を正の方向として，売り注文の場合は，価格が上がる方向を正の方向として統計した．ただし，あくまで，直近約定価格を基準としているので，流動性が薄い場合などに，マイナスのティック数の位置に注文が入ることがある．また，HFT-MM とみなした 10 個の主体のうち，2 主体はマーケットメイク戦略と言えるような戦略を取っているものの，その注文の取り扱い方法が非常に特殊であり，データをうまく補正しないと同一に扱えないため，対象から外した．

結果は図 3 の通りとなった．まず，着目したいのが，最終的に約定しているのは主に最良気配値周辺の注文だけであると思われることである．これは，ある意味当たり前の結果であり，今回の実験がおかしな結果ではないとわかる．

さらに，興味深いのが，HFT-MM といえども，非常に幅広い範囲に注文をしていることである．もちろん，最大の頻度を出しているのは，直近の約定価格とその隣であるのだが，直近の約定価格から離れた価格では，注文頻度は減るものの，5 ティックと 10 ティック離れた価格に注文頻度が増える極値が存在している．

[Avellaneda 08] によれば，HFT-MM における最適化戦略の注文価格はある程度の範囲におさまるはずであり，ここまで大きくテイルを持つのは異なる戦略を合わせて使用している可能性が想定できる．ただし，[Avellaneda 08] によれば，銘柄のボラティリティーや，取引主体のリスク許容度によっては売買の注文の幅が異なる可能性があるので，それらを加味した分析を次に行うことにした．

4.4 銘柄別ボラティリティーや取引主体のリスク許容度を加味した HFT-MM の注文位置の確認

まず，HFT-MM は [Avellaneda 08] で示された最適化戦略を想定して行動を取っており，4.3 節の結果の第一ピークはその結果であると想定した．[Avellaneda 08] によれば買い注文，売り注文のそれぞれの最適値を P_a, P_b として，最適な戦略は

$$\frac{P_a + P_b}{2} \approx P - \gamma\sigma^2 q_t \Delta T \tag{6}$$

$$P_b - P_a \approx \gamma\sigma^2\Delta T + \frac{2}{\gamma}\ln\left(1 + \frac{\gamma}{k}\right) \tag{7}$$

となる．ここで，P は現在価格，γ はリスク回避度で，取引主体に依存する変数，σ は銘柄の価格のボラティリティー (厳密には価格変動をランダムウォークと見た場合の変動の標準偏差) で，銘柄に依存する変数，q_t は取引主体が抱えている在庫，ΔT はどれだけ先の時点での効用を最大にしたいかで，取引主体に依存する変数，k は注文の強度分布がべき分布近似できることに基づいた，そのべき分布の指数で，銘柄に依存する変数

であると考えられる．よって，$P_b - P_a$ は銘柄と取引主体を固定すれば，概ね変動のないものと考えられる．さらに，$\frac{P_a+P_b}{2}$ については，HFT-MM はリスクヘッジのために在庫 q_t を抱えていることが少ないと考えられる上，抱えていたとしても，$P - P_a$ と $P_b - P$ を集計すれば，$\gamma\sigma^2 q_t \Delta T$ だけ $P - P_a$ にプラスされ，$P_b - P$ にはマイナスされるだけなので，ピークの位置が分かれて左右に若干ずれるだけで影響は少ないと仮定できる．(売買株式数が対称であれば，平均の変化はないはずである．)

以上の仮定に基づき，銘柄，取引主体，日付が同じデータに関して 4.3 節の分析を個別に行い，さらに，そのデータを正規化のような作業 (以下スケーリングと呼ぶ) をすることで，同一指標として集計することとした．スケーリングは，0-5 ティックで最も頻度の高い地点を探し，その地点が 2 ティック以上であれば，全てのティックをそのティックで割るというものである．具体的には次の通りだ． 図 4 の場合 (銘柄番号については

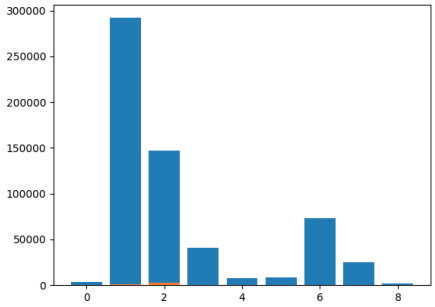


図 4: 2015/08/03 の 102 番の主体の銘柄 A における集計結果

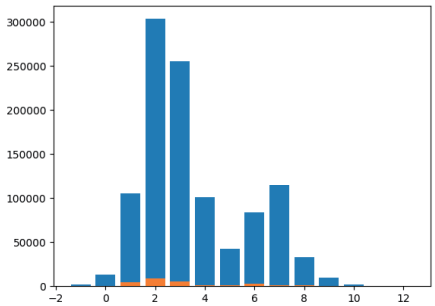


図 5: 2015/08/03 の 102 番の主体の銘柄 B における集計結果

は匿名性確保のため表示していない)，1 ティック地点が最大値を取っているので，データの変換は行わない．図 5 の場合，2 ティック地点が最大値を取っているので，横軸の値を全て 1/2 にする．このような操作をすることで，銘柄ごとのボラティリティーや，取引主体ごとのリスク回避度を加味して集計を行えると考えた．この操作で，[Avellaneda 08] で示された最適化戦略に基づく取引は 1 ティックの地点に集まると考えられる．ただし，この操作により，整数値以外も取りうるようになるため，ヒストグラムを利用してプロットした．結果は図 6 の通りである．この結果より，スケーリングを行っても概ね同じような結果が見えることが確認できた．

5. 考察・まとめ

HFT-MM は最良気配値付近のみでマーケットメイク戦略を行うものだと考えがちであり，最適化戦略においても，離れた位置に注文をおくメリットはあまりないように見える．しか

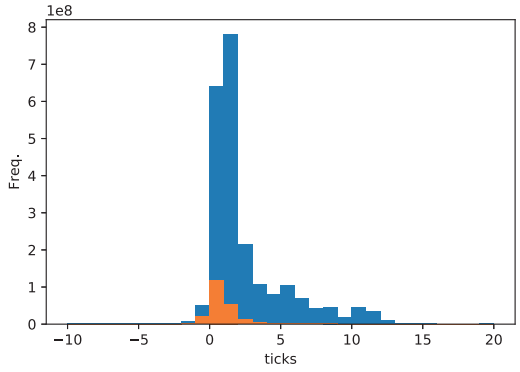


図 6: HFT-MM の注文投入位置．横軸は買い注文の場合は，価格が下がる方向を正の方向として，売り注文の場合は，価格が上がる方向を正の方向とした時のスケーリング後のティック数．縦軸が頻度，青が総注文数，オレンジが最終的に約定した注文数．区切り値は全整数値である．

し，実際には 10 ティックを超える位置にも注文を置いていることが明らかで，なんらかの異なる戦略を組み合わせている可能性がある．例えば，早いタイミングで最良気配値から離れた位置に注文を置いておくことで，時間優先のルールから，価格変動が起きた場合に優位な立場に立てる可能性がある．そのような戦略の場合，約定しそうになってから注文を取り下げるかの判断をすれば良いだけである．ただし，最良気配値から離れた位置での注文は約定しているケースが少なかった．(概ね 2.5%程度．0 ティック地点は 20%．) また，HFT-MM においては，失効を待たずに取消しをすることが極めて多いので，多くの場合，取り消されていると考えられる．このような戦略は，約定の可能性が極めて低いもので，流動性供給者としての機能がない可能性がある．特に，価格急変時には，HFT-MM のような戦略をとる主体はこれらの注文を取り消すことが多いと考えられるため，板で見えている以上に価格急変が起こる可能性があるのではないだろうか．

現実の市場は理論では片付けられないレベルで複雑であり，今後起こりうる金融市場のイベントは予知するのは難しい．今回は HFT-MM だけに絞って研究を行なったが，これをさらに他の行動主体にも拡張し，実際のデータに基づいた分析と，シミュレーションを組み合わせるなどして，さらなる金融市場の動向分析やリスク予想などにつなげていきたいと考える．

謝辞

本研究は，株式会社日本取引所グループよりデータの提供をいただきました．この場を借りて，心より御礼申し上げます．

参考文献

[Avellaneda 08] Avellaneda, M. and Stoikov, S.: High-frequency trading in a limit order book, *Quantitative Finance*, Vol. 8, No. 3, pp. 217–224 (2008)

[Hosaka 14] Hosaka, G.: 東京証券取引所における High-Frequency Trading の分析, JPX Working Paper (2014)

[Uno 18] Uno, J., Goshima, K., and Tobe, R.: 取引行動のクラスター分析：HFT 抽出の試み, 行動経済学会 第 12 回大会 (2018)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

有価証券報告書からの未来志向文の抽出

Extraction of Future-oriented Sentences from Annual Securities Reports

小寺　俊哉[*1] Shunya Kodera　田中　良典[*1] Yoshinori Tanaka　佐藤　史仁[*1] Fumihito Sato　佐久間　洋明[*1] Hiroaki Sakuma　坂地　泰紀[*2] Hiroki Sakaji　和泉　潔[*2] Kiyoshi Izumi

[*1] 日興リサーチセンター株式会社 Nikko Research Center, Inc.　[*2] 東京大学大学院工学系研究科 Graduate School of Engineering, The University of Tokyo

In annual securities report, various information such as results of diverse business performances, point of view about causation of these outcomes, and issues and challenges to be addressed in the near future are included. Most of previous researches proposed the extraction methods of important sentences containing causal information of past company's performances but not effort to address future company's issues from text materials. In this paper, we propose our original method to extract future-oriented sentences by the combination of two SVM identification models, one of which captures features of future and the other aims for purposes and means in sentences of annual reports. All mean evaluations of our models, that were precision, recall and F-score, showed more than almost 0.9. and indicated that by using our model, we can effectively collect future information about business activities from annual reports as well as other relevant sources, which would allow us to make unique investment decisions and to develop unprecedented investment methods.

1. はじめに

近年，テキストマイニングの技術を使い，自動でテキストデータから重要部分を判断し抽出する研究やテキストデータを定量評価する研究が盛んに行われている．例えば，坂地ら[坂地 2015]や佐藤ら[佐藤 2018]は，業績等の記述のある決算短信や有価証券報告書に着目し，機械学習を用いて自動でテキストデータから投資判断に有用な情報として因果関係文を抽出することの出来るモデルを開発した．因果関係文は，出来事（結果）とその理由（原因）の組から構成される文と定義される．例えば，原因「猛暑」による結果「冷房需要の盛り上がり」等の因果関係を提示することで，「猛暑」の際には「冷房需要」が高まる可能性があるという情報を得ることが可能となる．このように因果関係文は，業績要因の分析など，主に過去に起きた事象に関する非数値情報として重要な情報であると考えられる．

しかしながら，過去に関する分析だけでなく，その企業がどのようなことを課題として認識し，それに対していつまでに何を実施していくのかなど，近い将来における取り組みに関する情報もまた，投資判断を行う上で必要不可欠な情報であろう．このような情報が記載されている開示書類として有価証券報告書が挙げられる．その中の「対処すべき課題」の項目には，「最近日現在における連結会社の事業上及び財務上の対処すべき課題について，その内容，対処方針等を具体的に記載すること」が法令によって定められている．さらに，投資家との対話促進の観点から，経営方針や経営環境に関する記述をすることが追加された．

将来における取り組みを含む特徴文を取得する際，単に未来に関する情報を含む特徴文を抽出するだけでは，その企業の取り組み以外の文も含まれ，一方で，その企業の取り組みに関する情報を含む特徴文を抽出するだけでは，過去に行った取り組みが取得されることが考えられる．つまり，未来における内容であり，かつ目的や取り組みについて記述しているという両方の特性を同時に保持している文を取得する必要がある．もし，このような企業の目的や手段を含み，将来時点で取り組む内容に関する情報を含む文を自動的に取得することが可能となれば，その企業が認識している課題，それらの課題に対する取り組みやその進捗を効率的に把握することが出来るだろう．さらに複数の企業のこれらの情報を網羅的に集約することが出来れば，財務指標の変化の予測や今後の業績の安定性，収益性の高低，ガバナンスの良し悪し等について，企業間や業種間での主観を排除した比較分析等に結びついていくはずである．

そこで，本稿では，有価証券報告書の「対処すべき課題」の項目から，未来に関する情報を含む特徴文を「未来表現文」，企業の目的や手段に関する情報を含む特徴文を「目的手段文」，これら2つの特徴を同時に持つ特徴文を「未来志向文」と定義し，これらの特徴文を自動的に抽出するモデルを開発し，その評価を行った．

連絡先：小寺　俊哉，日興リサーチセンター株式会社，〒103-0026　東京都中央区日本橋兜町 8-1

2. 未来志向文の抽出方法の全体像

本稿で提案する未来志向文の抽出モデルは，未来表現文抽出モデルと目的手段文抽出モデルの 2 つのモデルの組み合わせによって構築される．図 1 にテキストデータから各々のモデルを通して未来志向文が抽出される過程を示す．まず，テキストデータから不要な部分を取り除くフィルタリング処理が実行される．

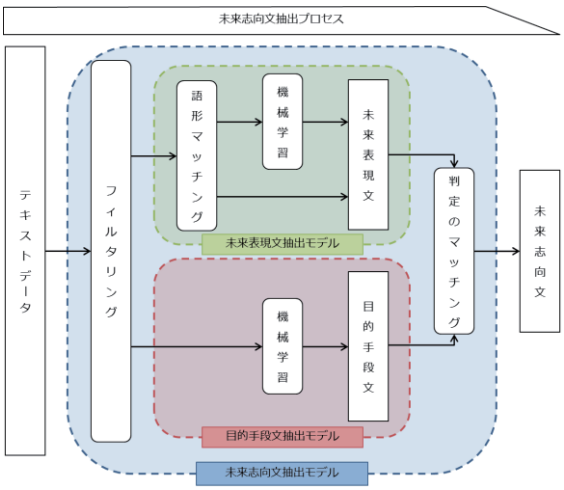


図 1　モデルによる未来志向文抽出プロセス

ここでは，文字数が 2 や 3 の極端に短い文や「【対処すべき課題】」の項目そのものを表すタイトル部分などが除外される．

次に，テキストデータは未来表現文抽出モデルと目的手段文抽出モデルにより各々の判定結果が付与される．それぞれのモデルの具体的な処理は後述する．最後に未来表現文と目的手段文の両方のモデルにおいて正例と判定されたものが未来志向文として抽出されることとなる．ここで，未来表現文とは未来に関する情報を含む特徴文であり，目的手段文とは企業の目的や手段に関する情報を含む特徴文のことである．また，未来志向文とは上記2つの特徴を同時に含む文の事である．各特徴文の例文を表 2 に示す．1 は豊田自動織機の 2017 年 3 月期，2 はデンソーの 2010 年 3 月期，3 は住石ホールディングスの 2009 年 3 月期，4 はヤマハ発動機の 2016 年 12 月期の有価証券報告書から抽出した特徴文を示している．本稿では，未来表現文，目的手段文，未来志向文それぞれにおいて当てはまるものを正例，当てはまらないものを負例と呼ぶこととする．なお，本抽出法は現在特許出願中である．

表 2　各特徴文の例文

No	未来表現文	目的手段文	未来志向文	例文
1	正例	正例	正例	・企業活動を通じて住みよい地球と豊かな社会づくりに取り組むとともに、クリーンで安全な優れた品質の商品を提供する。
2	正例	負例	負例	今後の世界経済については、引き続き内需が好調な中国を中心とするアジアが世界を牽引し、緩やかに回復が続き、先進国・新興国ともにプラス成長するものと見ています。
3	負例	正例	負例	事業環境の急激な変化にあっても、安定的な成長を続けるべく昨年 10 月より持株会社体制に移行しました。
4	負例	負例	負例	また、これらに限らず株式の買付行為の中には、その態様によっては、企業価値及び株主共同の利益を害するものも存在します。

2.1 利用データ

本稿では対象テキストとして有価証券報告書を用いた．対象期間は 2008 年～2018 年とし，各年において取得することの出来た各企業の本決算の有価証券報告書の PDF ファイルをテキスト化した．そして，それらの中から「対処すべき課題」及び「経営方針、経営環境及び対処すべき課題等」の項目を抽出した後，文単位に分割し，テキストデータとした．本稿では，学習データ及び評価データの文の抽出においては，より広範な表現に対応できるようにするために，有価証券報告書の時期や業種を分散させ，各特徴文についてそれぞれ 935 文(5 社×17 業種×11 年)を抽出した．ただし、評価データは，未来表現文，目的手段文，未来志向文において同じデータを用いてラベルを付与し，評価を行った．

3. 未来表現文の抽出方法

3.1 未来表現文のラベル付与

日本語においては，時制に関する定義が難しく様々な議論がなされている．例えば，龍城[龍城 2013]は，「特に日本語の場合は，良く知られているように，時間的概念の過去，現在，未来は存在するが，時制としては過去と非過去という 2 つの時制しかない．」と述べており，文中における節単位での時制転移について日英語を比較して議論している．このように日本語における時制の定義は，単純なルールに基づいて決定することは難しく，様々な要素から複合的に考える必要がある．その中で庵[庵 2001]は，文末の表現から日本語の時制に関して表 3 の様に分類できるとしている．

表 3　日本語のテンス及びアスペクトによる対立

テンス ＼ アスペクト	完了相	継続相
非過去	スル	シテイル
過去	シタ	シテイタ

これを元に考案した未来表現文のラベル付与に関するルールを図 4 に示す．本稿では文末が「“た。”」で終わるものをタ形，それ以外のものを基本形と呼ぶこととし，タ形のものであれば文脈に関わらず過去を示す文と判断し，未来表現文における負例とした．また，基本形の中で文末表現が「”致します。”，“参ります。”，“行います。”，“行う。”」及びそれらの平仮名表現のものは，常に未来に行う内容を含む文であると判断し，文脈に関わらず正例であるとした．例えば，「新製品の開発により成長機会を確保することに注力致します。」といった文がこれに該当する．

次に，上記 4 つ以外の完了相基本形について，厳密なルールに基づいて分類する方法が筆者らの知る限りでは存在しなかったため，文脈から人手によって正例負例を判断し，正例となる部分を完了相(未来)，負例となる部分を完了相(現在)と呼ぶこととした．

最後に，庵[庵 2001]では「—てい—」で示される継続相に着目し，その文の意味により以下の a~h に分類し，a~e は「継続」，f,g は「以前」のカテゴリとし，h は形容詞的用法として別物として扱っている．そこで本稿ではこれらを参考に，継続相基本形の文について，a~e に含まれる文を未来表現文の正例として，f~h に含まれる文を負例として人手によって判定し，ラベル付与することとした．

a. 進行中　　d. 効力持続　　g. 反事実
b. 結果残存　　e. 記録　　h. 単なる状態
c. 繰り返し　　f. 完了

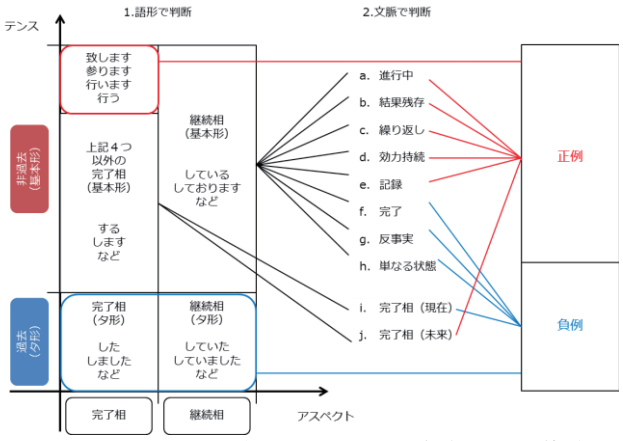


図 4　人手による未来表現文のラベル付与の判断基準

3.2 未来表現文の抽出

本稿では未来表現文の抽出を，「語形によるマッチング抽出」と「機械学習による判定抽出」の 2 つの手法を複合的に用いて行った．この抽出手法の全体像は図 5 に示す．まず，文末の語形のみによって，タ形にマッチングする文を負例に，「”致します。”，“参ります。”，“行います。”，“行う。”」及びそれらの平仮名表現を含む文を正例として抽出した．次に，これら以外の文に対して機械学習を用いて未来表現文の判定を行った．ところで，正例と判定した上記4つの文末表現に類似した表現は，同様に正例として判別されることが想定された．そのため，本稿では，酒井ら[酒井 2016]の手法を参考に，文末手がかり表現を自動的に獲得し，その情報を後述の機械学習による判定の素性として用いた．獲得手法の詳細は，同様の手法を用いている拙稿[小寺 2018]を参照されたい．

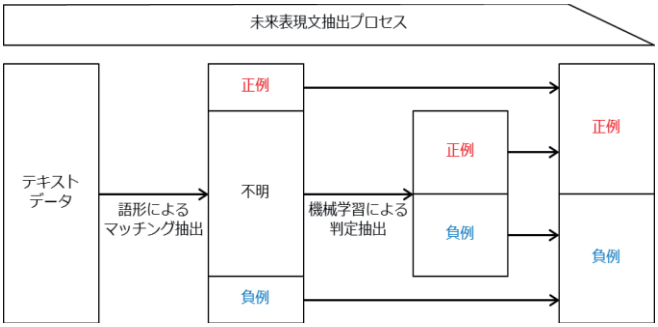


図 5　未来表現文抽出プロセス

(1)　語形によるマッチング

未来表現文の判定には文末の表現の特徴を利用した．例えば「参ります。」という表現であれば，その文はほぼ将来の取り組みについて記述されているため，この表現がある場合は正例と判断した．また，文末が「“た。”」のタ形の文は過去や現在までに完了した内容を示していると考えられるため負例と判断した．この文末の特徴を利用し，全てのテキストデータに対してまずは文末の表現を確認し「”参ります。”，“致します。”，“行います。”，“行う。”」及びそれらの平仮名表現のいずれかに合致するものは正例，文末の表現が「“た。”」に合致するタ形のものは負例と機械的に判定した．この文末表現の語形マッチングで判定出来なかったものに対して後述の機械学習の判定を行った．

(2)　機械学習による判定

機械学習による判別モデルを用いる際に，学習，評価及び学習後の判別処理において，文の特徴を表す素性が必要となる．本稿では表 6 に示す 9 種類の素性を利用した．素性の作成において，形態素解析では形態素解析器 MeCab [工藤 2004]を，構文解析では係り受け解析器 CaboCha [工藤 2002]を用いた．機械学習の手法としてサポートベクターマシン（SVM[*1]）を利用した．

[*1] 本稿では，python の機械学習のオープンソースライブラリである scikit-learn を用いた．
http://scikit-learn.org/stable/index.html

表 6　未来表現文抽出機械学習モデルの素性概要

素性の名前	概要
形態素ユニグラム	学習データに含まれる頻度 2 以上の形態素．
形態素バイグラム	学習データに含まれる頻度 2 以上の隣り合った形態素のペア．
文末手がかり表現	文末手がかり表現の自動獲得手法により得られた文末手がかり表現の内，学習データに含まれるもの．
共通頻出表現	文末手がかり表現の自動獲得手法により得られた共通頻出表現の内，学習データに含まれるもの．
副詞	学習データに含まれる品詞が副詞の形態素．
文末 2 文節	学習データに含まれる文末 2 分節のペア．
文末の品詞	学習データに含まれる文末の形態素の品詞．
句点の有無	文末に句点が存在するか否か．
文の属性	「タイトル」「箇条書き」「注記」「本文」のいずれの属性に属するか．

4.　目的手段文の抽出方法

4.1 目的手段文のラベル付与

日本語において，手段部分と目的部分をルールで分けることは出来ないため，文脈から判断し分類を試みると，図 7 の例文 1 に示すように，基本的には手段部分が目的部分に係るという係り受け構造が見られる．この例では「顧客の取り込み」が手段部分となり，「ユーザー数の拡大」が目的部分となる．

しかしながら，例文 2 や例文 3 のように，例えば例文 3 では「人員の流動化」が手段部分となり，目的部分「技術者の確保と適正配置の実行」に係る．ところが，この「技術者の確保と適正配置の実行」は手段部分として，「現場力の向上」を目的部分として係る．つまり，着目する語群は，係り受けの組合せ次第で，手段にも目的にも成り得てしまい，またこれらの事例は多数見られた．加えて，文頭の「現場支援体制を強化」が手段部分として同じく「現場力の向上」に係るといった入れ子の構造になる場合も多々存在した．このように，文中の手段部分や目的部分を厳密に分けることは難しいため，本稿では文中に目的もしくは手段の少なくともいずれかを含むものを正例として判定した．

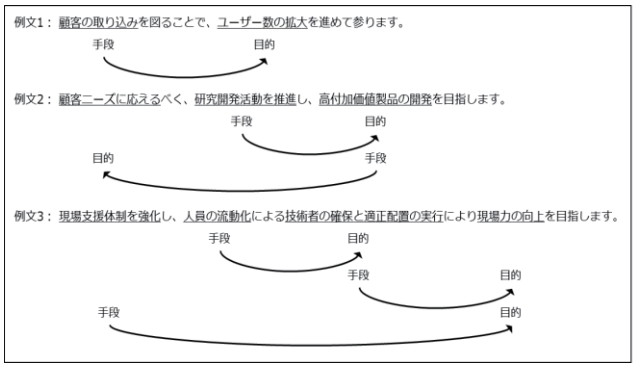


図 7　文中における目的と手段の関係性の構造

4.2 目的手段文の抽出

上述したように目的手段文の判定はルールベースで行えないため，機械学習での判定のみを行った．本稿では表 8 に示す 7 種類の素性を利用した．機械学習に入力する素性データは，未来表現文と同様の処理を行い作成した．ただし，ここでは

未来表現文の判定結果が目的手段文の判定にも関係のあるものとして素性に加えた．また，未来表現文と同様に機械学習手法としてサポートベクターマシン（SVM）を利用した．

表 8　目的手段文抽出機械学習モデルの素性概要

素性の名前	概要
形態素ユニグラム	表 6 の形態素ユニグラムと同様.
形態素バイグラム	表 6 の形態素バイグラムと同様.
読点の前の品詞	学習データに含まれる読点の前の形態素の品詞（読点が無い場合は読点無しという素性を加える）.
文末の品詞	表 6 の文末の品詞と同様.
句点の有無	表 6 の句点の有無と同様.
文の属性	表 6 の文の属性と同様.
未来表現文判定結果	未来表現文抽出モデルでの判定結果（正例か負例）.

5. 結果

表 9 は左上，右上，左下の順に未来表現文，目的手段文，未来志向文の抽出モデルの評価結果を示している．平均/合計の欄は，適合率，再現率，F 値については正例と負例の数で加重平均した値を，データ数，判定数については合計を示す．未来表現文抽出モデルと目的手段文抽出モデルのいずれにおいても正例の判定で適合率，再現率，F 値それぞれで 0.9 を超える非常に高い評価結果であった．また，負例においても最低でも 0.765 と，ある程度高い水準を示した．平均をみると全ての評価指標で 0.9 前後であった．同様に，未来志向文抽出モデルでは，正例はいずれの評価指標においても 0.9 を超える高い性能を示した．一方で，負例においても全ての指標で 0.8 を上回る良好な性能を示した．また，平均をみると全ての指標が 0.9 を上回った．

表 9　各抽出モデルの評価結果

	適合率	再現率	F値	データ数	判定数
正例	0.936	0.993	0.964	726	770
負例	0.970	0.766	0.856	209	165
平均/合計	0.944	0.942	0.940	935	935

	適合率	再現率	F値	データ数	判定数
正例	0.936	0.924	0.930	714	705
負例	0.765	0.796	0.780	221	230
平均/合計	0.896	0.894	0.895	935	935

	適合率	再現率	F値	データ数	判定数
正例	0.918	0.964	0.940	631	662
負例	0.916	0.822	0.867	304	273
平均/合計	0.918	0.918	0.916	935	935

左上：未来表現文抽出モデル
右上：目的手段文抽出モデル
左下：未来志向文抽出モデル

6. 考察

表 9 に示すように，未来表現文抽出モデル，目的手段文抽出モデル，未来志向文抽出モデルそれぞれの判定性能は良好なものであった．一方で，データの特性として，どのタイプの抽出文においても正例が多く負例が少ないという偏りがあった．つまり，すべて正例と判定すればそれだけで正解しやすくなるためモデルが高性能に見えてしまう懸念があった．しかしながら，全てのモデルについて判定数とデータ数に大きな乖離は無いため，むやみに正例と判定したことによって高い性能を示している訳ではなく的確に判定できていると言えるだろう．さらに，興味深い点として，未来志向文における負例の再現率と F 値の評価指標が，未来表現文及び目的手段文のそれよりも高い値を示した．これは未来志向文抽出モデルでは，未来表現文抽出モデルと目的手段文抽出モデルの両方で正例とならない限り正例と判定されないために，いずれかのモデルにおいて実際に負例のものを正例と誤判定したとしても，もう片方のモデルで適切に判定できれば，相補的に誤判定された文を負例にしたと考えられる．本稿の目的として，企業が今後取り組む課題やその対処を記述した特徴文の抽出を試みた．その際の仮説としてそれらの特徴文は，課題や取り組みを含み，かつ未来に関する記述であることを含んでいるとし，その方法として各々を独立に評価し，最後に総合的に評価することで目的の達成を試みたが，これらのアプローチが有効であったことの証左であり，同時に二つの機械学習を組み合わせて判別するアプローチの有効性も示すことが出来た．

7. おわりに

本稿では，目的表現や手段表現を含みかつ未来を表現している文を未来志向文と定義し，自動で抽出するモデルを構築し，有価証券報告書の「対処すべき課題」の項目から未来志向文の抽出を行った．本稿の提案モデルは，適合率，再現率，F 値の平均でいずれの評価指標でも 0.9 を超える非常に高い性能を示した．また，この評価の内訳として未来表現文と目的手段文の各抽出モデルの評価を確認すると，負例の再現率，F 値において互いのモデルの誤判定を補う形で評価を向上させることが分かった．

今後は，未来志向文から見た業種の特徴を定量的に分析することや，同業他社間での類似する未来志向文を抽出し各社の取り組みの機微な違いを比較分析等を行うなど，抽出した未来志向文を活用した分析を行うとともに，未来志向文の有効性を示していきたい．

参考文献

[庵 2001] 庵功雄: テイル形，テイタ形の意味の捉え方に関する一試案，一橋大学留学生センター紀要，(4)，pp. 75-94 ，(2001)．

[工藤 2002] 工藤拓，松本裕治: チャンキングの段階適用による日本語係り受け解析，情報処理学会論文誌，Vol.43，No.6，pp. 1834-1842，(2002)．

[工藤 2004] 工藤拓，山本薫，松本裕治: Conditional Random Fields を用いた日本語形態素解析，情報処理学会研究報告自然言語処理 (NL)，Vol.2004，No.47，pp. 89-96，(2004)．

[小寺 2018] 小寺俊哉，佐藤史仁，田中良典: テキストマイニングによる有価証券報告書の因果関係文以外の特徴文の抽出，日興リサーチレビュー，2018 年，1 月号，(2018)．

[酒井 2016] 酒井浩之，柴田宏樹，平松賢士，坂地泰紀: アナリストレポートからのアナリスト予想根拠情報の抽出，第 17 回金融情報学研究会，pp. 25-30，(2016)．

[坂地 2015] 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)．

[佐藤 2018] 佐藤史仁，佐久間洋明，小寺俊哉，田中良典，坂地泰紀，和泉潔: 有価証券報告書からの因果関係文の抽出，人工知能学会全国大会論文集 JSAI2018，2O404，(2018)．

[龍城 2013] 龍城正明: 日英語節複合における時制表現に関する考察:話者の状況の視点という概念を通して，同志社大学英語英文学研究，90，pp. 190-216，(2013)．

General Session | General Session | [GS] J-13 AI application

[2O3-J-13] AI application: investments

Chair:Takanobu Mizuta Reviewer:Shinobu Hasegawa

Wed. Jun 5, 2019 1:20 PM - 2:40 PM Room O (Front-left room of 1F Exhibition hall)

[2O3-J-13-01] Analysis of Posted Price as a Determinant of Office Rent

○Yoshiteru Osawa[1], Yoshinao Ebina[1], Mayuko Tahara[2], Katsutaka Bunya[2], Takahiro Hoshino[2,3] （1. Mitsubishi UFJ Trust and Banking Corporation, 2. Faculty of Economics, Keio University, 3. RIKEN Center for Advanced Intelligence Project）

1:20 PM - 1:40 PM

[2O3-J-13-02] Analysis of Chain Bankruptcy Using Multilayer Networks Simulation among Banks and Companies

○Ryo Hamawaki[1], Junnichi Ozaki[2], Kiyoshi Izumi[1], Takashi Shimada[1], Hiroyasu Matsushima[1], Hiroki Sakaji[1] （1. The University of Tokyo, 2. Tokyo Institute of Technology）

1:40 PM - 2:00 PM

[2O3-J-13-03] What is a Hedge or Safe Haven Asset for Bitcoin Investors?

○Ryuta Sakemoto[1,2], Alden Ho[1], Yoshihiko Ichikawa[1] （1. YJFX, Inc, 2. Keio Economic Observatory Keio University）

2:00 PM - 2:20 PM

[2O3-J-13-04] Construction of Causal Networks for Risk Finding Considering Word Polarities

○Hiroaki IGARASHI Igarashi[1], Hiroki Sakaji[1], Kiyoshi Izumi[1], Takashi Shimada[1], Shintaro Suda[2] （1. the University of Tokyo, 2. Mitsubishi UFJ Trust Investment Technology Institute Co., Ltd.(MTEC)）

2:20 PM - 2:40 PM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

REIT 保有不動産を使用した賃料推計モデルの作成

Analysis of Posted Price as a Determinant of Office Rent

海老名喜直[*1] 大沢賢輝[*1] 田原万悠子[*2] 文屋克隆[*2] 星野崇宏[*2*3]
Yoshinao EBINA Yoshiteru OSAWA Mayuko TAHARA Katsutaka BUNYA Takahiro HOSHINO

[*1] 三菱 UFJ 信託銀行株式会社
Mitsubishi UFJ Trust and Banking Corporation

[*2] 慶應義塾大学経済学部
Faculty of Economics, Keio 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

Predicting expected office rent obtained from a land can be utilized for making investment decisions. Previous research showed that fluctuation of office rent differs in new and renewal contracts. In order to accurately predict office rent, paid rent which is an indicator of rental price in both contracts should be considered as an important determinant of office rent. In this research, posted price is used to calculate the paid rent and estimate the office rent by conducting multiple regression analysis. We present posted price is strongly correlated with rent and effective for prediction of rent.

1. はじめに

不動産投資家にとって、不動産投資における主な収益源である賃料は大きな関心事である。ある土地から将来得ることができる賃料を事前に把握することで、投資判断に資することができる。

投資用不動産が存在する「土地」に着目をすると、その地価と賃料には密接な関係がある。すなわち、地価の算出方法の一つである「収益還元法」は、「地価はその土地から将来得られる収益の合計を一定の金利条件において現在価値に割り引いたもの」とする考え方である。ただし、実際に取引される土地の価格は個別的な事象にも影響を受け、収益還元法による地価と実際の取引価格は一般に乖離するため、地価と賃料の相関にも個別的な事象が影響していることが言える。

また、需要面から考えると、不動産の賃料は立地や物件の特徴によって決定される。立地に関していえば、地域ごとに平均的な賃料の相場が形成されるほか、物件固有の情報として最寄り駅からの距離や周辺地域の環境などが賃料に影響を与えるといわれている。また、物件の特徴としては、築年数や階数、建物構造などが挙げられる。

例えば下向井(2013)は、東京都区部におけるオフィス賃貸契約の成約賃料について、1999 年から 2002 年までと、2009 年から 2012 年までの 2 つの期間において賃料モデル推定をそれぞれ作成し、各説明変数の説明力が 2 つのモデルで変動すること、また後者のモデルで決定係数が低下した原因として、モデルに組み込んでいない要因の影響が相対的に強くなったと報告している。

また、同一の不動産であっても、賃料を決定する要因は景気によっても変動することが知られている。Barrett (2000)は、1991 年 1 月から 1996 年 9 月までのアメリカ・フェニックスにおけるオフィス賃料データを用いて、ヘドニックアプローチによる賃料推計モデルを作成し、モデルにおける平均床面積、階数、築年数等の各説明変数の説明力が、景気の後退期、不況期、回復期によってそれぞれ変動することを示している。

一方、不動産投資の観点からは、新たに契約された不動産の賃料である成約賃料とは別に、「継続賃料」も考慮する必要がある。中山ら(2015)は、東京 23 区内のオフィスビルを対象に、新規賃料と継続賃料の両方を加味した「支払賃料」のインデックスを作成し、支払賃料の推移が新規賃料に対し 1 年から 1 年半ほど遅れるという遅行性と、契約更新時には賃料の変更が起こりにくいため支払賃料の変動幅が小さいという粘着性があることを示した。

個別不動産の支払賃料を把握することができる情報の一つに、不動産投資証券（J-REIT）が年に 1 回または 2 回の決算期において公開している有価証券報告書がある。この有価証券報告書には、決算対象期間における保有物件ごとの賃料収入や貸付面積、稼働率等が記載されている。これを利用することで、各物件の単位面積ごとの支払賃料収入を求めることができる。

連絡先：三菱 UFJ 信託銀行株式会社 大沢賢輝
（e-mail:yoshiteru_osawa@tr.mufg.jp）

そこで本研究では、J-REIT から求められた支払賃料について、土地の公的な評価額である「公示価格」をベースとし、駅からの距離や建物の性質等の個別事象を反映した賃料推計モデルを作成した。

2. 使用データ及び分析対象

2.1 使用データ

本研究に使用したデータは以下のとおりである。

(1) J-REIT が保有する不動産データ

J-REIT とは、投資法人が個人や企業などの投資家から資金を集め、不動産の購入・管理・運用を行い、その収入から得られた利益を投資家に分配する仕組みの投資法人である。J-REIT は情報開示事項として有価証券報告書の提出が義務付けられており、決算期間において物件から得られた賃料収入や費用を公開している。

J-REIT が保有する物件はマンションなどの共同住宅やオフィスビルの他、商業施設やホテル、物流施設など多岐にわたる。表 1 に、2007 年～2018 年の間に J-REIT に保有された期間のある物件の特徴を示す。なお、J-REIT が公開している保有物件の用途には、同一物件に「事務所・店舗」など複数の用途が設定されていることもあるため、この場合は重複してカウントしている。

表 1:J-REIT 保有物件の特徴

用途別件数（上位 5 つ）	
共同住宅	2,197 件
事務所	1,517 件
店舗	1,335 件
駐車場	779 件
倉庫	431 件
地域別件数	
都心 5 区※	1,266 件
東京 23 区（都心 5 区除く）	1,055 件
関東（東京 23 区除く）	895 件
近畿	579 件
その他	958 件

※東京都渋谷区、新宿区、中央区、千代田区、港区

分析においては、2007 年～2018 年において J-REIT に保有された期間のある物件について、以下のデータを使用する。

- 住所
- 建物用途
- 賃貸事業収入
- 貸付可能面積
- 稼働率（貸付可能面積のうち、貸付面積の割合）
- 修繕費
- その他各種属性（築年数などの賃料に影響を与えうる変数）

なお、被説明変数である単位面積当たりの賃料は、賃貸事業収入、期末貸付可能面積、期末稼働率、営業日数をもとに算出している。

(2) 公示価格

公示価格とは毎年 3 月下旬ごろに国土交通省により公示される土地の公的価格の一つである。公示される地点は個別的な事象が介入しないよう、地域の標準的な地点が国土交通省により選ばれる。また、建物の価値を除外するために土地を更地とみなしたうえで不動産鑑定士が鑑定評価を行う。本研究では、以下の情報を利用する。

- 住所
- 基準日（毎年1月1日）
- 単位面積あたりの土地価格

なお、一般に公示価格の標準地点と分析対象不動産の位置は一致しない。そのため、分析対象の地価は近接する複数の標準地点を基に補正を行った額としている。

(3) その他

前述データの他、物件の住所から求めた最寄駅からの距離等、賃料に影響を与えうる変数を求め、分析に用いる。

2.2 分析対象

(1) 建物の用途による抽出

J-REIT が保有する物件の用途は多岐にわたるが、同じエリアの類似物件であっても、建物用途ごとに賃料が異なる可能性がある。また店舗として運用されている物件については、大型スーパーなのか小型店舗の集合なのかによっても単位面積当たりの賃料は変わることが想定される。したがって、分析においては十分なデータ数のある共同住宅および事務所に限定した。

(2) 稼働率の変動が大きい物件の対応

J-REIT が公開する有価証券報告書からは各期中の物件ごとの賃料収入および各期末の貸付面積を取得することができるが、期中に入居者やテナントが退去した場合、退去時期によって賃料収入が変動する。また、各期末の貸付面積からは期中の貸付面積の変動をとらえることはできない。すなわち、稼働率が大きく変動した場合、単位面積当たりの賃料を正しく求めることができなくなる。

また、事務所が主なテナントであるオフィスビルにおいては、新規契約時に一定期間賃料を徴収しない、フリーレントと呼ばれる期間を設定することがある。これは貸主が賃料を下げずに新規テナントを募集するなどを目的として行われるが、フリーレントが設定されているテナントが存在する場合、そのテナント分の賃料収入は得られない一方、貸付面積には含まれることとなる。

そこで分析においては、稼働率が大きく変動した場合など、単位面積当たりの賃料を推計することができ

ないデータについては、データの除外や外部データによる補正等を行っている。

3. 推計手法

推計モデルには、公示価格を含む賃料に影響を与えうる特徴量を説明変数として重回帰分析を用いた。使用する各特徴量のモデルへの寄与率を確認し、推計モデルの決定係数が一定以上になることによって、今回作成したモデルの妥当性を検証する。

作成したモデルによる推計結果については当日示す。

参考文献

下向井邦博(2013).「第1章 オフィス賃料推計モデルにおける賃料決定要因の変化の考察」,『都市未来総合研究所 不動産レポート2013』, pp.5-26.

中山善夫,大西順一郎(2015).「新規賃料と継続賃料の両方を含む新しいオフィス賃料指数 ～ザイマックス支払賃料インデックスの紹介～」,『ARES 不動産証券化ジャーナル Vol.28』, pp.58-63.

Barrett A. Slade(2000). "Office Rent Determinants during Market Decline and Recovery," Journal of Real Estate Research, American Real Estate Society, vol. 20(3), pp.357-380.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

銀行間と企業間の多層ネットワーク・シミュレーションによる連鎖破綻の解析

Analysis of Chain Bankruptcy
Using Multilayer Networks Simulation among Banks and Companies

濱脇　諒 *1　尾崎　順一 *2　和泉　潔 *1　島田　尚 *1　松島　裕康 *1　坂地　泰紀 *1
Ryo Hamawaki　Junichi Ozaki　Kiyoshi Izumi　Takashi Shimada　Hiroyasu Matsushima　Hiroki Sakaji

*1東京大学大学院　工学系研究科
School of Engineering, The University of Tokyo
*2東京工業大学　科学技術創成研究院
Institute of Innovative Research, Tokyo Institute of Technology

Recent globalism of economic makes the effect of a certain small bankruptcy enhance internationally beyond of the area and country. So, we propose the model in which the interaction between banks and companies is focused and simulate and consider the effect of whether banks invest the funds or not to the growth of companies. In particular, by varying the width of change of the growth rate of companies according to whether they are invested, we researched the difference in the distribution of the final size of companies. The model of banks is based on actual data such as financial statement analysis edited by Japanese Bankers Association. As the results, the investment of banks did not raise the mean of growth rate but widened the disparity in size among companies. As future plans, we'd like to reproduce and analyze the cause of large chain bankruptcy using the extended model.

1.　はじめに

近年の経済のグローバル化により，特定の企業や業界で起こった破綻や倒産のリスクがその業界および国を超えて国際的に影響を与えることが起きている．これらはシステミックリスクと呼ばれ，関連する研究が近年注目を浴びている [永田 13]．

システミックリスクに関わる研究として，銀行間ネットワークに着目した研究がある．今久保ら [今久保 08] では，銀行間のコール市場におけるネットワーク構造の特徴を明らかにしている．橋本ら [橋本 17] では，複数の種類のネットワークを用いて，破綻の連鎖を説明し，予測を行なっている．前野 [前野 13] では，各銀行が貸借対照表を持つことで，資金貸出先の倒産による自己資本の毀損によって銀行が連鎖的に倒産していく様子を再現し，連鎖倒産リスクが高くなる条件をまとめている．また，企業についても，田村ら [田村 14] は企業間での活動に着目し企業間の発注下請け関係をリンクとしたネットワークとして見ることで，資金の流れに着目する研究を行なっている．

しかし，今久保らは銀行のネットワークについての実証研究でありシミュレーションの研究は行なっていない。橋本らは銀行のみのシミュレーションであり，銀行の主業務である融資についての考慮がなされていない。前野では独自のモデルで銀行のバランスシートを作成していて，現実のデータと整合性が取れるかの検証がなされていない．企業についても、田村らは銀行に触れておらず，企業のみの活動に着目していて，銀行との融資関係までをモデル化したものは少ない．

そこで，本研究では，銀行と企業の活動の相互作用に着目したモデルを提案し，銀行からの投資の有無が企業の成長に与える影響についてシミュレーションした結果を考察する．

2.　モデル

本モデルは，大きく分けて 3 つの構成要素から成る: 1. 銀行 100 行; 2. 企業 100 社; 3. 株式市場 40 銘柄．

銀行に関する詳細については，2.1 節と 2.2 節，企業については 2.4 節，株式市場については 2.3.2 節の中で述べていく．

連絡先: 濱脇　諒，東京大学大学院工学系研究科，東京都文京区本郷 7-3-1，03-5841-1867，1996rhamawaki@gmail.com

2.1　銀行間ネットワーク

銀行間ネットワークは銀行同士の貸借関係を表したものであり，各銀行をノードとし貸借関係をリンクとしている．本モデルでは，コアペリフェラルネットワークを用いて実験を行う．コアペリフェラルネットワークは実際の日本における銀行間の貸借関係で観測されたもので [今久保 08]，以下のような特徴を持つネットワークである: 1. コアと周辺という 2 重構造; 2. コア内は完全ネットワークに近い; 3. コアは周辺に対するハブとなっている; 4. 周辺はクラスター化している．

銀行 i から銀行 j への初期の貸借額 $Lend_{i,j}$ は式 1 を用いて算出した [前野 13]．

$$Lend_{i,j} = \frac{{}^{out}k_i^r \ {}^{in}k_j^r}{\sum_{i=1}^{N}\sum_{i\neq j} {}^{out}k_i^r \ {}^{in}k_j^r} L \tag{1}$$

ここで，${}^{out(in)}k_i$ は銀行 i が貸出 (借入) を行っている銀行数，N は総銀行数，L は総貸出数，r は貸借額の偏りを表しているパラメータである．式 1 は自分の貸出先が多ければ多いほど，また，貸出先の借入先が多ければ多いほど貸出額が大きくなることを意味している．

2.2　貸借対照表

各銀行は資金の貸し借りや株式市場のような有価証券の管理を貸借対照表を用いて管理する．今回使用する項目は以下の 7 つである

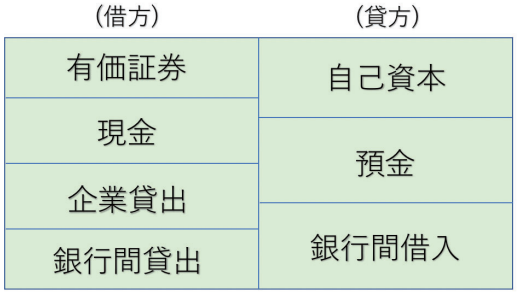


図 1: 貸借対照表の項目

まず，式 1 で各銀行間の貸出と借入が決定される．

次に，全国銀行協会が公表している全国銀行財務諸表分析より，日本における銀行の貸借対照表をもとにノンパラメトリック手法であるカーネル密度法を用いて実データから有価証券，現金，自己資本，預金の割合を決定する．

2.3 銀行と企業の連携

2.3.1 銀行から企業への貸出

銀行は 1 年に一度余剰資金を企業へ貸し出す．余剰資金 $surplus$ は式 2 によって決定される．

$$\begin{aligned} surplus &= \left\{ [\text{現金}] + min\left(0.5\,[\text{有価証券}], \frac{15.0}{85.0}\,[\text{現金}]\right)\right\} \\ &= -\{0.05\,(0.6\,[\text{預金}]) + 0.4\,(0.4\,[\text{預金}]) \\ &\qquad + 0.3\,(0.35\,[\text{企業貸出}])\} \end{aligned} \tag{2}$$

式 2 は国際決済銀行が世界の銀行に求めているバーゼル規制に基づくものであり，流動性破綻を防ぐため，最低限持っておくべき現金の量を表している．本モデルでは，この量の半分を 1 年に 1 度企業に貸し出すこととしている．

また，その貸出先は規模が上位 30 社の企業の中からランダムに決定される．

2.3.2 株式市場とファンダメンタル価格

本モデルには株式市場が存在し，40 種類の銘柄が各銀行によって売買されている．この売買には鳥居らのモデル [鳥居 15] を使用していて，各銀行はその銘柄の本質的な価値と値動きのトレンドを見て取引を行う．

各株式の時刻 t における価格 p_t は式 3 によって決定される．

$$p_t^i = p_{t-1}^i + \alpha(n_{b,t-1}^i - n_{s,t-1}^i) + \beta growthrate_{t-1}^i \tag{3}$$

$n_{b,t}^i$ は時刻 t に購入された株式 i の数，$n_{s,t}^i$ は時刻 t に売却された株式 i の数，$growthrate_t^i$ は時刻 t における企業 i の成長率を表している．需給の差と成長率に比例して価格が変動するモデルとなっている．α, β はそれぞれ需給の差と成長率の影響を統制する定数であり，今回は全ての実験において一定としている．

2.4 企業の成長モデル

各企業は 1 年に一度以下の分布にしたがって生成された値を成長率として規模を拡大させる．この成長率は 1 年毎の企業の規模の対数差分として定義する．企業の成長率 g の分布 $P(g)$ は坂井ら [坂井 12] によると以下の分布に従うことが知られている．

$$P(g) = \frac{2V}{\sqrt{g^2 + 2V}(|g| + \sqrt{g^2 + 2V})} \tag{4}$$

V は以上の分布の分散を表すパラメータである．以上の分布は，$g \to 0$ 付近ではラプラス分布に従い，$g \to \infty$ ではべき分布で近似されることを意味している．また，規模の大きな企業は分布の中央に多く，テール部分には規模の小さな企業の成長率が反映されている．

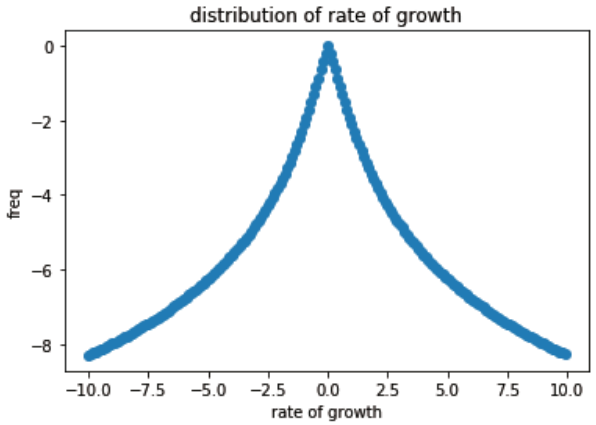


図 2: 企業の成長率の分布

3. シミュレーション

3.1 実験の目的

各企業の規模に焦点を当てる．

一般に，企業は設備拡張や新規事業開発のために銀行から融資を受け資金を調達する．この投資による影響として，銀行の主業務の 1 つである融資が企業の成長にどの様なを作用をするのかを調べ，モデルの妥当性を検証する．

3.2 実験の詳細

シミュレーションは図 3 のフローに従って行われる．

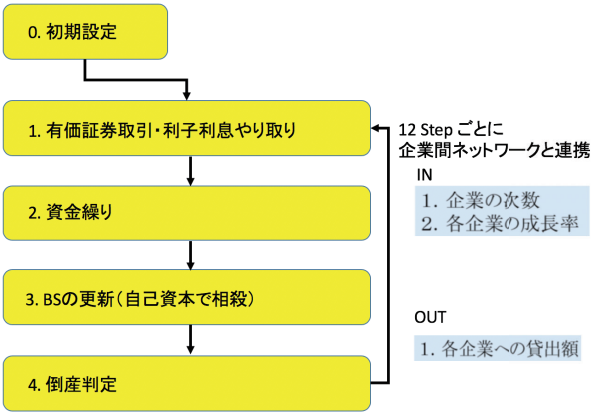


図 3: 貸借対照表の項目

図で示されるフローを 1 ステップとし，これを 12 ステップ繰り返す．12 ステップ終了後に前述のアルゴリズムにしたがって，各銀行は企業へ貸し出す額を決定する．その貸出額を受け取って各企業の成長率が決定され，成長率から企業の規模が求められる．以上の行動を 1 セットとして本シミュレーションでは 10 セット行う．

10 セット終了後の企業の規模の分布について以下の 3 パターンの成長率の決定方法で実験し比較を行う．

成長率は 2.4 節で述べた確率分布から取得するが，平均 0 の両側何% の範囲で乱数が動くかを変化させる．

1. 両側 20%
2. 企業の規模 $size$ に反比例する値 $width = \frac{1}{2\sqrt{size}}$

3. パターン 2. に投資の額に応じた係数を加算した値

企業の投資の 1 つである設備投資は一般に，供給力の増大が期待される一方で，在庫リスクの拡大や市場の効率性が損なわれる可能性がある [比佐 07]．これをモデルに組み込むため，パターン 3. の投資の額に応じた係数は，小規模の投資の時 5%，大規模の投資の時 7.5% とし，投資の規模が大きくなるにつれて，不安定な成長となるモデルとした．

各実験を 30 試行ずつ行い，最終的な企業の規模の初期値からの成長率を調べた．また，それぞれのパターンの成長率の分布について，正規分布と言えるかどうかを調べる Shapiro-Wilk 検定を行った．

3.3 実験結果

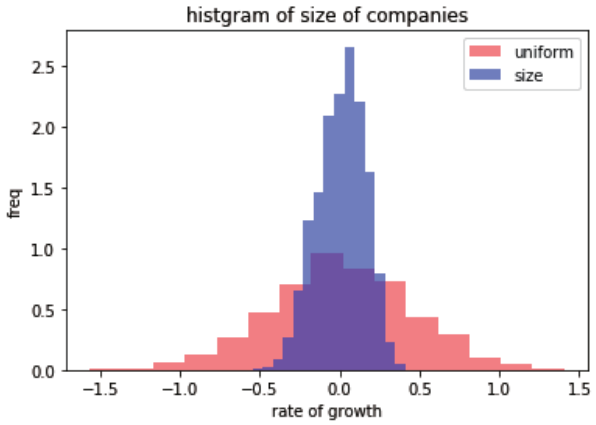


図 4: 成長率の頻度分布の比較その 1

図 4 は，パターン 1(uniform) の時とパターン 2(size) の時の最終的な成長率の頻度分布を正規化したものである．パターン 1 では成長率が −1.0 から 1.0 の範囲で正規分布の様な分布で広がっているのに対し，パターン 2 では 0 付近の値に集中する結果となった．

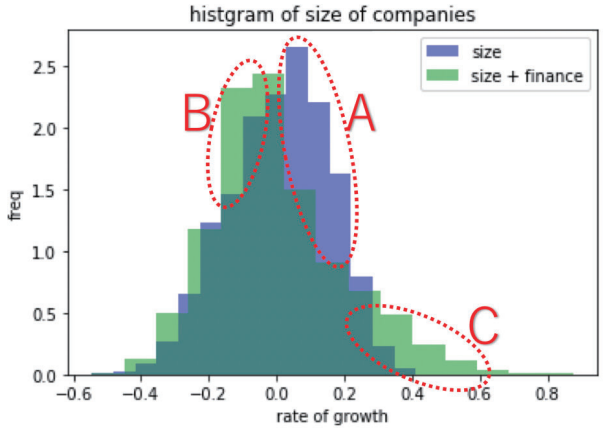


図 5: 成長率の頻度分布の比較その 2

図 5 は，パターン 2(size) の時とパターン 3(size + finance) の時の最終的な成長率の頻度分布を正規化したものである．パターン 2 よりもパターン 3 の方が最頻値が負の方向に移動していることが見て取れる．平均値もパターン 2 の時が 0.0078，パターン 3 の時が 0.0025 であり，若干ではあるが減少していた．

次に，各パターンについて Shapiro-Wilk 検定の結果を示す．それぞれの p 値は表 3.3 のとおりであった．

表 1: 各パターンにおける Shapiro-Wilk 検定の p 値

	パターン 1	パターン 2	パターン 3
p 値	0.282	1.51×10^{-15}	8.3×10^{-32}

4. 考察

4.1 パターン 1 と 2 の比較

まず，パターン 1 の時とパターン 2 の時の差異について考察を行う．本モデルでは成長率を各年の規模の対数差分としているため，n 年の成長率を g_n とすると，10 年目の各企業の規模 $size_{10}$ は以下の様に表される．

$$size_{10} = size_0\ e^{g_1} e^{g_2} \cdots e^{g_{10}} = size_0\ e^{\sum_{k=1}^{10} g_k} \qquad (5)$$

さらに，パターン 1 においては g_k は図 2 の中心から両側 20% の同じ分布から成長率を取得している．よって，中心極限定理より式 5 の指数部分は正規分布に従うことが示され，シミュレーションの結果も表 3.3 より，Shapiro-Wilk 検定の p 値が 0.05 より大きくなっており，正規分布であるという帰無仮説は棄却されず，整合的な結果となっている．

一方で，パターン 2 の時は企業の規模の初期値を 100 としたため，大抵の企業が安定的な成長しかせず，大きく成長するものや急速に規模が縮小する様なものが現れず，$g = 0$ の周辺に集中してしまったということが言える．Shapiro-Wilk 検定の p 値も 0.05 より小さくなり，正規分布であるという帰無仮説は棄却される．

4.2 パターン 2 と 3 の比較

次に，パターン 2 の時とパターン 3 の時について考察を行う．

パターン 3 もパターン 2 と同様に企業の規模が成長率に影響を与えるモデルであるので，$g = 0$ の周辺に成長率が集中していることが言え，また，Shapiro-Wilk 検定より正規分布であるという帰無仮説も棄却される．

しかし，図 5 を見るとパターン 2 とパターン 3 の分布に差異を確認することができる．それは赤い点線で囲まれた 3 つのエリアである．パターン 2 では観測されるエリア A の分布がパターン 3 ではエリア B とエリア C に移動している．この部分が投資による率への成長率への影響と考え，考察を行う．

4.1 節で行なった考察をもとに考えると，エリア A にあった企業は規模が大きく安定的な成長をしていた企業である．本モデルでは，銀行が余剰資金を投資している企業は規模の上位 30 社としたため，エリア A の企業も投資対象になりうる．

ここで，投資を受けた時企業は高いリターンを得られるかもしれない一方で，規模が縮小してしまうかもしれないリスクを負う様なモデルとしたため，エリア A にいた企業が成長を遂げることができ，エリア B に移動したものと規模が縮小しエリア C に移ったものの 2 つに分かれたことが図 5 からうかがえる．

そこで，パターン 2 とパターン 3 の平均値を比較してみると，パターン 2 の方が若干大きくなったものの最終的な企業の規模に変換するとパターン 2 の時が 100.8 に対し，パターン 3 の時が 100.3 となり，大差はなかったことがわかる．つまり，本モデルでは銀行の企業への投資は企業の集合全体での成長率の平均には影響を与えないが，企業の成長率の分布には影響を与え，企業間での格差が広がる方向に作用するという結果となった．

5. まとめと将来の展望

5.1 まとめ

本研究では，銀行と企業の相互作用について研究を行うためのモデルの提案とそれを用いた実験を行った．

モデルとしては，銀行間ネットワークの作成に日本のコール市場に見られた特徴を反映したコアペリフェラルネットワークを用い，各銀行の貸借対照表は全国銀行協会の全国銀行財務諸表分析の分布をもとに作成し，データ・ドリブン志向のモデルを構築した．

また，このモデルを使った実験では銀行から企業への投資が企業の成長率にどの様な影響を与えるかについて，シミュレーションを行った．その結果，銀行の投資は企業の成長率に対して，全体の平均を上げ成長を促すという効果は得られなかったが，企業間の格差を拡大させるという結果となった．具体的には，投資を受けて成長できた企業とそうでなかった企業の 2 群に分布が分かれた様子が確認された．

5.2 将来の展望

将来の展望としては，今回時間依存しない確率モデルで成長率をおいた企業側の部分のモデルについて，銀行間ネットワークと同様にエージェントベースのシミュレーションに拡張する．各企業をノードとし，企業同士の活動をリンクとしたネットワークを作り，企業同士の相互作用も考慮することが狙いとなっている．これにより，ある企業への銀行の投資がその企業とつながっている企業への好影響をもたらし，投資の影響が伝播していく様子や反対に，投資していた企業の倒産が銀行の倒産を招き，大きな連鎖倒産を引き起こしてしまうといったシステミックリスクが生じるメカニズムを再現し分析できる．

参考文献

[永田 13] 永田 裕司 : システミック・リスクと金融の脆弱性, 福岡大学商学論叢, Vol. 57, No. 3-4, pp. 253–272 (2013)

[橋本 17] 橋本 守人, 倉橋 節也 : 資金取引ネットワークモデルに基づく連鎖破綻リスク分析, 人工知能学会論文誌, Vol. 32, No. 5, pp. B–H21_1 (2017)

[今久保 08] 今久保 圭, 副島 豊 : コール市場の資金取引ネットワーク, 金融研究, Vol. 27, No. 2, pp. 47–100 (2008)

[坂井 12] 坂井 功治, 渡辺 努 : 企業成長率分布の統計的性質と含意, 経済学論集, Vol. 78, No. 3, pp. 2–13 (2012)

[前野 13] 前野 義晴 : 金融システムを安定化する最適な投融資ポートフォリオと銀行間ネットワーク, 人工知能学会 金融情報学研究会 (2013)

[鳥居 15] 鳥居 拓馬, 中川 勇樹, 和泉 潔 : 複数資産人工市場を用いた裁定取引によるショック伝搬の分析, 人工知能学会全国大会論文集 2015 年度人工知能学会全国大会 (第 29 回) 論文集, pp. 1J4OS13a2–1J4OS13a2 一般社団法人 人工知能学会 (2015)

[田村 14] 田村 光太郎, 高安 美佐子 : 企業間取引ネットワーク上でのお金の流れのモデル化とシミュレーション, シミュレーション, Vol. 33, No. 4, pp. 262–268 (2014)

[比佐 07] 比佐 章一 : 日本企業における設備投資行動の不安定性とその決定要因–横並び行動の検証と所有構造の影響, 日本経済研究, No. 57, pp. 1–22 (2007)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

What is a Hedge or Safe Haven Asset for Bitcoin Investors?

Ryuta Sakemoto [*1,2] Alden Ho [*1] Yoshihiko Ichikawa [*1]

[*1] YJFX, Inc [*2]Keio Economic Observatory Keio University

This paper investigates a hedge and safe haven asset for Bitcoin investors. Bitcoin has been receiving high attention from finance investors because of its high upside return and volatility. The recent finance literature focused upon Bitcoin characteristics as an alternative asset. We take Bitcoin investors' perspectives and consider how to manage the high volatility of Bitcoin. We employ the definitions of hedge and safe haven based on the finance literature and conduct the respective statistical analyses. Our definition distinguishes a weak and strong hedge (safe haven). Our empirical results show that traditional assets such as global equities and global bonds are weak hedges for Bitcoin. Furthermore, we observe that gold acts as a strong hedge against Bitcoin during an extreme bearish Bitcoin market, although the impact is marginal. There is no strong safe haven asset identified in our data period. Our results imply that the fundamental value of Bitcoin is still unclear, and it is difficult for Bitcoin investors to manage their portfolio risk.

1. Introduction

Investors seek for a new asset class that is not correlated with traditional asset classes such as stocks and bonds. Today, one of the candidates for an alternative asset class is a cryptocurrency. In particular, Bitcoin receives high attention. Bitcoin is a virtual currency and payment system which is introduced by Nakamoto. [Nakamoto 08].

Two of the most attractive features of Bitcoin is its high historical return and volatility. The market value of one Bitcoin was less than five cents in 2010 and that exceeded 19,000 U.S. dollars in December 2017. However, the price fell dramatically after the peak, and it was below 4,000 U.S. dollars in November 2018. Figure 1. illustrates the historical price of Bitcoin and we can observe major fluctuations over the observed period. Therefore, another important feature of Bitcoin is its high volatility.

Finance researchers have investigated a hedge and safe haven for portfolios. Baur defines a hedge asset as "an asset that is uncorrelated or negatively correlated with another asset or portfolio on average" and a safe haven asset as "an asset that is uncorrelated or negatively correlated with another asset or portfolio in times of market stress or turmoil" [Baur 10a]. This paper follows these definitions.

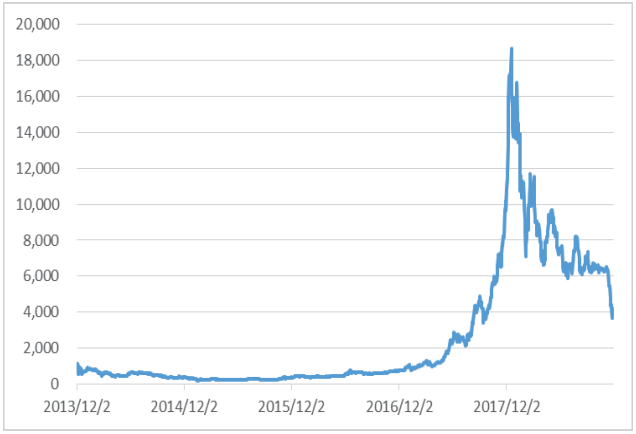
Hedge and safe haven properties are explored for commodities such as gold and silver. For instance, Baur finds that gold acts as a hedge for the U.S. stock market index [Baur 10b], Agyei-Ampomah observes that copper is a better hedge and safe haven asset for Euro bond investors [Agyei-Ampomah 14], and silver works as a safe haven asset for currency portfolio investors [Sakemoto 18].

Some studies focus upon the hedge property of Bitcoin, since it is regarded as an alternative asset class. Bouri uses the test specification proposed by Ratner, and observes that Bitcoin does not act as a hedge for U.S. and European stock indices [Bouri 17], [Ratner 13]. Furthermore, it does not work as a safe haven for most asset classes [Bouri 17]. Klein concludes that Bitcoin has a different property against gold [Klein 18]. These studies assume that investors hold traditional assets, and add Bitcoin into their portfolios. This framework does not fit for investors who hold Bitcoin and seek to hedge assets.

The first contribution of this study is that we focus upon Bitcoin investors. We investigate whether traditional assets act as hedge and safe havens for Bitcoin. In particular, extreme negative return days for Bitcoin are different from those of other assets, and hence our examination differs from the previous literature.

The second contribution is that we focus upon a mean equation. The conditional correlation test framework [Ratner 13] is important for sophisticated investors and researchers, while it is not linked to a return directly. We employ the test specification that focus upon the mean equation [Baur 10b] and it is easier for interpretation.

Fig 1. Bitcoin Price



Notes: This data covers December 2nd, 2013 to November 29th, 2018.

The third contribution is that we extend the data sample period which includes a bear market in 2018. The price of Bitcoin is volatile and sample periods affect empirical results [Baur 18]. Furthermore, investors are interested in the properties of a safe haven during a bearish market situation, and hence our sample

Contact: Ryuta Sakemoto, YJFX, Inc, 1-3 Kioicho, Chiyoda-ku, Tokyo, +81-3-6867-0898, ryuta_sakemoto@yjfx.co.jp

period is appropriate to investigate hedge and safe haven properties.

2. Methodology

We employ a test model proposed by Baur. [Baur 10b]. A test asset return, r_t, is dependent upon a return on Bitcoin rbt_t and extreme market conditions for Bitcoin are taken into account by dummy variables:

$$r_t = a + b_t rbt_t + e_t \quad (1)$$

$$b_t = \delta_0 + \delta_1 D10 + \delta_2 D5 + \delta_3 D1 \quad (2)$$

$$h_t = \omega + \alpha e_{t-1}^2 + \gamma I(e_{t-1} > 0) e_{t-1}^2 + \beta h_{t-1} \quad (3)$$

$$e_t \sim N(0, h_t) \quad (4)$$

where a and b_t are estimated parameters, and e_t is an error term. The parameter b_t depends upon the dummy variables, $D10$, D5 and $D1$, which capture extreme Bitcoin market movements. The dummy variable *Di* is equal to one if the return on Bitcoin falls in the lower *i*th percentile. The estimated parameter δ_0 is the hedge coefficient. We distinguish a weak and a strong hedge as in Baur [Baur 10b]. If δ_0 is not statistically different from zero then the asset is a weak hedge for Bitcoin. Moreover, if δ_0 takes a statistically significant negative value, then this indicates that the asset is a strong hedge for Bitcoin. The parameters of dummy variables, δ_1, δ_2, and δ_3 capture non-linear impacts on the asset return and if these parameters are not statistically different from zero, it indicates a weak safe haven. When these parameters are significantly negative, it implies a strong safe haven. Note that the dependent variable of the mean equation is the asset return. This is the important difference of the work conducted by Bouri which employs a conditional correlation as the dependent variable [Bouri 17]. Our specification investigates a relationship of two return series directly.

The error term e_t follows the asymmetric Glosten-Jagannathan-Runkle GARCH (GJR-GARCH) model that captures an asymmetric impact of the past squares of the error term [Glosten 93]. This provides allowance for asymmetric effects of positive and negative shocks by cause of volatility. The conditional variance of the GJR-GARCH process is expressed by h_t in equation (3). Along with the lagged squared of error term, e_{t-1}^2, and the lagged conditional variance, h_{t-1}, the equation captures the disturbance on the conditional variance. This best reflects the asymmetric nature of investors' response to asset returns which leads to both positive and negative shocks.

3. Data

We employ a Bitcoin price index that is an exchange rate of Bitcoin to U.S. dollars. Daily prices are adopted, and weekend prices are excluded since other asset classes are not traded during weekends [Klein 18]. We pick up 'end of the day prices' with GMT timestamp, since Bitcoin is traded continuously. The price index is transformed as the natural logarithmic price difference to obtain the return, $r_t = \log(P_t/P_{t-1}) \times 100$.

For hedge assets, we consider gold, global stock, and global bond. Gold has been used as the hedge asset for stock and bond markets [Baur 10a]. We use a spot price of gold and it is also quoted in U.S. dollars. MSCI World index and FTSE World Government Bond Index are employed to capture global stock and global bond performances which are U.S. dollar base indices. All three price indices are calculated return series. Our data covers from December 2nd, 2013 to November 29th, 2018.

Table 1: Summary of descriptive statistics

	Bitcoin	gold	stock	bond
Mean	0.11	0.00	0.02	0.00
Std. Dev.	5.14	0.82	0.68	0.35
Min	-58.39	-3.36	-5.03	-1.94
Max	51.7	4.58	2.56	1.81
Skewness	-0.55	0.21	-0.83	-0.11
Kurtosis	24.37	2.48	4.83	2.41

Note: Std. Dev. indicates standard deviation, Max and Min are the maximum and minimum of the daily time series.

Table 1 provides a summary of the descriptive statistics for the four assets such as Bitcoin, gold, world stock, and world bond. Among the four assets, Bitcoin has the highest daily mean return of 0.11% and standard deviation of 5.14%, which also corresponds with the qualitative results found in the literature [Klein 18]. In contrast, among the conventional hedge assets, gold has the highest daily standard deviation of 0.82%. Interestingly, gold is known as a safe haven asset, while the volatility is relatively high. Bitcoin also has a high kurtosis, which is attributed to its extreme price fluctuation within the observed period.

4. Empirical Results

We begin with the empirical results of hedge and safe haven assets for Bitcoin. Table 2 presents parameter estimates and each column indicates the asset we include. We observe that the hedge parameter, δ_0 is insignificant in all three assets. This indicates gold, stock, and bond work as a weak hedge for Bitcoin investors. Our findings correspond with those of Klein and Baur who highlight the difference between Bitcoin and gold [Klein 18] and [Baur 18].

Given insignificant hedge parameter results, we focus upon the safe haven parameters. For gold and stock, all safe haven parameters are insignificant in Table 2, which means that gold and stock are weak safe haven assets for Bitcoin investors. The safe haven parameter, δ_1, in the bond result is statistically significant at the 10% level, while the sign of the parameter is positive, which indicates bond moves in the same directions during extreme Bitcoin fluctuations.

Another point worth mentioning is that the asymmetric term of GJR-GARCH model, γ, is statistically significant at the 1% level in the stock result, while this term is insignificant in the other two assets.

Table 2 Hedge and safe haven properties: Full sample

	(1) gold		(2) Stock		(3) bond	
a	-0.01		0.03		-0.01	
	(0.02)		(0.02)		(0.01)	
δ_0	0.00		0.00		0.00	
	(0.01)		(0.00)		(0.00)	
δ_1	0.00		0.00		0.01	*
	(0.01)		(0.01)		(0.00)	
δ_2	0.00		0.00		0.00	
	(0.02)		(0.01)		(0.01)	
δ_3	-0.01		0.01		0.00	
	(0.02)		(0.01)		(0.01)	
ω	0.00		0.02	***	0.00	
	(0.00)		(0.01)		(0.00)	
α	0.02	**	0.03		0.04	***
	(0.01)		(0.06)		(0.01)	
γ	0.00		0.23	***	0.00	
	(0.02)		(0.06)		(0.02)	
β	0.98	***	0.81	***	0.96	***
	(0.00)		(0.05)		(0.00)	

Notes: This table shows the estimation results in equations (1)–(4). ***,**, and * indicate statistical significance at the 1%, 5%, and 10% levels, respectively.

Having found weak hedge and safe haven relationships between Bitcoin and other assets, we focus on a down side market. Baur demonstrates that Bitcoin estimation results are sensitive to sample periods [Baur 18]. We use the down market period of Bitcoin (January 1st, 2018 to November 29th, 2018). The price of Bitcoin fell by about 70% in this period. We repeat the same estimation whereas we only use the 10% dummy variable since the number of observations are not sufficient to construct 1% and 5% dummy variables.

Table 3 presents hedge and safe haven properties of the other assets when the price of Bitcoin fell. The hedge parameter of gold is statistically significant at the 10% level and the sign is negative, which indicates gold works as a strong hedge asset during the condition of a bearish Bitcoin market. This is positive news for Bitcoin investors since Bitcoin has idiosyncratic characteristics, and therefore it is not easy to protect the value of Bitcoin portfolios. However, the impact is marginal since a 1% decrease in the Bitcoin price leads to a 2bp increase in the gold price. In contrast to gold results, stock and bond neither serve as a strong hedge nor strong safe haven, which implies that gold has a more preferable characteristic for Bitcoin investors.

Table 3 Hedge and safe haven properties: Bear market phase of Bitcoin

	(1) gold		(2) stock		(3) bond	
a	-0.02		0.00		-0.02	
	(0.04)		(0.08)		(0.02)	
δ_0	-0.02	*	0.02		0.00	
	(0.01)		(0.01)		(0.01)	
δ_1	0.01		-0.01		0.00	
	(0.01)		(0.01)		(0.01)	
ω	0.02	**	0.04	**	0.00	
	(0.01)		(0.02)		(0.00)	
α	0.00		0.00		0.02	
	(0.01)		(0.17)		(0.01)	
γ	-0.05		0.30	***	-	
	(0.04)		(0.11)		-	
β	0.96	***	0.77	***	0.96	***
	(0.01)		(0.15)		(0.02)	

Notes: This table shows the estimation results in equations (1)–(4). ***,**, and * indicate statistical significance at the 1%, 5%, and 10% levels, respectively. The sample period covers January 1st, 2018 to November 29th, 2018

5. Conclusion

This paper attempts to identify asset classes which are hedge or safe haven assets for Bitcoin investors. Our research results are concluded based on the distinguished definition of both strong and weak hedge, and safe haven assets. The empirical results show that the identified asset classes – gold, stocks and bonds are weak hedge and safe haven investments in the overall market. By narrowing to the down side market, the results identified that gold works as a strong hedge although the impact is relatively marginal. However, all of the asset classes still do not serve as strong safe haven assets during an extreme bearish market. The extreme volatility of Bitcoin and relatively short timeframe may only reflect a snapshot of the fundamental value of Bitcoin, thus strong hedge and safe haven assets may be clearly identified with the growth in maturity of the Bitcoin trading market. While many critics have questioned the fundamental value of Bitcoin, its differing properties from other traditional asset classes makes it attractive to some investors, and seeking for a hedge or safe haven assets will be useful to reduce the high risk associated with it.

Disclaimer

The views expressed in this paper are those of our own and do not necessarily represent those of YJFX, Inc.

References

[Nakamoto 08] Nakamoto, S., Bitcoin: A Peer-to-Peer Electronic Cash System, URL: https://bitcoin.org/bitcoin.pdf, 2008.

[Baur 10a] Baur, D.G. and Lucy, B.M., Is Gold a Hedge or a Safe Haven? An Analysis of Stocks, Bonds and Gold, The Finance Review, Vol. 45, pp. 217-229, 2010.

[Baur 10b] Baur, D.G. and McDermott, T.K., Is Gold a Safe Haven? International Evidence, Journal of Banking and Finance, Vol. 34, pp. 1886-1898, 2010

[Agyei-Ampomah 14] Agyei-Ampomah, S., Gounopoulos, D., and Mazouz, K., Does Gold Offer a Better Protection against Losses in Sovereign Debt Bonds than Other Metals? Journal of Banking and Finance, Vol. 40, pp. 507-521, 2014.

[Sakemoto 18] Sakemoto, R., Do Precious and Industrial Metals Act as Hedges and Safe Havens for Currency Portfolios? Finance Research Letters, Vol.24, 256-262, 2018.

[Bouri 17] Bouri, E., Molnar, P., Azzi, G., Roubaud, D., and Hagfors, L.I., On the Hedge and Safe Haven Properties of Bitcoin: Is It Really More than a Diversifier? Finance Research Letters, Vol.20, 192-198, 2017.

[Ratner 13] Ratner, M. and Chiu, C-C., Hedging Stock Sector Risk with Credit Default Swaps, International Review of Financial Analysis, Vol. 30, pp. 18-25, 2013.

[Klein 18] Klein, T., Thu, H. P., and Walther, T., Bitcoin is not the New Gold – A Comparison of Volatility, Correlation, and Portfolio Performance, International Review of Financial Analysis Vol. 59, pp. 105-116, 2018.

[Baur 18] Baur, D.G., Dimpfl, T., and Kuck, K., Bitcoin, Gold and the US Dollar – A Replication and Extension, Finance Research Letters, Vol.25, 103-110, 2018.

[Glosten 93] Glosten, L.R., Jagannathan, R., and Runkle, D.E., On the Relation between the Expected Value and the Volatility of the Nominal Excess Return on Stocks, Journal of Finance, Vol.48, pp. 1779-1801.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

極性を考慮したリスク発見に向けた因果関係ネットワークの構築

Construction of Causal Networks for Risk Finding Considering Word Polarities

五十嵐 光秋 *1 Hiroaki Igarashi　坂地 泰紀 *1 Hiroki Sakaji　和泉 潔 *1 Kiyoshi Izumi　島田 尚 *1 Takashi Shimada　松島 裕康 *1 Hiroyasu Matsushima

須田 真太郎 *2 Shintaro Suda

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

*2株式会社 三菱 UFJ トラスト投資工学研究所 Mitsubishi UFJ Trust Investment Technology Institute Co., Ltd.(MTEC)

In this research, we conduct an experiment of constructing a causal networks within settlement account briefs. We extracted the causal relations from settlement briefs, and construct a network by connecting them by judging similarities. For calculating the similarities, we use a word2vec model created from the Japanese Wikipedia corpus.We use a method based on a combination of idf values which representing importance of words. In addition, by giving the polarities of causal expression using a polar dictionary, and judgment of synonyms that word2vec can't detect, we define so to speak, "negative relation".

100 edges between causal relationships obtained by experiments were randomly selected and evaluated visually. As a result, the ratio that is deemed to be a reasonable connection was 84%, and among them the ratio of edges where polarity inversion was correctly captured was 86%.

1. はじめに

近年，人工知能分野の技術の発展に注目が集まっており，これを金融領域に対しても応用することが期待されている．経済事象は複雑に絡み合い，様々なことが原因となり発生する．これを深く理解するには，様々な社会事象の因果関係を読み解いていく必要がある．こうした背景の中で，テキストデータの活用に対して注目が集まっている．複雑な因果関係を数値データだけで読み解くのは難しいが，人間の理解力をもって因果関係と解釈された関係性が，テキスト情報には蓄えられているからである．

社会事象の因果関係を読み解くことによるメリットの 1 つとして，あるニュースから企業の業績を予測することができることがある．これにより，例えば投資家はいち早く投資の意思決定に役立てることができるし，また企業自身としても業績予測に応じた対応策を講じることができるであろう．

世界中に衝撃を与えた社会事象として，リーマン・ショックは記憶に新しい．サブプライムローンというリスクの高い金融商品が出回っていたこと，信用の高い格付け企業がこの金融商品に高い評価を出していたこと，不動産価格の暴落など，様々な問題が密接に結びついて発生したと言われるリーマン・ショックであるが，因果関係を適切に把握することでこのようなリスクを事前に察知することができると考えられる．もちろん，リーマンブラザーズだけにリーマン・ショックの責任があるのではない．リスクの高い状態にあった金融市場に対して，投資家や証券会社等の様々なステークホルダーが楽観的すぎたことが最大の要因であると考える．したがって，社会全体として，リスク要因となるような因果関係を把握していくことが，健全な社会への第一歩となる．

とはいうものの，こうした複雑な因果関係は単一の文章に記載されているものではなく，膨大な数のテキストデータを網羅し，因果関係をつなぎ合わせることで初めて読み解くことができる．したがって，膨大なテキストから因果関係のネットワークを構築して，リスク事象を発見することに大きな価値がある．

この課題を解決するアプローチとして、テキストマイニングによる因果関係を抽出する研究，そして抽出した因果関係を元にそれらのネットワークを構築する研究がなされてきた．乾ら [乾 04] は，接続標識の「ため」に注目して，これが含まれる表層的な因果関係を抽出した．ここでは，事象を「事態」と「行為」に分けて捉え，抽出した因果関係を cause 関係，effect 関係，precond 関係，means 関係の 4 つに分類した．坂地ら [坂地 11] の研究では，乾らと同様の概念である「手がかり表現」を鍵として新聞記事から因果関係を抽出した．そしてこれを機械学習の手法の 1 つである SVM（サポートベクターマシン）によって分類し精度を高めた．これらの研究はあくまで単一の記事からの抽出にとどまり，因果関係のネットワークを作成するには至らなかった．そこで，佐藤ら [佐藤 06] は，Web 上の文書から因果関係ネットワークを構築することを試みた．ここでは因果関係表現のキーワードを抽出し，その一致率から検討していた．石井らは [石井 09]SVO 構造に注目した単語の一致による因果関係の接続について検討した．この手法では，それぞれ主語，動詞，目的語が一致した場合に限り因果関係の接続を行うという制約のもとで接続を行なっている．しかし，主語，動詞，目的語のセットというシンプルなフォーマット以外での表現による因果関係表現も存在し，本来的には接続されるべきであった因果関係が抜け落ちてしまう可能性がある．表現方法による制限をかけずに因果関係を接続するという考え方から，word2vec モデルの利用を検討した研究も存在する．西村ら [NISHIMURA 18] は，新聞記事から抽出した因果関係表現に対して，word2vec モデルを用いて因果表現のベクトル表現を算出し，コサイン類似度の計算から因果関係の接続を試みた．ただ，ここでは単語ベクトルの扱いの処理や品詞の選定などに改善点が見られた．

以上のような背景から、我々は word2vec モデルを用いた因果関係ネットワークを構築する．これにより，企業の業績悪化

連絡先: 五十嵐光秋，東京大学大学院工学系研究科，東京都文京区本郷 7-3-1，m2018higarashi@socsim.org

などに対してその根拠となるような潜在的な事象を発見することを目指す．

2. 因果関係ネットワーク構築手法

文書集合の中から因果関係を抽出し，それらを接続する手続きについて説明する．本研究では word2vec のモデルと単語の重要度を用いて，因果関係ネットワークを構築する．図 1 に本手法の概要を示す．

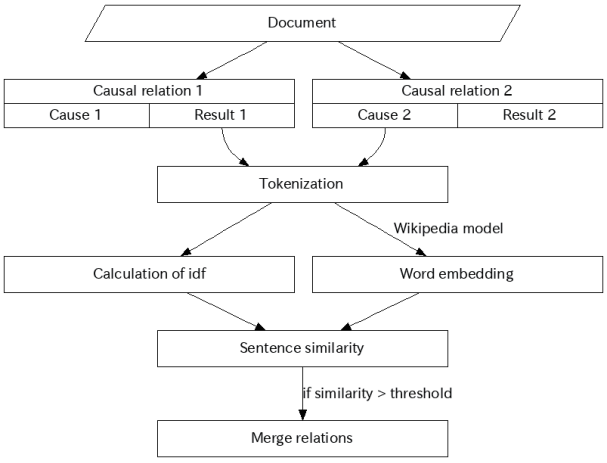


図 1: 本手法のフレームワーク

2.1 因果関係の抽出

決算短信からの因果関係の抽出には，坂地らの手法を用いた．[坂地 11] これにより，重文や複文にまたがって記述されるような因果関係を抽出することができる．詳しいアルゴリズムについては引用論文を参照されたい．この手法により決算短信から抽出した因果関係の例を以下に記述する．

原因表現	手がかり表現	結果表現
海外経済の改善	を背景に，	輸出も持ち直しの動きが見られています。
物流及び生産機能の低下	により，	当社の業績は影響を受ける可能性があります。

表 1: 決算短信から抽出した因果関係の一覧

2.2 因果表現から単語集合への変換

本手法では，単語をベクトルで表現することで，文を表現するベクトルを得る．日本語では，単語と単語が必ずスペースで区切られている英語などの言語とは異なり，単語が全てそのまま接続されて文をなす構造をしているために，これを単語集合へと変換する作業が必要である．この分かち書きの作業を，形態素解析ツール MeCab[*1] を用いて行った．辞書には，新語などに対応している mecab-ipadic-NEologd[*2] を採用した．

自然言語から単語集合へ変換する際に，品詞による単語の選定を行なった．有効とした品詞とその詳細は表 2 に示す．

2.3 因果関係の接続

複数の因果関係を接続することで，因果関係の連鎖を構築することを試みる．ある因果関係 $A \rightarrow B$ に対して，また別の因果関係 $B' \rightarrow C$ が存在する状況を想定する．$A \rightarrow B$ の関係性においては，A が原因表現，B を結果表現と呼ぶ．この時，B と B' が同一の事象について言及しているのであれば，これらを接続することで $A \rightarrow B \rightarrow C$ という連鎖が確立される．この因果関係の上流側には，企業の業績の要因となるような事象が現れることが期待される．したがって，文書群に対して因果関係の抽出，接続を行い，これらを遡ることで単一の文書だけでは発見できなかった潜在的な事象を発見することを目指す．

品詞	詳細
名詞	サ変接続，一般，固有名詞，形容動詞語幹，副詞可能
動詞	自立
形容詞	自立

表 2: 決算短信から抽出した因果関係の一覧

2.4 word2vec モデル

前節で述べた手続きを行う上で，結果表現 B と原因表現 B' の類似度を評価する必要がある．この時の文間類似度を算出する手続きでは，word2vec モデルを用いる．word2vec とは，「文書集合において，類似した単語は同一の文脈において現れる」という理解に基づいて構築したニューラルネットワークモデルを介して作成した，単語のベクトル表現である．従来の自然言語処理においては，テキストに登場する各単語を表現する方法が語彙数次元の onehot ベクトル（文書集合内での登場回数を用いる tf-idf という考え方もあるが，依然として次数は語彙数に一致する）であり，文書のサイズが大きくなるほどに計算量が膨大になってしまうという問題点があった．しかしこの word2vec モデルで学習することにより，単語同士の意味的な繋がりへの表現力に強く，かつ低次元なベクトル表現の実装が可能になった．本手法では，この word2vec による単語のベクトル表現を拡張して，文に対するベクトル表現を獲得する．なお，モデルの中に含まれない単語に関しては，全ての成分が 0 のベクトルにより代用した．

2.5 idf 値の算出

例えば「する」,「いる」のような語は，非常に多種の単語との親和性が高く，多くの文書内で登場する．今回のような文の意味的類似性を測る上で，このような単語のマッチングがノイズとなることが予想される．したがって，複数の単語から構成される文に対してベクトル表現を獲得するにあたってこのような重要度の低い単語の影響は小さく抑え，かつ重要度の高い単語は大きい影響を持つように調整することが必要である．

この点を考慮するために，本手法では各単語の idf 値を単語ベクトルに対する重みとして扱うこととする．この idf 値は以下の式により与えられる．

$$idf_i = log_2 \frac{D}{freq_i} \tag{1}$$

ここで，D は全文数，$freq_i$ は単語 i の出現する文数である．

各単語に対する idf 値を対象の決算短信データから算出した．各単語の idf 値の算出結果について，下位 10 単語を表 3 にまとめる．

決算短信で頻繁に現れる単語の idf 値が，確かに下位に現れていることが確認できる．

2.6 文間類似度の算出

前々節で述べた単語ベクトルと前節で述べた idf 値を用いて文ベクトルを獲得する．文 s_j を単語集合に変換する手続きにより，そこに含まれる全ての単語に対して単語ベクトルと idf 値が獲得できる．それらを用いて，以下のように文ベクトルを定める．ただし，一文中に登場する同一の単語は，登場する回

∗1 http://taku910.github.io/mecab/
∗2 https://github.com/neologd/mecab-unidic-neologd

単語	idf 値
する	0.96
なる	2.429
四半期	2.874
ある	2.93
当社	3.19
連結会計	2.93
事業	3.26
平成	3.315
増加	3.352
セグメント	3.384

表 3: idf 値の下位 10 項目

数だけ重複して加算される．

$$vec_{s_j} = \sum_i vec_i \cdot idf_i \tag{2}$$

ここで，vec_i と idf_i は，それぞれ文 s_j 内に含まれる単語 i に相当する単語ベクトルと idf 値である．

文間類似度に関しては，以上の手続きによって獲得された文ベクトルのコサイン類似度を採択した．

$$sim(s_1, s_2) = \frac{vec_{s_1} \cdot vec_{s_2}}{|vec_{s_1}||vec_{s_2}|} \tag{3}$$

算出された類似度が閾値を超える因果関係のペアを接続した．

2.7 極性辞書の利用

類似した文を探索するタスクにおいて，word2vec モデルでは対義語と類義語の区別ができないため欠点となる．これは，word2vec モデル構築の際に設定している「類似単語が同一の文脈において登場するという」仮定によるものであり，例えば「増加」と「減少」は類似単語として学習されてしまう．それにより，本来真逆の概念として捉えたい対義語が，類義語であるかのように扱われてしまう．

この問題に対するアプローチとして，我々は単語の極性を用いた．極性とは，単語が示す概念がポジティブなのかネガティブなのかについて定量評価をしたものである．単語に極性を付与するにあたって，本手法では伊藤ら [Ito 18] による金融領域に特化した極性辞書を用いた．伊藤らによる極性辞書では，金融分野におけるコーパスから極性を獲得しているため，決算短信内に現れる単語に対して高精度で適切な極性を与えることが可能であると考える．本手法では，単語ごとに付与されている極性の総和を取り，文に対する極性として定義する．類似度と極性の正負に注目することにより，対義語により誤って類似文と判定された文を特定することができる．

この判定によって，結果表現 $A \rightarrow$ 原因表現 B の極性の反転が認められた場合，A を含む事象の発生に対して B を含む事象が「起こらない」という関係性が得られたことに相当する．したがって，次章で示す結果ではあえてこの極性判定によるエッジの削除は行わず，エッジの種類を変えることでそれを表現することとする．

3. 因果関係ネットワーク構築実験

3.1 実験仕様

ある事象が影響する企業の業績に焦点を当てるために，決算短信を対象として因果関係を抽出した．決算短信には，各企業の売上や利益といった数値情報の他に，その利益の原因となった事象や経営上のリスクに関する記述などが記載されている．2012 年 10 月 9 日から 2018 年 5 月 11 日までに発行された，4359 企業の決算短信データから因果関係を抽出したものを対象に分析を行った．これらの決算短信から，前章に述べた idf 値の獲得と因果関係の抽出，因果関係ネットワークの構築を行った．

また，単語のベクトル表現に関しては，乾らによる Wikipedia の日本語コーパスを用いて作成した「日本語 Wikipedia エンティティベクトル」[*3] を用いた．このモデルでは，通常の word2vec の学習に加えて，Wikipedia の記事になった固有表現に付される記事本文中のハイパーリンクを用いて学習している．同一表記であるが違うものを指す言葉（例えば魚の「スズキ」と四輪・二輪車メーカーの「スズキ」など）の違いを反映することができる．

本実験では「国際情勢への不安」を起点とした因果関係ネットワークを構築した．因果関係接続のための閾値を 0.9 で定め，起点事象から広がる因果関係の波及を 2 段階目まで確認した．

3.2 実験結果

坂地ら [坂地 11] の手法により抽出された因果関係の数は 92 万 5908 件であった．これらの候補の中から前節で述べた条件で探索をし，得られた因果関係ネットワークの一部を図 2 に示す．

算出された類似度をエッジの近傍に付した．また，極性の反転が認められたエッジは点線により表現している．構築したネットワークのうちランダムに 100 件を抽出し，結ばれたエッジの妥当性を目視により検証した．目視による判定は，「反転なし」，「反転あり」，「因果関係なし」の 3 種類である．表 4 にその結果を示す．

表 4: 因果関係エッジの評価

		目視による判定		
		反転なし	反転あり	因果関係なし
実験結果	反転なし	42	2	11
	反転あり	9	31	5

抽出された 100 件の因果関係エッジのうち，妥当なつながりであると認められる割合は 84%，それらの中で，正しく反転を捉えられた割合は $(42 + 31)/84 = 0.86$ より 86%であった．

4. 考察

因果関係が正しく結ばれるケースのほぼ全てで，その事象を表す核となる単語が一致している（例えば「原材料価格の上昇」における「原材料」，「上昇」など）．逆に，正しく結ばれないケースでは文章中でさほど重要でない単語が一致していた（例えば「円相場は１０１円台まで円高が進行しました。」における「進行」など）．したがって，因果関係を適切に接続するには文におけるキーワードを適切に抽出することが重要であると言える．

また，Wikipedia のモデルには収録されていない，決算の専門用語（「繰延税金資産」など）がキーワードとなっているケースが存在し，Recall を下げている可能性が考えられる．こうしたベクトルは 0 ベクトルとして置換するため，素性をつかむことができない．これに対しては，決算短信を学習させた word2vec モデルを用いた場合，決算短信に固有な単語もカ

*3 http://taku910.github.io/mecab/

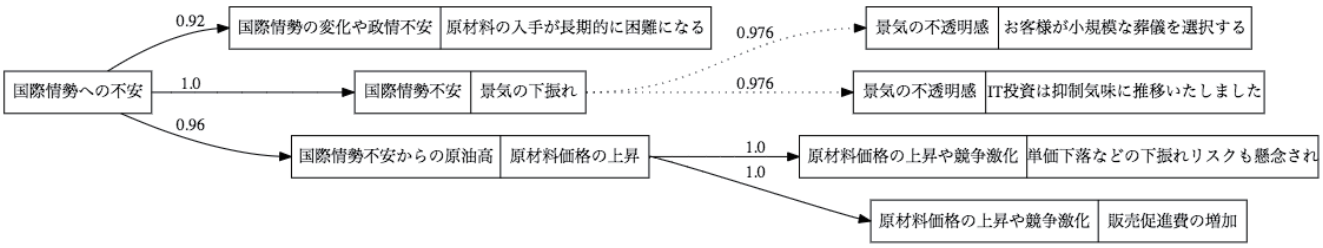


図 2: 「国際情勢への不安」を起点とした因果関係ネットワーク （可読性のため，一部を省略している）

バーすることができる．本研究で利用した Wikipedia によるモデルに対して，決算短信のデータを追加学習させることで，単語のカバー範囲を広げることが有効であると考えられる．

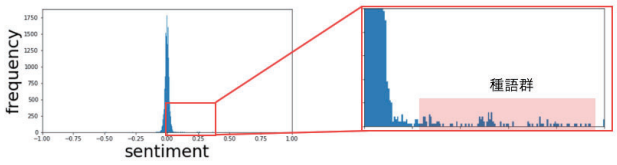


図 3: 極性辞書内の極性の分布

図 3 に示したように，極性辞書の中に収録されている単語の極性の分布は，極めて多くの単語が 0 近傍に集中しており，ごく少数の単語がそれより外側に位置するという構成になっている．この非連続性は，極性辞書の作成時の手順による．伊藤ら [Ito 18] の手法では，あらかじめ人手によりリストアップされた極めて強い極性をもつ単語（「種語」という）を起点に，ニューラルネットワークモデルによりその他の単語へ伝搬させている．そのため，これら種語群とその他の単語群では極性が大きく異なる．これにより，「下振れ」のような，種語として設定されていないが十分に強い極性を示す単語が適切に処理されなかったと考える．こうした問題に対しては，石井ら [石井 09] の手法のように，単語のシソーラスを用いて同概念を示す類似表現に置き換えることが有効である可能性がある．

5. まとめ

本研究では，決算短信内での因果関係ネットワークの構築実験を行った．

決算短信内に存在する因果関係を抽出し，これらの類似度を判定して接続することによりネットワークを構築した．類似度の算出には，Wikipedia 日本語コーパスから作成した word2vec モデルと，単語の重要度を表す idf 値による組み合わせによる手法を用いた．また，極性辞書を用いて因果表現の極性を付与することにより，word2vec が苦手とする対義語の判定を行い，いわば「負の関係性」を特定した．

この手順により得られた因果関係間のエッジから 100 件について目視で判定したところ，妥当なつながりであると認められる割合は 84%，またそれらの中で，正しく反転を捉えられた割合は 86%であった．

上述のアルゴリズムによって作成された因果関係の連鎖について，目視による判定を導入して正解データを集積したのち，機械学習によるフィルタリングを導入することにより Precision の向上が期待される．

また評価方法に関しても改善が必要である．本研究では，インプットした事象に対して，因果関係ネットワークの終端に企業の業績に関する表現が現れることは確認したが，これが実社会において妥当な結果なのかは不明である．外部の数値データを正解として，実際にそのような因果関係が働いているのかを確認することが重要だと考える．

留意事項

本稿の内容は筆者が所属する組織を代表するものではなく，すべて個人的な見解である．また，当然のことながら，本稿における誤りは全て筆者の責に帰するものである．

参考文献

[Ito 18] Ito, T., Sakaji, H., Tsubouchi, K., Izumi, K., and Yamashita, T.: Text-Visualizing Neural Network Model: Understanding Online Financial Textual Data, in *Pacific-Asia Conference on Knowledge Discovery and Data Mining*, pp. 247–259Springer (2018)

[NISHIMURA 18] NISHIMURA, K., SAKAJI, H., and IZUMI, K. : Creation of Causal Relation Network using Semantic Similarity, 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, pp. 1P104–1P104 一般社団法人人工知能学会 (2018)

[乾 04] 乾 孝司, 乾 健太郎, 松本 裕治 他 : 接続標識 「ため」 に基づく文書集合からの因果関係知識の自動獲得, 情報処理学会論文誌, Vol. 45, No. 3, pp. 919–933 (2004)

[佐藤 06] 佐藤 岳文, 堀田 昌英 : Web マイニングを用いた因果ネットワークの自動構築手法の開発, 社会技術研究論文集, Vol. 4, pp. 66–74 (2006)

[坂地 11] 坂地 泰紀, 増山 繁 : 新聞記事からの因果関係を含む文の抽出手法, 電子情報通信学会論文誌 D, Vol. 94, No. 8, pp. 1496–1506 (2011)

[石井 09] 石井 裕志, 馬 強, 吉川 正俊 他 : SVO 構造を用いた因果関係ネットワーク構築手法について, 研究報告データベースシステム (DBS), Vol. 2009, No. 10, pp. 1–8 (2009)

General Session | General Session | [GS] J-2 Machine learning

[2P1-J-2] Machine learning: conquests of limits

Chair:Takuma Otsuka Reviewer:Yuiko Tsunomori

Wed. Jun 5, 2019 9:00 AM - 10:20 AM Room P (Front-left room of 1F Exhibition hall)

[2P1-J-2-01] Toward Deep Satisficing Reinforcement Learning

○Kuniaki Satori[1], Yutaka Yoshida[1], Takumi Kamiya[1], Tatsuji Takahashi[1] （1. Tokyo Denki University）

9:00 AM - 9:20 AM

[2P1-J-2-02] Imbalanced Classification with Near-misses for Binary Decision-making

○Akira Tanimoto[1,2,3], So Yamada[1], Takashi Takenouchi[2,4], Hisashi Kashima[2,3] （1. NEC, 2. Riken, 3. Kyoto University, 4. Future University Hakodate）

9:20 AM - 9:40 AM

[2P1-J-2-03] Learning Model Discrepancy in Physics-guided Neural Networks

Junya Tanaka[1], Tomohiko Tomita[2], Masayuki Numao[1], ○Ken-ichi Fukui[1] （1. Osaka University, 2. Kumamoto University）

9:40 AM - 10:00 AM

[2P1-J-2-04] Collaborative filtering based on distributed expression considering differences in evaluation trends

○Ryousuke Goto[1], Hideki Fujinami[1], Tianxiang Yang[1], Masayuki Goto[1] （1. Facutly of Science and Engeneering, Waseda University）

10:00 AM - 10:20 AM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

深層満足化強化学習に向けて

Toward Deep Satisficing Reinforcement Learning

佐鳥玖仁朗 *1 Kuniaki Satori　吉田豊 *1 Yutaka Yoshida　神谷匠 *2 Takumi Kamiya　高橋達二 *1 Tatsuji Takahashi

*1東京電機大学理工学部 School of Science and Engineering, Tokyo Denki University

*2東京電機大学大学院 Graduate School of Tokyo Denki University

For dealing with continuous state spaces, DQN and other algorithms have been proposed in reinforcement learning (RL). However, it is hard for DQN to explore efficiently, as it depends on random search strategies such as epsilon-greedy. Humans are known to effectively search and learn through "satisficing" instead of optimizing. Although the risk-sensitive satisificing (RS) algorithm enables satisficing in RL, it depends on the count of visiting each state, which poses a problem for continuous spaces. We propose a method for solving this problem by pseudocount and hash+auto encoder methods that enables intrinsically motivated exploration. Through two experiments, we show that RS combined with the two methods enables deep satisficing RL that searches and learns efficiently in continuous spaces.

1. はじめに

強化学習では，エージェントの試行錯誤を通じて未知の環境において収益を最大化する行動系列を学習することを目的とする．エージェントの試行錯誤には，探索と知識利用の間にトレードオフが存在し，エージェントは両者のバランスを調整しながら学習を行う必要がある．

近年，連続状態空間を扱う方法として深層学習と強化学習を組み合わせた深層強化学習の Deep Q-Network(DQN)[Mnih 2013] がある．DQN は，Atari2600 のゲーム画面を入力とし得られたスコアを報酬とすることで人間レベルのパフォーマンスを達成したアルゴリズムである．しかし，現状では行動を決定する意思決定方法として ϵ-greedy のような単純なルールに依存しているため，膨大な探索空間を扱う場合に探索と知識利用のバランス調整を適切に行えているとは言い難い．

人間は，莫大な探索空間上で意思決定を行う場合に最適化ではなく満足化により意思決定を行う．満足化による意思決定では，現状が目的とする基準を満たしていなければ探索を行い，満たしていれば知識利用を行うように意思決定を行うことで，探索空間の広大な未知の環境であっても基準を満たすような行動を可能としている [Simon 1956].

この満足化を反映した意思決定手法として，Risk-sensitive Satisficing (RS) が考案された． RS は多腕バンディット問題をはじめとした様々なタスクにおいて基準値が適切であれば少数の探索で，最適な行動系列を学習できることがわかっている [高橋 2016][牛田 2017]．深層強化学習においても，RS を適用することで莫大な探索空間上での探索を改善し，基準を満たすような行動系列の短時間での学習が期待される．しかし，RS の深層強化学習への適用する場合，RS がカウントベース手法であり，意思決定に経験した状態行動対の試行数を利用することが問題となる．状態数が極めて多いタスクでは完全に同じ状態に訪れることが少なく，多くの状態行動対が新奇の観測となってしまう．

連絡先: 高橋達二， 東京電機大学理工学部， 350-0394 埼玉県比企郡鳩山町大字石坂， 049-296-1642, tatsujit@mail.dendai.ac.jp

そこで本研究では，連続状態空間で状態の不確実性から内発的動機付けを行うために状態をカウントする手法として考案されている擬似カウント (pseudo count)[Bellmare 2016] とハッシュ関数+AutoEncorder(AE)[Tang 2017] によって抽象化された状態を用いることで，RS の深層強化学習への適用を図る．

2. Risk-sensitive Satisficing (RS)

本章では，満足化を反映した意思決定手法である RS について説明する． 強化学習において RS を用いる場合，エージェントは RS 価値関数と大局基準変換法 (Global Reference Conversion: GRC) を用いることで意思決定を行う．

2.1 RS 価値関数

RS 価値関数は，方策の信頼度 $\tau(s_i, a_j)$ と行動価値関数 $Q(s_i, a_j)$，各状態の基準値 $\aleph(s_i)$ から式 (1) のように定義される．信頼度 τ はある方策に従った際の行動価値 Q がどの程度信頼できるかの指標であり，状態 s_i において行動 a_j を試行した回数 $\tau_{\mathrm{curr}}(s_i, a_j)$ と，未来信頼度 $\tau_{\mathrm{post}}(s_i, a_j)$ の和として定義される (式 (2)).

$$RS(s_i, a_j) = \tau(s_i, a_j)\Big(Q(s_i, a_j) - \aleph(s_i)\Big) \quad (1)$$

$$\tau(s_i, a_j) = \tau_{\mathrm{curr}}(s_i, a_j) + \tau_{\mathrm{post}}(s_i, a_j) \quad (2)$$

$\tau_{\mathrm{curr}}(s_i, a_j)$ と $\tau_{\mathrm{post}}(s_i, a_j)$ は，実際の試行によって式 (3)，式 (4) のように更新される．このとき，状態 s' は状態行動対 (s_i, a_j) により遷移した状態で，行動 a' は状態 s' において選択する行動である．また，γ_τ は未来信頼度割引率，α_τ は信頼度学習率を表す．

$$\tau_{\mathrm{curr}}(s_i, a_j) \leftarrow \tau_{\mathrm{curr}}(s_i, a_j) + 1 \quad (3)$$

$$\tau_{\mathrm{post}}(s_i, a_j) \leftarrow \tau_{\mathrm{post}}(s_i, a_j) + \alpha_\tau\Big(\gamma_\tau \tau(s', a') - \tau_{\mathrm{post}}(s_i, a_j)\Big) \quad (4)$$

RS 価値関数による評価値 RS を最大化する行動を選択する方策を，RS 方策と呼ぶ．

2.2 大局基準変換法 (GRC)

現実的なタスクにおいて，各状態ごとの適切な基準値を推定することは困難である．一方で，タスク全体を通して得られる収益は既知であることも多く，タスク全体の収益に対する適切な基準値の推定は可能である場合が多い．そこで，タスクの収益に対する大局基準値 $\aleph_G$ と現在の方策による収益の大局観測期待値 E_G からタスク全体の満足度合いを求め，その値から各状態の基準値 $\aleph(s_i)$ を求める手法である GRC が考案された [牛田 2017]．

E_G は現在の方策による収益を E_{tmp} としたとき，式 (5) のように更新される．

$$E_G \leftarrow \frac{E_{\mathrm{tmp}} + \gamma_G (N_G E_G)}{1 + \gamma_G N_G} \tag{5}$$

$$N_G \leftarrow 1 + \gamma_{N_G} \tag{6}$$

E_G と $\aleph_G$ の差 δ_G を現在の方策の満足化度合いとしたとき，各状態の基準値 $\aleph(s_i)$ は式 (9) のように計算される．$\zeta(s_i)$ はスケーリングパラメータで，各状態と大局のスケールの違いを吸収するために用いられる．

$$\delta_G = \min(E_G - \aleph_G, 0) \tag{7}$$

$$\max Q(s_i) - \aleph(s_i) = \zeta(s_i)\delta_G \tag{8}$$

$$\aleph(s_i) = \max Q(s_i) - \zeta(s_i)\delta_G \tag{9}$$

2.3 RS の深層強化学習へ適用への問題点

RS を深層強化学習で用いる場合，深層強化学習で扱うようなタスクの状態数の多さが問題となる．観測した状態を信頼度 τ にそのまま用いた場合，その状態へ再訪することが少ないため，適切な評価値 RS の比較が行えない．

そこで，状態の不確実性から擬似的にカウントを行う擬似カウントや，画像上の物体間の位置等を考慮した AENO による状態表現をハッシュ関数を用いることで，抽象的な状態のカウントを行う．それにより信頼度 τ を計算することで，深層強化学習への RS 適用の問題解決を図る．

3. 擬似カウントによる RS の深層強化学習への適用

本章では，疑似カウントによる状態のカウント方法を説明した上で，その信頼度への拡張方法を提案する．

3.1 擬似カウント (pseudo count)

擬似カウントとは状態が極めて多い場合でも状態の経験回数をカウントできるように，状態の不確実性から算出した擬似的な状態の経験回数である．擬似カウントでは，状態が要素の集合で表現されているとみなし，状態の各要素が過去に出現した比率を計算しその比率を全要素について掛け合わせることで，その状態の出現確率を近似する．状態 x の出現確率 $\rho_n(x)$ と新たに状態 x が観測された後の出現確率 $\rho'_n(x)$ は，記録された状態数 n と記録された状態内の x の出現回数 $N_n(x)$ から次のように定義できる．

$$\rho_n(x) = \frac{N_n(x)}{n} \tag{10}$$

$$\rho'_n(x) = \frac{N_n(x)+1}{n+1} \tag{11}$$

n と $N_n(x)$ を未知数 $\widehat{n}$ と $\widehat{N}_n(x)$ とした時，$\widehat{N}_n(x)$ は式 (12) のように求められる．

$$\widehat{N}_n(x) = \frac{\rho_n(x)\,(1-\rho'_n(x))}{\rho'_n(x) - \rho_n(x)} \tag{12}$$

疑似カウントでは，この $\widehat{N}_n(x)$ を擬似的な状態 x の出現回数として使用する．

3.2 擬似カウントによる信頼度の表現

疑似カウントを用いて τ を表現するにあたり，状態ではなく状態行動対の経験回数を擬似的に表現する必要がある．状態 s の要素を s_n とし，行動 a を選択したときの各要素の出現回数を $N_{\tau_{\mathrm{curr}}}(s_n, a)$，未来出現回数を $N_{\tau_{\mathrm{post}}}(s_n, a)$ と表すと，τ_{curr} と τ_{post} は式 (15) のように定義される．ここで以下の式の τ_x には τ_{curr} もしくは τ_{post} が対応する．

$$\rho_{\tau_x}(s,a) = \prod_{k=1}^{n} \frac{N_{\tau_x}(s_k,a)}{\sum_{l=1}^{n} N_{\tau_x}(s_l,a)} \tag{13}$$

$$\rho'_{\tau_x}(s,a) = \prod_{k=1}^{n} \frac{N_{\tau_x}(s_k,a)+1}{\sum_{l=1}^{n} N_{\tau_x}(s_l,a)+1} \tag{14}$$

$$\tau_x(s,a) = \frac{\rho_{\tau_x}(s,a)\,(1-\rho'_{\tau_x}(s,a))}{\rho'_{\tau_x}(s,a) - \rho_{\tau_x}(s,a)} \tag{15}$$

$$\tau(s,a) = \tau_{\mathrm{curr}}(s,a) + \tau_{\mathrm{post}}(s,a) \tag{16}$$

行動 a を選択したときの各要素の出現回数 $N_{\tau_{\mathrm{curr}}}(s_n, a)$ と未来出現回数 $N_{\tau_{\mathrm{post}}}(s_n, a)$ は，以下のように更新される．

$$N_{\tau_{\mathrm{curr}}}(s_n,a) \leftarrow N_{\tau_{\mathrm{curr}}}(s_n,a) + 1 \tag{17}$$

$$N_{\tau_{\mathrm{post}}}(s_n,a) \leftarrow N_{\tau_{\mathrm{post}}}(s_n,a) + \alpha_\tau(\gamma_\tau \tau(s',a') - \tau_{\mathrm{post}}(s,a)) \tag{18}$$

以上の手法により信頼度 τ を擬似カウントで表現することで，RS を深層強化学習へ適用した．

4. ハッシュ関数と AE による RS の深層強化学習への適用

本章では，ハッシュ関数と AE による状態表現と，その状態表現を用いた信頼度の拡張方法を提案する．

4.1 SimHash と AE による状態表現

先行研究において，直接カウントを行うことが困難な連続状態の環境で状態カウントを行う手法として，SimHash と AE を用いた手法が提案されている [Tang 2017]．SimHash はハッシュ関数の一種で，類似値を類似ハッシュ値にハッシュ化する性質を持つため，この性質を利用することで類似状態を抽象化して同一状態として扱うことが可能である．また，Atari2600 など，画像を直接的に状態入力へ用いる環境の場合，非常に複雑であるため状態の抽象化は困難である．そのため，AE を用いることで状態を次元削減し，その削減された状態表現をハッシュ関数を通して抽象化することで，連続状態のカウントを行う．

4.2 SimHash と AE による信頼度の表現

式 (3), (4) では直接 s_t を用いていたが，SimHash と AE を用いた信頼度は SimHash によって離散化された k 次元のベクトル $g(s_t)$ を用いる．

また，画像を状態として用いる場合，SimHash への入力は，s_t を入力とした AE の隠れ層 h からの出力となる．

本実験の AE は CNN を用い，バイナリ層の活性化関数は sigmoid 関数，それ以外の層の活性化関数は Relu を用いた．具体的な構成，各層のノード数を図 1 に示す．

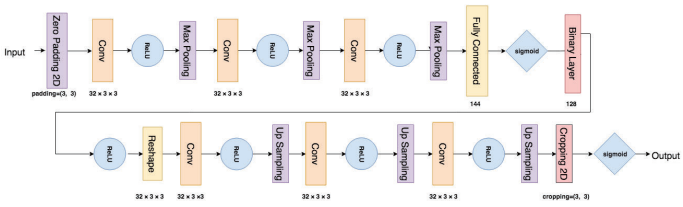


図 1: AE の構成

また，損失関数は式 (19) のように定義した．

$$Loss = \frac{1}{N}\sum_{n=1}^{N}[\log p(s_n) - \sum_{i=1}^{D}\min\left\{(1-b_i(s_n))^2, b_i(s_n)^2\right\}] \quad (19)$$

損失関数は AE の入力と出力の誤差を表す第 1 項と，バイナリ層における出力を 0 か 1 に偏るようにコストをかける正則化項から構成される．AE はエージェントの学習中にそれまでに観測した状態によって動的に更新を行う．実験を通して AE の更新は 3 ステップに 1 回, SimHash の出力のハッシュ値は 16 次元のベクトルとした．

以上の SimHash と AE を用いた手法により信頼度 τ を表現することで，RS を深層強化学習へ適用した．

5. MountainCar

既存手法と提案手法の比較のため，状態が極めて多くかつ報酬が疎である MountainCar タスクで実験を行った．

5.1 環境設定

環境は OpenAI Gym の MountainCar タスクを用いた．MountainCar はスタート位置の左右に二つの山があり，エージェントは台車を操作する．台車がゴールにたどり着くためには，一度ゴールと反対側の山を途中まで登り反動をつける必要がある．今回は報酬を疎にするため，ゴールに到達した時のみ報酬 1 を得るように MountainCar の設定を変更した．MountainCar では速度と位置情報により状態が表現されており， それらを等分割して離散化することで信頼度に使用した．また他手法との比較のため，離散化の必要のないハッシュ関数による信頼度も状態を等分割して離散化した場合と連続値の場合を別々に用いた．状態の分割数を変化させ，各手法による信頼度の表現の性能比較を行った．

Q 値の推定には DQN を使用し，近似するニューラルネットワークのノードは入力層 2 個（連続値），隠れ層は 128 個が 3 層，出力層 3 個とし，活性化関数は Relu，損失関数は HuberLoss，学習率 lr =5e-4，割引率 $\gamma = 0.99$ とした．リプレイメモリサイズは 50,000，バッチサイズは 32，ターゲットネットワークの更新頻度は 500 ステップとした．RS は全ての分割数設定と信頼度表現手法で 200 ステップ以内のゴールを目的として, $\aleph_G = 1/200$，E_{tmp} はエピソードの平均報酬として 報酬/ステップ数，$\zeta = 1$，$\gamma_G = 0.9$，$\alpha_\tau = 0.1$，$\gamma_\tau = 0.9$ とした．

5.2 結果

図 2 に各手法の分割数ごとの目的達成までの累計ステップ数の 10 シミュレーションの平均の結果を示す．縦軸は累計ステップ数，横軸は分割数とし，エピソード終了条件はゴールに到達したときのみとした．また, タスクのクリア条件を移動平均 200 ステップ以内の到達を良い行動系列の条件とし, 移動平均はエピソードごとのステップ数の 100 エピソード分の移動平均を用いた．分割数が増えるごとに状態数が増えているため，経験カウントの累計ステップ数が大幅に増加したのに対して，擬似カウントとハッシュ関数は少ない累積ステップ数でクリア条件を達成できている．このことから, 状態が極めて多い場合では経験カウントに比べて提案手法の擬似カウントとハッシュ関数で信頼度を表現した方法が有用であることが示せている．

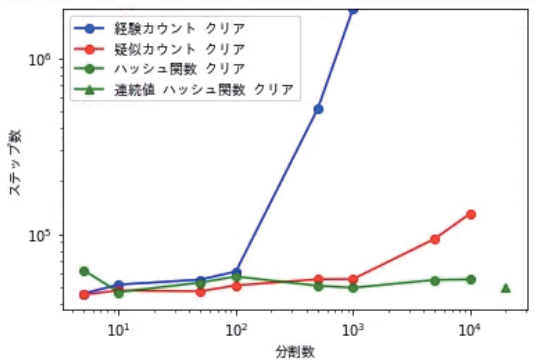


図 2: 擬似カウントと経験カウントを用いた RS の比較

6. SuboptimaWorld

SuboptimaWorld は準最適解が複数存在するタスクである．MountainCar の実験で状態の要素から信頼度を計算したが，SuboptimaWorld では画像から信頼度を計算し RS の学習が行えるか検証した．また，DQN で通常使われる ϵ-greedy と内発的動機付けの手法である MBIE-EB との比較も行った．

6.1 環境設定

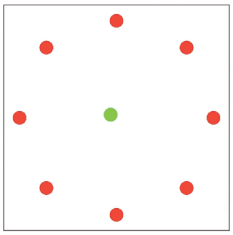
実験環境は連続状態を扱い，ゴールが複数あるタスクを用いた．このタスクは状態の要素として x 軸，y 軸の位置が $[0, 1]$ の連続状態で与えられる．図の赤い点のゴールは 8 つ存在し，報酬は $[1.0, 0.8, 0.8, 0.6, 0.6, 0.4, 0.4, 0.4]$ の 8 つの値がランダムで配置される．スタートの位置は中心付近でランダムに決められ，エージェントの行動は上下左右とその斜めの計 8 つの行動が存在する．各手法による信頼度の比較のため，Q 値の近似は簡易的に x 座標と y 座標を入力とした NN を用いた．

DQN の設定は，学習率 lr=1e-4，近似するニューラルネットワークのノードは入力層 2 個（連続値），隠れ層は 128 個が 3 層，出力層 8 個とし，他の設定は MountainCar の実験と同じものを使用した．RS は最大報酬の獲得を目的として $\aleph_G$=1，E_{tmp} は 1 エピソードの獲得報酬，ζ は擬似カウントを用いた RS は 0.01，ハッシュ関数+AE を用いた RS は 0.5 で，$\gamma_G = 0.9$，$\alpha_\tau = 0.1$，$\gamma_\tau = 0.9$ とした．

RS の信頼度は画像から計算するため，図 3 の画像をグレースケールに変換し，ピクセルを 42 × 42 へ平均値によるダウンサンプリングを行なった．擬似カウントの信頼度の計算では，各ピクセルのグレースケール値を 8 分割 (3bit) に変換し，

各ピクセルを状態の要素とし，各ピクセルの出現確率の積を状態の出現確率とした．

比較アルゴリズムとして，DQN で通常使われる ϵ-greedy と，擬似カウントとハッシュ関数+AE の論文で使われた内発的動機付け手法である MBIE-EB を擬似報酬として用いた ϵ-greedy を使用した．ϵ-greedy は初期値を $\epsilon = 1$ とし，定量的に減少させ 20000 ステップ以降は $\epsilon = 0.1$ で固定した．MBIE-EB のパラメータである β は擬似カウントを用いた場合では 0.01，ハッシュ関数+AE を用いた場合では 0.001 とした．MBIE-EB の報酬ボーナスは経験再生が行われる際に計算し報酬に加算した．



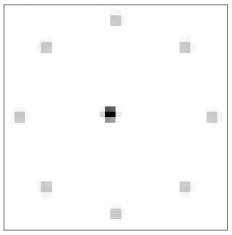


図 3: SuboptimaWorld　図 4: 加工した画像 (42 × 42)

6.2 結果

図 5 に，200000 ステップを 1 シミュレーションとして行い，10 シミュレーションを平均した結果を示す．縦軸は報酬で横軸はステップ数である．ϵ-greedy は局所解に陥った．それに対して，提案手法の二つの RS と擬似カウントを用いた MBIE-EB は，最大報酬 1 への行動系列を学習することができていることがわかる．

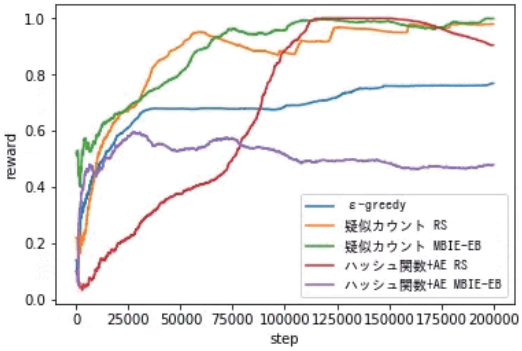


図 5: 提案手法 RS と比較アルゴリズムの獲得報酬

7. 考察

MountainCar の実験では，経験カウントを用いた RS がタスクをクリアするまでにかかった累計ステップ数が要素の分割数が増えるごとに一気に増加している．状態数が増えたことで観測の必要数が増え学習速度が低下した結果，安定してゴールにたどり着けなかったためだと考えられる．対して擬似カウントを用いた RS は，状態が抽象化された結果，新奇な状態が少なくなり，分割数が増えても対応できたと考えられる．ハッシュ関数を用いた RS は，SimHash を用いることで類似状態がある程度同一ハッシュ値にまとめられるため，状態を分割した場合と連続値を扱った場合の離散化の度合いが類似しタスククリアのステップ数が一定になったと考えられる．

SuboptimaWorld の実験では，提案手法 2 つを含む 3 つの手法が局所解に陥らずに学習できている．提案手法の 2 つの RS は，目標の報酬 1 のゴールの行動系列を見つけるまで満足できないため探索を続けたことで効率的な探索が行えたためだと考えらえる．ハッシュ関数+AE を用いた RS は，擬似カウントを用いた RS に比べて最大報酬 1 の行動系列の学習に時間がかかっている．AE は状態表現の学習を行う必要があるため，安定した状態の抽象化が行われるまでカウント数が安定しないためと考えられる．擬似カウントを用いた MBIE-EB は，不確実性に与えられるボーナス報酬により未探索状態を進んで探索し，ほぼ全ての報酬を観測できたことにより最終的に高い報酬を獲得する行動系列を学習することができたと考えられる．

カウントを用いた手法のうち，ハッシュ関数+AE を用いた MBIE-EB のみ局所解に陥っている．ハッシュ関数+AE を用いた RS と同様，カウント数が不安定であり，シミュレーション内でボーナスの加算が適切に行われなかったためと考えられる．疑似カウントによる手法は RS と MBIE-EB の両者とも安定した学習ができているが，ハッシュ関数+AE による手法は MBIE-EB のみ学習が進まなかった．RS と MBIE-EB に差がでた理由として，MBIE-EB ではボーナス報酬が直接 Q 値に影響を与えるため AE の学習初期の影響が強く，RS は Q 値に直接影響を及ぼさないため状態の不確実性を素早く利用できたと考えられる．

8. おわりに

本研究では RS を深層強化学習へ適用する方法を提案した．状態が極めて多い場合でも状態のカウントが可能な擬似カウントとハッシュ関数+AE により，RS の信頼度を表現し深層強化学習へ適用できた．今後の課題として，さらに擬似カウントとハッシュ関数+AE のカウント表現の性質の差を明らかにする必要がある．また RS の信頼度の表現方法は，より複雑な Atari2600 タスクへの適用や，今回の手法以外の状態の不確実性を測り定量化する方である RND などに関しても比較検証する必要がある．

参考文献

[Bellmare 2016] Bellemare, M.G. Srinivasan, S. Ostrovski, G. Schaul, T. Saxton, T. Munos, R.: Unifying Count-Based Exploration and Intrinsic Motivation, NIPS2016. (2016)

[Mnih 2013] Mnih, V. Kavukcuoglu, K. Silver, D. Graves, A. Antonoglou, I. Wierstra, D. Riedmiller, M.: Playing Atari with Deep Reinforcement Learning, *Nature*, 518(7540), 529–533. (2015)

[Simon 1956] Simon, H.A.: Rational choice and the structure of the environment, *Psychological Review*, 63(2), 129138. (1956)

[Tang 2017] Tang, H. Houthooft, R. Foote, D. Stooke, A. Chen, X. Duan, Y. Schulman, J. Turck, F.D. Abbeel, P: #Exploration: A Study of Count-Based Exploration for Deep Reinforcement Learning, NIPS2017. (2017)

[牛田 2017] 牛田 有哉, 甲野 佑, 高橋 達二: 生存を目的とする満足化強化学習, JSAI2017. (2017)

[高橋 2016] 高橋 達二, 甲野 佑, 浦上 大輔: 認知的満足化—限定合理性の強化学習における効用, 人工知能学会論文誌, Vol.31, No.6, pp.1-11. (2016)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

二値意思決定のためのヒヤリハットを用いた不均衡判別学習

Imbalanced Classification with Near-misses for Binary Decision-making

谷本 啓 *1*2*3 Akira Tanimoto　山田 聡 *1 So Yamada　竹之内 高志 *2*4 Takashi Takenouchi　鹿島 久嗣 *2*3 Hisashi Kashima

*1NEC NEC　*2理化学研究所 Riken　*3京都大学 Kyoto University　*4公立はこだて未来大学 Future University Hakodate

We consider a prediction-based decision-making problem, in which a binary decision corresponds to whether or not a numerical variable is predicted to exceed a given threshold. The final goal is to predict a binary label, however, we can exploit the numerical variable in the training phase as side-information. In addition, we focus on class-imbalanced situation. We investigate on an idea of using near-miss samples, which is specified by the numerical variable, to deal with the class-imbalance. We present the benefit of exploiting the side-information theoretically as well as experimentally.

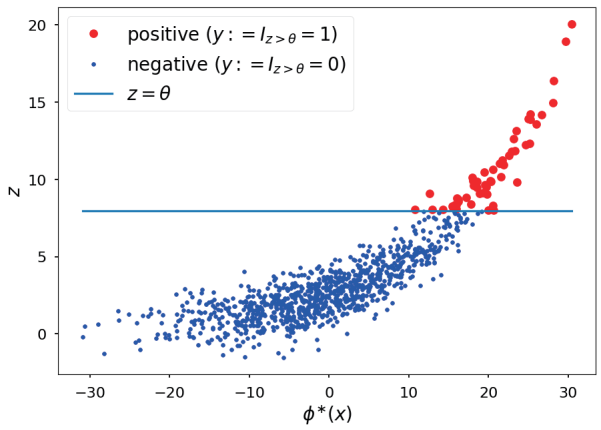


図 1: GLM モデルにより生成した人工データ．“正例度合い”z が訓練データ中に得られているが，最終的に得たい出力は y であるとき，z を不必要に予測することなく，しかし z の情報を利用して y の予測器を学習することを考える．

1 背景

我々は，不均衡データの判別問題であって，データに補助情報として “正例度合い” が含まれるようなものを考える．例えば水位情報に基づく洪水予測では，河川の水位が堤防の高さを超えた場合に洪水となり，その時点で避難を完了しているべき状況となる．よって，最終的に解きたい問題は河川水位が翌日や数時間後に堤防の高さを超えるかどうかという二値の予測である．しかし，これを通常の判別問題として解く場合，正例，すなわち実際に洪水が起こった事例数が相当程度必要となり，洪水予測のような安全にかかわる分野での適用は困難である．そこで我々は、河川水位が堤防の高さに近づいた事例を部分的に正例として活用することにより不均衡を改善することを考える．この場合，観測された河川水位を正例度合いと呼ぶ．

素朴なアプローチとしては，まず水位を予測し，その予測値に閾値を適用することによって避難すべきかどうかを判断するという方式が考えられる．しかし，あくまで最終的に行いたいのは避難すべきかどうかの判断だけであることを考えれば，中間問題である水位予測を解くことが悪影響する場合も考えられる．この方式については第 3.1節にて議論する．

一方で，正例数と負例数が不均衡なデータから判別器を学習することが難しいことはよく知られている．特に，正例が実際の事故や災害を意味するなど稀な現象と対応する場合，第 4章で解析するように，正例数がボトルネックとなる．

そこで我々はこのような，最終的に行いたい意思決定は二値であるが学習時には数値データが得られているような状況に対し，数値データを補助情報として扱うことによるサンプル効率的な判別学習を行う手法を提案する．理論解析及び実データでの実験によって既存の判別手法と提案手法を比較し，高度に不均衡な設定における提案手法の優位性を示す．

連絡先: 谷本 啓，ＮＥＣ，a-tanimoto@ay.jp.nec.com

2 問題設定

判別モデル $f : \mathcal{X} \to \mathcal{Y}$ の学習が我々の目的である．ここで，$\mathcal{X}$ は説明変数空間，$\mathcal{Y} = \{0, 1\}$ はラベル空間である．さらに，各ラベル $y_n \in \mathcal{Y}$ は次のように，正例度合い $z_n \in \mathbb{R}$ と与えられた閾値 θ から決定される．

$$y_n = \begin{cases} 1 & (z_n \geq \theta) \\ 0 & (z_n < \theta). \end{cases}$$

簡単のため，以後 $\theta = 0$ とする ($z_n - \theta$ をあらたな z_n とする)．ここで，z_n は学習時のみ各サンプルに対して与えられ，予測時には与えられない．すなわち，z_n は補助情報，とくに特権情報 [1] である．

評価指標としては，誤判別コストのクラス間の違いを考慮した重み付き精度 (WA: weighted accuracy) を用いる．

$$\mathrm{WA}(\{(z_n, f(x_n))\}) = \frac{1}{N} \sum_n C_+ I_{z_n \geq 0} I_{f(x_n) \geq 0.5} + C_- I_{z_n < 0} I_{f(x_n) < 0.5}, \quad (1)$$

ここで，N はサンプル数，C_+, C_- はそれぞれ正例と負例に対する誤判別コストであり，問題ごとに設定される定数である．とくに実験では，これらを頻度の逆数に比例する値に設定した場合，すなわち $C_+ = N/2N_+, C_- = N/2N_-$ の場合について

評価する．

$$\mathrm{BA}(\{(z_n, f(x_n))\}) = \frac{1}{N}\sum_n \frac{N}{2N_+} I_{z_n \geq 0} I_{f(x_n)\geq 0.5} + \frac{N}{2N_-} I_{z_n<0} I_{f(x_n)<0.5}, \quad (2)$$

ここで $N_+ = \sum_n I_{z\geq 0}, N_- = \sum_n I_{z<0}$ はそれぞれ正例数，負例数である．これを均衡化精度 (BA: balanced accuracy) と呼ぶ．$1-\mathrm{BA}$ は均衡化誤差率 (BER: balanced error rate) と呼ばれ，しばしば不均衡判別問題において採用される [2]．

3 関連研究

我々の問題設定は新規のものであるが，いくつかの関連する研究を以下に挙げ，違いを明確化する．

3.1 確率ラベルによる教示に基づく学習

まず，二値よりも質の高いラベルが与えられるという点では，確率ラベル (ソフトラベル)$\{s_n = p(y=1|x_n)\}$ が与えられる設定はよく研究されている [3, 4, 5]．この設定では，確率ラベル s に対するガウス過程回帰の適用 [5] や，サンプルペア間の確率ラベルの大小関係を用いたランク学習 [4] などにより学習のサンプル効率化が可能であることが示されている．確率ラベルはたとえば，クラウドソーシングにより集められたラベルを平均することにより与えられることが想定されている．我々の設定における正例度合い z は確率ラベル $p(y=1|x)$ と強い関係があると考えられるが，それそのものではない．そのためたとえば直接に z を回帰し，その予測値に閾値を適用する，すなわち $\hat{y} := I(\hat{z} \geq \theta')$ とすることで高精度な判別が可能となるかどうかはサンプル数や分布に依存し，性能は保証されない．

3.2 特権情報を用いた学習

二値のラベルに加えて学習時のみ各サンプルに与えられる情報であって，ラベルに強い相関を持つことが想定されるものは特権情報 (PI: privileged information) と呼ばれる．特権情報を用いた学習 (LUPI: learning using privileged information) は，はじめ SVM においてスラック変数を推定する目的で導入され [1, 6]，その後，一般化蒸留 (GD: generalized distillation)[7] により一般のモデルの学習に拡張された．GD では，まず “教師モデル” をラベルと PI $\{y_n, x_n^*\}_n$ から学習し，その後 “生徒モデル” f を以下の損失関数の最小化により学習する．

$$L_{S,T}^{\mathrm{GD}}(f) = \frac{1}{N}\sum_n \sigma(g_t(x^*)/T)\log f(x_n) + \sigma(-g_t(x^*)/T)\log(1-f(x_n)), \quad (3)$$

ここで，g_t は教師モデルの決定関数，T は温度と呼ばれるハイパーパラメタ，$\sigma(a) := 1/(1+\exp(-a))$ はシグモイド関数である．

第 4章にて説明する提案手法は，正例度合い z を PI とした GD と，クラス均衡化の組み合わせである．ただし，GD を含め LUPI は主に学習率の向上，すなわちサンプル数を増やしたときに期待損失が最適なモデルパラメタに対する期待損失へ収束する速さを問題としているのに対し，我々の目的は正例が少ない状況での精度向上である．

3.3 コスト考慮型学習

PI を用いない通常の設定における不均衡データの判別においてよく知られた従来手法の一つはコスト考慮型学習 [8] である．その損失関数はクラスごとの誤判別コスト C_+, C_- によって各サンプルを重みづけすることによって得られる．

$$L_S(f) = \frac{1}{N}\sum_n C_+ y\log f(x_n) + C_-(1-y)\log(1-f(x_n)). \quad (4)$$

コスト考慮型学習の損失関数はほぼ $1-\mathrm{WA}$ の凸緩和となっていることから，サンプル数が十分な状況では良い WA を達成する．しかし，正例数 N_+ が小さく正例の重み C_+ が大きいとき推定分散が大きくなる．第 4章では，GD とコスト考慮型学習の組み合わせによる提案手法の損失を導入し，その最小化における期待余剰損失の上界を与え，従来のコスト考慮型学習に対する優位性を議論する．第 5章では，実データを用いた実験によって従来のコスト考慮型学習と提案手法を様々な正例比率で比較し，正負例の偏りが非常に大きい場合における提案手法の優位性を実験的に示す．

4 提案手法

提案する損失関数は，GD 損失 (3) とコスト考慮型損失 (4) の組み合わせ，また GD の導入による正負例の期待重みの変化を再均衡化することにより，下記の代理損失として与えられる．

$$L_{S,T}(f) = \frac{1}{N}\sum_n C_{T,+}\sigma(z_n/T)\log f(x_n) + C_{T,-}\sigma(-z_n/T)\log(1-f(x_n)), \quad (5)$$

ここで $C_{T,+}, C_{T,-}$ はそれぞれ再均衡化されたコストパラメタで，下記で与えられる．

$$C_{T,+} = C_+\frac{p_+}{p_{T,+}}, \quad C_{T,-} = C_-\frac{p_-}{p_{T,-}}, \quad (6)$$

ここで p_+, p_- はそれぞれ正例比率，負例比率，$p_{T,+}, p_{T,-}$ はそれぞれ GD によるソフトラベルの有効正例比率，有効負例比率であり，$p_+ := \mathbb{E}[y], p_{T,+} := \mathbb{E}[\sigma(z_n/T)]$ のように与えられる．

上記の損失関数におけるソフトラベル $\sigma(z_n/T)$ は，パラメタ T を 0 に漸近させたとき元のラベル y に一致する，すなわち，$\sigma(z/T) \to I(z\geq 0) = y$ as $T \to 0$．よって，提案手法の損失関数はコスト考慮型学習の損失関数を $T\to 0$ の特殊ケースとして含む．

この損失関数の最小化に対する期待余剰損失は以下のように上から抑えられる．ただし，本解析においてはモデルクラスを有界線形クラスとする．

定理 4.1 (提案損失関数に対する期待余剰損失上界)．w_T^* を最適なパラメタ，すなわち期待代理損失を最小化するパラメタとし，$\hat{w} : \|\hat{w}\|_2 \leq B$ を経験代理損失 *(5)* を最小化するパラメタとする．また，説明変数 x は確率 1 で有界とする，すなわち，$p(\|x\|_2 \leq X) = 1$．このとき，期待余剰損失は以下のように上から抑えられる．

$$\mathop{\mathbb{E}}_S[L_T(\hat{w}_T) - L_T(w_T^*)] \leq \frac{2BX}{\sqrt{N}}\sqrt{C_+^2\frac{p_+^2}{p_{T,+}} + C_-^2\frac{p_-^2}{p_{T,-}}},$$

ここで，$\mathbb{E}_S$ は学習用サンプルのとり方に関する期待値とする．

証明は紙面の都合上割愛する．上記に対し，均衡化精度を最大化するコストパラメタ設定，すなわち

$$C_+ = \frac{1}{2p_+} \text{ and } \quad C_- = \frac{1}{2p_-}, \tag{7}$$

とすると以下を得る．

系 4.1.1 (均衡化コスト設定における期待余剰損失上界)．

$$\mathop{\mathbb{E}}_{S}[L_T(\hat{w}) - L_T(w_T^*)] \leq \frac{BX}{\sqrt{N}}\sqrt{\frac{1}{p_{T,+}} + \frac{1}{p_{T,-}}}. \tag{8}$$

上記定理および系から次のことがわかる．不均衡な設定のとき，すなわち正例が非常に少なく，かつ正例に対するコストが大きく設定されているとき，従来のコスト考慮型学習では正例比率 $\lim_{T\to 0} p_{T,+} = p_+$ が小さいことから上界が大きくなる．一方で，z の情報を用いてニアミス正例，すなわち z の値が比較的大きい負例を部分的に正例として扱うことによって有効正例比率 $p_{T,+}$ を増加できた場合，上記上界は改善される．

第 5章の実験結果からも，正負例比率が大きく偏っている場合に精度が改善されることが示される．

5 実験

第 4章で考察した提案手法の利点を実データを用いた実験により検証する．提案手法は実数値の正例度合い z が得られることを仮定しているため，実数値の目的変数を持つ回帰用データセットであり，かつ高度に不均衡な設定を含む実験を行うため，サンプル数の大きいデータセットとして GPU カーネルパフォーマンスデータセット [9, 10] を用いた．本データセットは様々な GPU のカーネルパラメタで演算を実行したときの経過時間が，各パラメタの組み合わせに対して 4 回ずつ測定されている．我々はこれを，高速な演算を実現するパラメタの組み合わせを見つける問題とした．すなわち，測定された経過時間 $\{\tau_1, \ldots, \tau_4\}$ から計算した平均実行速度 $z := \frac{4}{\sum_i \tau_i}$ を正例度合いとし，その上位 $100p_+\%$ が正例となるようそれぞれ閾値 θ を設定した．パラメタの種類，すなわち説明変数の次元は 14，平均実行速度に変換後のサンプル数は 60,400 である．正例度合い z の分布を図 2に示す．右裾部では概ね右肩下がりの分布形状となっている．このような分布であれば，右裾部に閾値 θ を設定したとき，ニアミス正例（負例であって正例度合いが高いもの）はニアミス負例よりも多くなる，すなわち適度なパラメタ T のもとで有効正例比率 $p_{T,+}$ は本来の正例比率 p_+ と比較して増加すると考えられる．

モデルには，提案手法，従来のコスト考慮型学習ともに L2 正則化項付きロジスティック回帰を用いた．正則化の強さと提案手法のハイパーパラメタ T の選択，および評価には入れ子式交差検証 [11] を用いた．その際，外側ループは 5 分割，内側ループは 2 分割とした．すなわち，データセットを 5 分割し，1 つを検証用，4 つを学習用とし，学習用データでさらに 2 分割交差検証によってハイパーパラメタを選択，その後選択したハイパーパラメタで学習用データ全体を用いて再度学習し，検証用データで検証を行う手続きを 5 回行った．さらに，分割方法を変えて 4 回ずつ前記操作を行い，計 20 回の検証を行った．

結果を図 3に示す．正例比率 p_+ が比較的大きい領域では提案手法は既存手法と同等の精度（BA）であるのに対し，正例比率が小さい領域では既存手法は精度が悪化する一方，提案手法では精度悪化が抑えられている．これは，提案手法では正例度合いの情報に基づいてニアミス正例を部分的に正例と扱うことにより有効正例比率 $p_{T,+}$ が高まり，期待余剰損失 (8) が軽減されたためと考えられる．

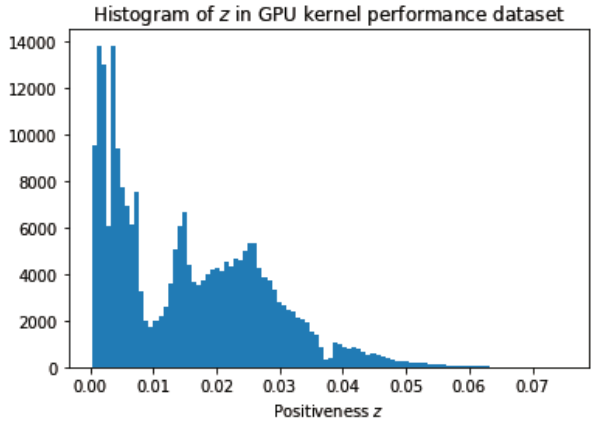


図 2: GPU カーネルパフォーマンスデータセットにおける正例度合い z のヒストグラム．

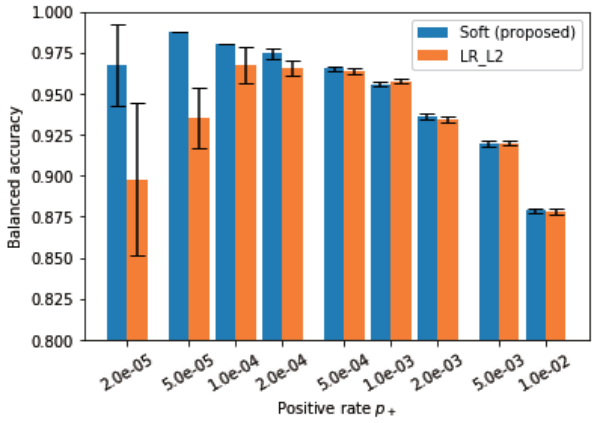


図 3: 提案手法と従来のコスト考慮型学習の均衡化精度の比較．高度に不均衡なとき（正例比率 $p_+ := \sum I(z \geq 0)/N$ が小さいとき）提案手法が高精度となっている．誤差バーは標準誤差を表す．

6 結論

我々は，実数値目的変数が与えられるが最終目的は判別であるという問題設定を新たに導入し，コスト考慮型学習と一般化蒸留の組み合わせによる損失関数を提案した．提案手法は既存のコスト考慮型学習と比べ，正負例比率が非常に偏っている場合でも均衡化精度の点で高性能となることを理論及び実験の両面から検証した．本手法は正例度合いが取得できるという強い仮定に依存している．一方で本結果は，災害や事故など正例が稀な現象に対応する場合でも，負例の中でも危険であった事例とその度合いを取得することができれば高精度な判別が可能となることを示唆し，そのようなデータの取得を推奨する．

参考文献

[1] Vladimir Vapnik and Akshay Vashist. A new learning paradigm: Learning using privileged information. *Neural networks*, 22(5-6):544–557, 2009.

[2] Xue-wen Chen and Michael Wasikowski. Fast: a roc-based feature selection metric for small samples and imbalanced data classification problems. In *Proceedings of the 14th ACM SIGKDD international conference on Knowledge discovery and data mining*, pages 124–132. ACM, 2008.

[3] Quang Nguyen, Hamed Valizadegan, Amy Seybert, and Milos Hauskrecht. Sample-efficient learning with auxiliary class-label information. In *AMIA Annual Symposium Proceedings*, volume 2011, page 1004. American Medical Informatics Association, 2011.

[4] Yanbing Xue and Milos Hauskrecht. Learning of classification models from noisy soft-labels. In *ECAI*, pages 1618–1619, 2016.

[5] Peng Peng, Raymond Chi-Wing Wong, and Phillp S Yu. Learning on probabilistic labels. In *Proceedings of the 2014 SIAM International Conference on Data Mining*, pages 307–315. SIAM, 2014.

[6] Vladimir Vapnik, Rauf Izmailov, Alex Gammerman, and Vladimir Vovk. Learning Using Privileged Information: Similarity Control and Knowledge Transfer. *Journal of Machine Learning Research memory of Alexey Chervonenkis*, 16:2023–2049, 2015.

[7] David Lopez-Paz, Léon Bottou, Bernhard Schölkopf, and Vladimir Vapnik. UNIFYING DISTILLATION AND PRIVILEGED INFORMATION. In *Proceedings of the International Conference on Learning Representations*, pages 1–10, 2016.

[8] Charles Elkan. The foundations of cost-sensitive learning. In *International joint conference on artificial intelligence*, volume 17, pages 973–978. Lawrence Erlbaum Associates Ltd, 2001.

[9] Cedric Nugteren and Valeriu Codreanu. Cltune: A generic auto-tuner for opencl kernels. In *Embedded Multicore/Many-core Systems-on-Chip (MCSoC), 2015 IEEE 9th International Symposium on*, pages 195–202. IEEE, 2015.

[10] Rafael Ballester-Ripoll, Enrique G Paredes, and Renato Pajarola. Sobol tensor trains for global sensitivity analysis. *arXiv preprint arXiv:1712.00233*, 2017.

[11] Sudhir Varma and Richard Simon. Bias in error estimation when using cross-validation for model selection. *BMC bioinformatics*, 7(1):91, 2006.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

物理過程に基づくニューラルネットワークを用いたモデル残差項の学習

Learning Model Discrepancy in Physics-guided Neural Networks

田中潤也 *1 Junya Tanaka　冨田 智彦 *2 Tomohiko Tomita　沼尾 正行 *3 Masayuki Numao　福井 健一 *3 Ken-ichi Fukui

*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熊本大学大学院先端科学研究部
Faculty of Advanced Science and Technology,Kumamoto University

*3大阪大学産業科学研究所
The Institute of Scientific and Industrial Research, Osaka University

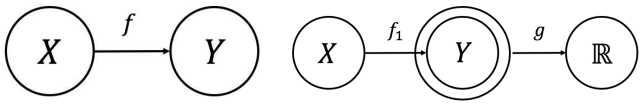
Recent machine learning models such as deep learning become complicated and difficult to understand the meaning of learned weights. And also, there is a possibility of obtaining output ignoring the prior knowledge because machine learning model is learned from the observed data including the noise outlier. Especially in the natural science field exploring the principle, non interpretable model cannot be a useful model unless the model has descriptiveness even if model could perform well with high accuracy. On the other hand, numerical simulation using physical model is difficult to predict long-term due to the model discrepancy. In order to solve such disadvantages, we focused on the method that integrate machine learning model and physical model. This paper proposes the algorithm that can predict two components, namely outputs based on the law of physics and their model discrepancy. As an example, we used on predicting winds in the upper troposphere from thermal wind equations.

1. はじめに

近年，観測データからパターンを取得し，未知のデータに対して予測・分類を行う機械学習が数多くの分野で使用されている．しかし，機械学習システムでは，ノイズ外れ値を含む観測データから学習しているため既知の法則性を無視した出力を得る可能性がある [1]．また，ニューラルネットワークに基づく深層学習では，予測・分類は高精度で行える一方で，学習モデルが複雑になり人間がモデルを解釈することが困難になるという欠点があった [2]．特に原理を探求する自然科学分野では，予測や分類において高い精度が得られたとしても，原理を理解できなければ有用なモデルを獲得できたとは言えない．　一方で，物理モデルによる数値シュミレーションでは，自然科学の法則性を満たす微分方程式を近似的に解くことで予測を行う．数値シュミレーションでは短期的な予測は高精度で行えるが，長期的な予測は高精度に行えないという欠点がある．これは数値解析で用いた近似値に含まれる誤差が時間発展とともに増幅するためである．

本研究では，自然科学分野で使用される物理モデルを機械学習モデルに統合することにより，このような問題点を解決する手法に着目した [3]．本稿では，予測したい変数のみを教師データとして与え，機械学習モデルからの予測値の中で物理モデルで表すことのできる支配的な要素と，物理モデルのモデル残差を表すことのできるアルゴリズムを提案する．例として，対流圏上層の風を温度風方程式から予測する例に着目した．対流圏上層の風ベクトルのみを教師データとして与え，温度風方程式に基づく地衡風成分とそれ以外の非地衡風成分の特徴を捉え，かつ高精度に予測できるアルゴリズムを提案する．本手法は，学習済みモデルの解釈を与える手法 [2] などとは異なり，損失関数に既知のモデルに基づく制約を導入し学習器の出力を制御することで，学習器に対してある種の透明性を与えている．

連絡先: 田中 潤也, 大阪大学, 産業科学研究所沼尾研究室,
〒 567-0047 大阪府茨木市美穂ヶ丘 8-1,
Tel: 06-6879-8426,Fax: 06-6879-8428,
E-mail: (surname)@ai.sanken.osaka-u.ac.jp



(a) 通常の教師あり学習（回帰問題）の枠組み　(b) 物理モデルによる制約を導入した枠組み

図 1: 既存および先行研究の枠組み

2. 問題設定

2.1 通常の教師あり学習（回帰問題）の枠組み

一般的な教師あり学習は図 1(a) で示すように，n 個の入力 $x_i \in X$ と出力 $y_i \in Y$ の組みを学習データ $D = \{(x_1, y_1), \cdots, (x_n, y_n)\}$ として，この学習データから写像関数 $f : X \mapsto Y$ を得ることである．以下に示すように損失関数 $\ell : Y \times Y \mapsto \mathbb{R}$ を最小化する関数 f^* を学習データを用いて求める．

$$f^* = \arg\min_{f \in \mathcal{F}} \sum_{i=1}^{n} \ell(f(x_i), y_i) \tag{1}$$

2.2 物理モデルによる制約を導入した枠組み

図 1(b) で示すように，物理モデルを制約として損失関数に加えることにより，教師データなしで写像関数 $f_1 : X \mapsto Y$ を得る先行研究がある [4]．物理法則に従う制約を加えた損失関数 $g : X \times Y \mapsto \mathbb{R}$ を使用することによって，出力 y_i の構造

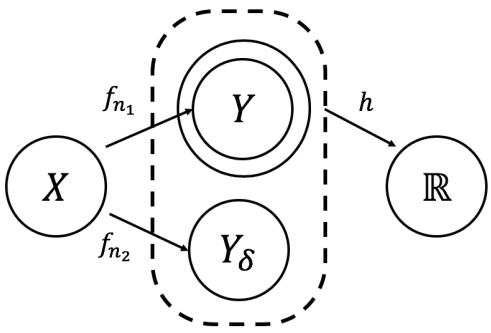


図 2: 物理モデルとモデル残差項成分を導入した枠組み

に関する事前知識をモデル化する．この枠組みでは，事前知識が関数の中で固有の性質を持っているという前提のもと，直接 y_i を与えず関数 f_1^* を求める．

$$f_1^* = \arg\min_{f_1 \in \mathcal{F}} \sum_{i=1}^{n} g(f(x_i), x_i) \tag{2}$$

2.3 物理モデルとモデル残差項成分を導入した枠組み

2.2 節では予測する現象が既知の物理法則によく従っていると仮定している．しかし，実際の物理現象では物理法則を満たす部分だけでなく，法則に従わない物理モデルのモデル残差が存在する．本研究では，入力 x_i と対応する出力 y_i，物理モデルで使用され計算により導くことができる変数 p_i を用いて物理法則に従う損失関数 $h : Y \times Y \times P \mapsto \mathbb{R}$ を使用する．図 2 で示すように，法則に従う出力 y_i を得ることができる関数 $f_{n1} : X \mapsto Y$ と，その物理モデルのモデル残差の出力 $y_{\delta_i} \in Y$ を得られる関数 $f_{n2} : X \mapsto Y$ を同時に取得できるアルゴリズムを提案する．このモデル残差項は，教師データの正解出力値と物理モデルの出力値の差とする．二つの関数はそれぞれ以下に示す損失関数から取得される．

$$(f_{n1}^*, f_{n2}^*) = \arg\min_{f_{n1}, f_{n2} \in \mathcal{F}} \sum_{i=1}^{n} h(f_{n1}(x_i) + f_{n2}(x_i), y_i, p_i) \tag{3}$$

3. 関連研究

本章では，自然科学分野で使用されている物理モデルと機械学習を統合させることによって，双方の様々な課題を解決している先行研究について述べる．

3.1 ドメイン知識に基づく教師あり学習

Stewart らは，単純な運動方程式や既知のルールなどのドメイン知識を畳み込みニューラルネットワークの損失関数に制約条件として統合させることによって，教師データなしの観測データから教師あり学習を行う枠組みを提案した [4]．深層学習などのニューラルネットワークを用いた機械学習モデルは，高い精度で予測・分類を行える一方で，大量の教師データが必要であるという問題があった．事前に観測データに潜むパターンがある程度把握できている場合に，ドメイン知識から制約を作り教師データなしで学習できる枠組みを提案している．一例として，運動方程式を制約として損失関数に加えることによって物体の放物線運動をラベル無しで推定しているものがある．

この先行研究では，教師あり学習の問題点である教師データを使用せずに学習する方法に焦点が置かれ，高精度な予測が行えている訳ではない．また，扱っている例も単純な運動方程式やルールなど，シンプルなものが多い．本研究では放物運動より複雑な風予測を対象とすしており，また学習データも大規模なものを使用している．

3.2 科学的な事前知識による学習の設計

Bzenac らは，海面の温度予測という例を用いて，物理モデルから得られた事前知識により効率的なモデルを設計する手法について提案した [5]．外乱のない理想的な海面の温度変化は，移流拡散方程式で近似できると仮定できる．学習モデルの出力を直接温度変化とするのではなく，移流拡散方程式の変化量を予測することにより，精度の良い学習モデルを構築する手法を提案している．物理モデルに基づく数値シュミレーションでの予測は，直近の時間の予測値は精度よく予測を行える一方で，時間発展とともに誤差が拡大するという問題があった．Bzenac らの提案した手法では，一般的な機械学習の予測値だけでなく，数値シュミレーションでの予測値と比較してもこのような問題に対して有用であることが示されている．

この先行研究では，移流拡散方程式が支配的となる領域になるように季節性等を消去する前処理が行われている．また，移流拡散方程式のモデル残差項は考慮されていない．

3.3 機械学習による RANS モデルのモデル残差項の推定

物理モデルによる数値シュミレーションは様々な工業分野でも応用されている．レイノルズ平均モデル（Reynolds Averaged Navier-Stokes：RANS）シミュレーションは，航空宇宙船やガスタービンの設計，最適化，評価に広く使用されてる．しかし，RANS モデルは近似モデルであり，モデルの信頼性は変数の値に依存し，使用するドメインによって大きなばらつきがある．Wu らは，機械学習モデルによりこのような物理モデルの法則性に従わないモデル残差項を推定する手法を提案した [6]．データからモデル残差項を推定することにより RANS モデルによる高精度な予測を行った．この先行研究では，機械学習モデルは全体の予測値ではなくモデル残差項のみを推定している．一方本研究では不一致成分のみではなく，同時に物理法則に従う成分の出力も得ることができるアルゴリズムを提案している．両方を同時に機械学習で扱うことで，直接観測可能な変数と，方程式で扱う物理量（運動量など）を結び付けることができ，設計や最適化にフィードバックをかけやすくなるという利点がある．

4. 温度風方程式を用いた地衡風予測

本研究では温度風方程式を用いた対流圏上層の風を予測するタスクに着目した．本研究では風ベクトルのみを教師データとして与え，温度風方程式に基づく地衡風成分とそれ以外のモデル残差項，すなわち非地衡風成分の特徴を捉え，かつ高精度に予測できる手法を提案した．微分方程式で近似することができること，またデータセットが容易に入手できるという観点から，温度風方程式を使用した．以下に地衡風と温度風・温度風方程式の関係性について述べる．

4.1 地衡風

地衡風とは，気圧傾度力とコリオリ力の釣り合いの状態で吹いている風である．気圧差がある平面において，気圧傾度力に比例する強さの地衡風が発生する．気圧傾度力は気圧の高い方から低い方へ向かって等圧線に直角に働き，コリオリの力は北半球では風の進行方向右向きに（南半球では左向きに）働く．それゆえ地衡風は等圧線に沿って北半球では気圧の高い方を右

手に（南半球では左手に）見る向きに吹く．中緯度上空では，この地衡風と実際の風の間に 10 パーセント程度の相違がある．この相違分，すなわち非地衡風成分が大気に収束・発散を生み，さらに鉛直流を生み，この鉛直流により雲ができ雨が降る．

4.2 温度風

温度風とは大気内の温度差が原因として生じる，高度の異なる 2 点での地衡風の差分ベクトルのことである [7]．あくまで差のことであり，実際にそのような風が吹いているわけではない．気圧が一様であるが気温は一様ではない平面を考えたとき，気圧が一様であるから気圧傾度力は働かず，この平面上では風は吹かない．一方で静水圧平衡の関係式から気温が低いところほど高度が上がった時の気圧の下がり方は大きい．そのため，その平面の上空では気温の高いところの上空が高気圧，気温が低いところの上空が低気圧となり，地衡風の関係より北半球では気温の高いところを右手（南半球では左手）に見るように風が吹く．

4.3 温度風方程式を用いた地衡風予測

温度風方程式を用いた対流圏上層の風を予測するタスクに着目した．二点間の気圧 p_{i-1}，p_i（$p_{i-1} < p_i$ 上の風ベクトルを $\mathbf{V_{p_{i-1}}}$，$\mathbf{V_{p_i}}$ とし，温度風方程式を用いた対流圏上層の風の予測式は以下のようになる．

$$\mathbf{V_{p_{i-1}}} = \mathbf{V_{p_i}} + \frac{R}{F} \ln \left[\frac{p_i}{p_{i-1}} \right] \mathbf{k} \times \nabla_p \bar{T} + \Delta \mathbf{V_{p_{i-1}}} \qquad (4)$$

$\bar{T}$ は二気圧間の積算平均気温，R は乾燥空気の比気体定数，F はコリオリパラメータ，$\mathbf{k}$ は単位ベクトルを表す．温度風方程式での支配的な法則性を持つ要素は温度勾配 $\nabla_p \bar{T}$ であり，$\Delta \mathbf{V_{p_{i-1}}}$ が温度風方程式によるモデル残差項である．

5. 提案手法

提案手法の全体のアーキテクチャを図 3 に示す．図で示すように，f_{n1}，f_{n2} はそれぞれ二つのネットワーク $SharedNN$，$NonSharedNN$ からなる．それぞれのネットワークには共通した特徴を学習する $SharedNN$ をもつ．一般的に，物理モデルで表すことができないモデル残差の成分は物理モデルの支配的な成分と関係し合っていることが多い．提案手法では，$SharedNN$ を用いることによって，この関係性を学習できるようにしている．f_{n1} と f_{n2} を交互に学習させパラメータを更新するが，$SharedNN$ のパラメータのみ両方の学習で更新する．これにより，支配的な要素と物理モデルで表すことのできないそれ以外の要素の共通した特徴を学習できるようにした．$SharedNN$ は五層の畳み込み層，$NonSharedNN$ はそれぞれともに五層の逆畳み込み層からなる．また，フィルタサイズは全て 3×3 とした．各層の出力の値には活性化関数である LeakyRelu 関数を加えている．

次に，f_{n1}，f_{n2} の損失関数について説明する．f_{n1} は物理法則に従う成分を表す．温度風方程式を用いた上層の風予測のタスクでは，物理法則に従う支配的な成分は地衡風成分である．地衡風成分の中で最も支配的な成分は温度成分である．そこで，f_{n1} からの出力は温度成分とし，R，f，p_{i-1}，p_i（$p_{i-1} < p_i$）は計算により与えられるものとする．f_{n1} からの出力を $\hat{f_{n1}}(x_j)$ とし，損失関数を式 (5) のように定義した．

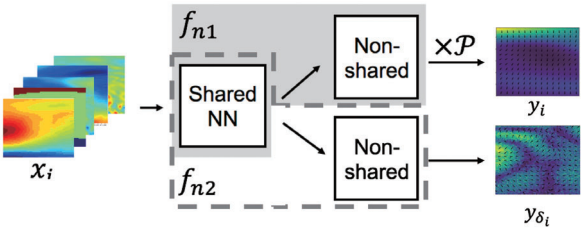


図 3: 全体のアーキテクチャ

$$\begin{aligned} \mathbf{L_{f_{n1}}} &= \sum_{i=1}^{k} |\mathbf{V_{p_{i-1}}} - \hat{\mathbf{V}}_{\mathbf{p_{i-1}}}| \\ &= \sum_{i=1}^{k} \sum_{j=1}^{n} |\mathbf{V_{p_{i-1}}} - \{\mathbf{V_{p_i}} + \frac{R}{F} \ln(\frac{p_i}{p_{i-1}}) \nabla \hat{f_{n1}}(x_j)\}|. \end{aligned} \qquad (5)$$

f_{n1} の学習では，式 (5) で示すようにモデル残差項成分を考慮せずに学習を行う．次に，f_{n2} はモデル残差項成分を表す．温度風方程式を用いた上層の風予測のタスクでは，モデル残差項成分は非地衡風成分である．f_{n2} からの出力を $\hat{f_{n2}}(x_j)$ とし，損失関数を式 (6) のように定義した．

$$\begin{aligned} \mathbf{L_{f_{n2}}} &= \sum_{i=1}^{k} |\mathbf{V_{p_{i-1}}} - \hat{\mathbf{V}}'_{\mathbf{p_{i-1}}}| \\ &= \sum_{i=1}^{k} \sum_{j=1}^{n} |\mathbf{V_{p_{i-1}}} - \{\mathbf{V_{p_i}} + \frac{R}{F} \ln(\frac{p_i}{p_{i-1}}) \nabla f_{n1}(x_j) + \hat{f_{n2}}(x_j)\}|. \end{aligned} \qquad (6)$$

f_{n2} の学習では，式 (6) で示すように f_{n1} で計算した残差を計算する．また，この時 $\nabla f_{n1}(x_j)$ の値を使用するが，f_{n1} に関しては誤差逆伝播を行わず，f_{n2} のみ誤差逆伝搬を行いパラメータを更新する．この二つの損失関数により，式 (5) によりまず物理法則に従う部分（地衡風成分）を学習し，式 (6) により残りのモデル残差項成分（非地衡風成分）を学習する．

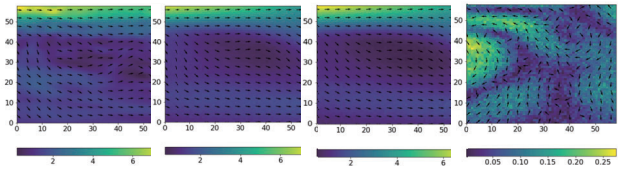
6. 実験

6.1 データセット

データセットには，ERA-Interim を使用した．ERA-Interim は全世界の気象に関する様々な変数からなるデータセットであり，データ同化を用いて取得されている [8]．ERA-Interim は完全な観測データではないが，現在手に入る最も詳細なデータであるため使用した．一カ月の月平均データを使用しており，学習データとして 1979 年 1 月から 2009 年 12 月までを使用し，テストデータとして 2010 年 1 月から 2016 年 12 月までを使用した．また，本実験では中緯度で表面が比較的均一な領域に着目するため太平洋上の北緯 30 度～北緯 75 度，西経 150 度～東経 150 度の範囲のみ使用した．解像度は経度・緯度共に 0.75 度であり，空間格子数は 60 × 60 点とした．高さ方向は 850hPa～150hPa までの 16 点を使用した．また，特徴量として気流，ジオポテンシャル，渦位，湿度を使用した．

6.2 比較手法

提案手法との比較手法として，ERA-Interim の風の速度を教師データとして与え，直接観測値を予測するモデルを用い



(a) (b) (c) (d)

図 4: 各出力値と観測値の定性的評価．(a) 観測値 (正解) (b) 提案手法による出力 ($f_{n1}+f_{n2}$) (c) 物理モデル成分の出力 f_{n1} (d) モデル残差項の出力 f_{n2}

た．また，学習率や学習回数は同一とし，同じネットワークとなるように五層の逆畳み込み層・畳み込み層からなる CNN を使用した (ACNN)．この他に，温度風方程式のみを用いて予測したもの (TWE) も比較手法として使用した．

6.3 実験内容

提案手法の有用性を検討するため，以下の実験を行った．ERA-Interim の上層と下層の風の強さの差分と，提案手法による地衡風成分と非地衡風成分 (式 (7),(8)) の差分，ERA-Interim の上層と下層の風の強さの差分を教師データとして学習させた比較手法 (ACNN) と，温度風方程式のみで導かれた値について，Root Mean Squared Error による定量的評価および定性的評価を行った．

7. 結果

7.1 定量的評価

RMSE を比較した結果を表 1 に示す．提案手法の精度がもっとも高く，次いで ERA-Interim を教師データとした CNN，温度風方程式を用いた計算結果の順となった．

表 1: Average RMSE

Method	RMSE	SD
Proposed	0.652	0.039
ACNN	0.679	0.038
TWE	1.682	0.182

7.2 定性的評価

図 4(a) および図 4(b) より，定量的評価だけでなく定性的評価でも特徴を捉えた予測が行えていることがわかる．提案手法による物理モデルに基ずく出力と，物理モデルに基づかない出力値の一例を図 4(c) と図 4(d) に示す．図 4(c) では法則に従う安定した地衡風成分が得られており，図 4(d) では，法則性に従わないカオス的な成分が抽出できていることがわかる．気象学における知見では，温度風方程式の残差は本実験の対象領域においては 10 パーセント程度であり，そのベクトルは収束・発散の方向であることが知られており，図 4(d) の提案法によるモデル残差項の出力分布と一致する．定量的評価・定性的評価の結果から，提案手法は精度を保ったまま，物理法則に従う成分と従わない成分 2 つを分解して出力可能であることがわかる．

8. まとめ・今後の展望

本研究では，自然科学分野で使用される物理モデルを機械学習モデルに統合することにより，機械学習の問題点を解決する手法に着目した．本稿では，機械学習モデルからの予測値の中で物理モデルで表すことのできる支配的な要素と，物理モデルで表すことのできないそれ以外の要素を得られるアルゴリズムを提案した．例として，対流圏上層の風を温度風方程式から予測する例を使用し，実験の結果，他の手法と比較し精度を保ったまま，予測値の中で物理モデルで表すことのできる支配的な要素と，物理モデルで表すことのできないモデル残差項を獲得できていることがわかる．

今後は物理モデルの支配的な要素と，物理モデルで表すことのできないモデル残差項の共通した特徴を含む $SharedNN$ の解析を行っていく．また，本稿ではモデル残差項の定性的な評価のみ行っており，定量的な評価は行っていない．データ駆動科学では今後モデル残差項を支配する原理の究明が求められる．今後はモデル残差項成分の定量的な評価も行っていく．現在本研究では上層の風の強さを推定する問題を扱っている．今後は時間と空間に関する偏微分方程式（エネルギー保存則）など数多くの現象を扱えるよう拡張していく．

謝辞

本研究は物質・デバイス領域共同研究拠点の支援により実施された．

参考文献

[1] Lazer, David and Kennedy, Ryan and King, Gary and Vespignani, Alessandro: The Parable of Google Flu: Traps in Big Data Analysis, pp.1203-1205, *Science (2014)*.

[2] Marco Tlio Ribeiro, Sameer Singh and Carlos Guestrin: "Why Should I Trust You?": Explaining the Predictions of Any Classifier, pp.1135-1144, *KDD (2016)*.

[3] A. Karpatne, G. Atluri, J. H. Faghmous, M. Steinbach, A. Banerjee, A. Ganguly, S. Shekhar, N. Samatova and V. Kumar : Theory-Guided Data Science: A New Paradigm for Scientific Discovery from Data, pp.2318-2331, *IEEE TKDE (2017)*.

[4] Russell Stewart and Stefano Ermon: Label-Free Supervision of Neural Networks with Physics and Domain Knowledge, pp.2576-2582, *AAAI(2017)*.

[5] de Bezenac E Pajot A Gallinari P: Deep Learning for Physical Processes: Incorporating Prior Scientific Knowledge, pp.2576-2582, *ICLR(2018)*.

[6] Jian-Xun Wang, Jin-Long Wu, and Heng Xiao: Physics-informed machine learning approach for reconstructing Reynolds stress modeling discrepancies based on DNS data, pp.2576-2582, *PHYSICAL REVIEW FLUIDS(2017)*.

[7] John Marshall, Alan Plumb and Lodovica Illari: Thermal wind, *MIT PAOC(2003)*.

[8] Paul Berrisford, Dick Dee, Paul Poli, Shinya Kobayashi, Sakari Uppala and Adrian Simmons: The ERA-Interim archive, ECMWF. (2011).

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

評価傾向の差異を考慮した分散表現による協調フィルタリング

Collaborative filtering based on distributed expression considering differences in evaluation trends

*1後藤 亮介 Ryousuke Goto　藤波 英輝 Hideki Fujinami　楊 添翔 Tianxiang Yang　後藤 正幸 Masayuki Goto

早稲田大学理工学術院
Facutly of Science and Engineering, Waseda University

Recently, the preferences of users using EC sites are diversifying. Therefore, a recommender system that grasps the preferences of each user and recommends items matching with the preferences became more and more important in bussiness activities. In the conventional recommendation proposed by Kuzmin, the items are divided into two groups depending on whether or not a user highly evaluated each item. Then, the same item group is regarded as one purchase series and learned by a single model. However, if items with different evaluation tendencies are learned by a single model, evaluation tendencies for items can not be properly expressed. In this research, we propose a recommender system that reflects users' preferences by expressing items with different two evaluation trends by different models. Finally, by applying the proposed method to the movie evaluation history data and comparing it with the conventional method, we show the effectiveness of our proposal.

1. 研究背景と目的

近年，情報技術の発展に伴い，EC サイトが取り扱うアイテム数が増加し，利用するユーザの嗜好も多様化している．そのため，EC サイトを運営する企業にとって，過去の購買履歴データから各ユーザの嗜好を把握し，嗜好に合致したアイテムを提示するための推薦システムは重要な Web マーケティング技術の 1 つになっている．また様々な EC サイト上では，評価履歴データという形で，ユーザが購買したアイテムに対して満足したか否かを判断できる評価値が導入されている．

推薦手法の 1 つとして，嗜好が似ているユーザに同じものを推薦する協調フィルタリング [神嶌 2003] がある．協調フィルタリングの中には，評価履歴データを用いて学習し，未評価アイテムの中で予測評価値の高いアイテムを推薦するアイテムベース協調フィルタリングがある．評価履歴が付いていない購買履歴データを用いて学習した場合，購入したアイテムにユーザが満足しているかどうかが分からない．しかし，評価履歴データを用いることで，選択したアイテムが好きか嫌いかを考慮することができるため，ユーザの嗜好をより反映した推薦システムを実現することができる．評価履歴データを用いたアイテムベース協調フィルタリング手法の 1 つに，Kuzmin の手法 [Kuzmin 2017] がある．この手法は，Item2Vec [Barkan 2016] をベースとした未評価アイテムの評価値予測モデルであり，Item2Vec に入力する学習データに対する前処理として，評価値をもとにデータを分割している．過去に評価を付けた全アイテムに対する評価値の平均値をユーザ毎に算出し，平均値以上の評価値が付与されたアイテムを“高評価アイテム群”，平均値未満の評価値が付与されたアイテムを“低評価アイテム群”と定義している．そして，Item2Vec の学習を行う際，同じユーザに評価され，かつ同じアイテム群に分類されたアイテムの分散表現が類似するように学習を行う．その際，Kuzmin の手法では，高評価アイテム群と低評価アイテム群を同時に Item2Vec で学習し，単一の意味空間を構成している．しかし，ユーザが対象アイテムに対して高評価する理由と，低評価する理由は異なると考えられる．そのため，それらを単一のモデルで表現するのではなく，別々のモデルで表現することで，ユーザの嗜好をより捉えたアイテムの分散表現が可能になると考えられる．

そこで本研究では，各ユーザに対して与えられる高評価アイテム群と低評価アイテム群を，それぞれ独立に学習し，異なる意味空間を構成する．そして，これらを統合する形で評価値予測を行う手法を提案する．また，提案手法を映画評価履歴データに適用し，従来手法と比較することで，提案手法の有効性を検証する．

連絡先: 後藤 亮介，早稲田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　pswonder@akane.waseda.jp

2. 準備 - Item2Vec

自然言語処理の分野において，単語を低次元の意味空間上のベクトルで表現する手法として Word2vec [Mikolov 2013] が知られている．ここで Word2vec をアイテムの分散表現モデルに援用した手法が Item2Vec である．ユーザが過去に購買した全アイテムを購買系列として，あるアイテムは，同じ購買系列中の他のアイテムから予測できると仮定する．そして，注目アイテムベクトルと周辺アイテムベクトルとの内積を大きくするように各アイテムベクトルの学習を行う．また，学習の進行を高速化し，分散表現の精度を高めるために，ネガティブサンプリング [Mikolov 2013] が一般的に用いられている．ネガティブサンプリングでは，全アイテムから確率的にアイテムのサンプリングを行うノイズ分布をあらかじめ定義し，注目アイテムに対してそのアイテム系列とは関係なく獲得されるアイテム（ネガティブアイテム）をこのノイズ分布に従ってサンプリングする．そして，ネガティブアイテムと注目アイテムとの内積を小さくするように各アイテムベクトルを更新する．

いま，アイテム数を N，ユーザ数を M とし，全アイテム集合を $\mathcal{I} = \{i_n : 1 \leqq n \leqq N\}$，全ユーザ集合を $\mathcal{U} = \{u_m : 1 \leqq m \leqq M\}$ とする．また，ネガティブサンプリング数を K とする．ユーザ u_m が j 番目に購買したアイテム $x_{m,j} \in \mathcal{I}$ を表す意味空間上のベクトルを $\boldsymbol{v}_{m,j}$ とし，ある 1 つの周辺アイテム $x_{m,l} (l \neq j) \in \mathcal{I}$ を表すベクトルを $\boldsymbol{v}_{m,l}$ とする．また，ネガティブアイテム $y^k_{m,j} \in \mathcal{I} (1 \leqq k \leqq K)$ のベクトルを $\boldsymbol{s}^k_{m,j}$ で表す．このとき，注目アイテム $x_{m,j}$ に対する周辺アイテム

への損失関数は式 (1) で定義される．

$$Loss(x_{m,j}, x_{m,l}) = \log(\sigma({\boldsymbol{v}_{m,j}}^T \cdot \boldsymbol{v}_{m,l})) + \sum_{k=1}^{K} \log(\sigma(-{\boldsymbol{v}_{m,j}}^T \cdot \boldsymbol{s}^k_{m,j})) \quad (1)$$

ただし，$\sigma(\cdot)$ はシグモイド関数を表す．ユーザ u_m の全購買アイテム数を e_m とすると，学習データ全体における損失項は以下の式 (2) で定義される．

$$Loss_{All} = \sum_{m=1}^{M} \sum_{j=1}^{e_m} \sum_{l \neq j}^{e_m} Loss(x_{m,j}, x_{m,l}) \quad (2)$$

3. 従来手法 - Kuzmin の手法

従来の Item2Vec は各ユーザの購買系列を 1 つの入力データとして学習を行う手法である．仮に，Item2Vec を評価の有無のデータにそのまま適用すると，あるユーザが高評価したアイテムと低評価したアイテムが同じように扱われて学習されてしまうという問題点がある．そこで，Kuzmin の手法では，各ユーザの平均評価値を閾値として，全アイテムを高評価アイテム群と低評価アイテム群に分割する．そして，同一アイテム群を 1 つの購買系列と捉えて Item2Vec の学習を行う．これにより，同じユーザに選択されていて，かつ似た評価がされているアイテム同士が，類似したベクトルとなるように分散表現が学習される．そして，得られたアイテムベクトル同士の類似度を用い，式 (3) によって予測評価値を算出する．

$$\hat{r}_{m,x} = \eta_x + \frac{\sum_{\tilde{x} \in \bar{\mathcal{I}}_m} Sim(\tilde{x}, x) \times (r_{m,\tilde{x}} - \eta_{\tilde{x}})}{\sum_{\tilde{x} \in \bar{\mathcal{I}}_m} |Sim(\tilde{x}, x)|} \quad (3)$$

ここで，$\hat{r}_{m,x}$ はユーザ u_m のアイテム $x \in \mathcal{I}$ に対する予測評価値，η_x は全ユーザのアイテム x に対する平均評価値，$Sim(\tilde{x}, x)$ はアイテム $\tilde{x}$ と x を表すベクトルのコサイン類似度，$\bar{\mathcal{I}}_m \in \mathcal{I}$ はユーザ u_m が評価した中でアイテム x と類似度が高いアイテム集合とする．そして，最終的に各ユーザに対して予測評価値が上位のアイテムを推薦することで，評価値を考慮した推薦システムを実現している．

4. 提案手法

4.1 概要

従来の Kuzmin の手法では，評価値の高いアイテムと低いアイテムを同一のモデルで学習するため，得られる意味空間は単一である．しかし，ユーザの評価行動の背後には多様な嗜好が存在している．例えば，1 人のユーザに関して考えた場合も，あるアイテムに対して好きと認識するに至るまでのメカニズムと，嫌いと認識するに至るまでのメカニズムは異なると考えられ，これらを単一のモデルで表現することは困難である可能性がある．例えば，ある映画 a,b は共に「アクションシーンが面白い」という理由で高評価されやすいが，一方，映画 a は「ストーリがつまらない」，映画 b は「俳優が魅力的ではない」という理由で低評価されやすいというように，高評価では同一の評価基準の 2 つの映画でも，低評価では評価基準が異なる場合がある．この場合，映画 a と b を単一のモデルで表現した際に，高評価される基準で類似度が高い映画と低評価される基準で類似度が高い映画が異なり，学習がうまくできないことが考えられる．

そこで本研究では，高評価アイテム群と低評価アイテム群に関して，それぞれ独立の意味空間を構成する (以下，高評価ベクトル空間，低評価ベクトル空間と呼ぶ)．すなわち，高評価アイテム群のみを学習させ，高評価アイテム群に特化した分散表現を獲得できるモデルと，低評価アイテム群のみを学習させ，低評価アイテム群に特化した分散表現を獲得できるモデルを獲得する．各アイテム群に対して独立に意味空間を構成することで，評価による意味の違いを捉えたベクトルが得られると考えられる．そして，それぞれのモデルから得られた分散表現を統合する形で評価値の予測を行うことで，より高精度な推薦システムの実現を図る．

4.2 提案手法のアルゴリズム

提案手法のアルゴリズムを以下に示す．

STEP1: アイテム評価系列の分割

各ユーザに対して，ユーザが付与した全評価値の平均を算出する．そして，算出した平均評価値よりも高く評価されているアイテムと低く評価されているアイテムに分割する．

STEP2: 意味空間の構成

STEP1 で得られた各アイテム群を学習データとし，Item2Vec を学習する．この際，高評価アイテム群と低評価アイテム群はそれぞれ独立のモデルで学習を行う．

STEP3: 2 つの意味空間での予測評価値の算出

各意味空間上のアイテムベクトル同士の類似度を用いて，式 (3) により別々に予測評価値を算出する．

STEP4: 予測評価値の算出

式 (3) によって求めた各予測評価値の加重平均により，最終的な予測評価値を式 (4) で算出する．

$$\hat{r}_{m,x} = \alpha \times \hat{r}^{(low)}_{m,x} + (1 - \alpha) \times \hat{r}^{(high)}_{m,x} \quad (4)$$

ここで，$\hat{r}_{m,x}$ はユーザ u_m のアイテム x に対する予測評価値，$\hat{r}^{(low)}_{m,x}$ は低評価ベクトル空間上で得られる予測評価値，$\hat{r}^{(high)}_{m,x}$ は高評価ベクトル空間上で計算される予測評価値，α は評価値の混合比とする．$\hat{r}^{(low)}_{m,x}$ は，低評価アイテム群の中に存在する評価軸を考慮したベクトル空間から算出された予測評価値，つまり，低評価アイテム群に特化した予測評価値であると言える．同様に，$\hat{r}^{(high)}_{m,x}$ は，高評価アイテム群に特化した予測評価値であると言える．

5. 実験

5.1 実験条件

評価値の予測実験には，公開データセット MovieLens [Lens] の映画評価データを用いる．評価値データ数は 100,000 件，ユーザ数 942 人，アイテム数 1,683 本，評価値は 1〜5 の 5 段階を実験対象データである．本実験では評価指標として式 (5)MAE(平均絶対誤差) を用い，5 分割交差検証法によりテストデータに対して得られる各予測精度の平均を求める．

$$\text{MAE} = \frac{1}{D} \sum_{m=1}^{M} \sum_{x \in \mathcal{I}} |\hat{r}_{m,x} - r_{m,x}| \delta_{m,x} \quad (5)$$

ここで，$r_{m,x}$ はユーザ u_m のアイテム x に対する真の評価値，D はテストデータ数である．また，$\delta_{m,x}$ はインジケータ関数であり，ユーザ u_m がアイテム x を評価している場合は 1，それ以外は 0 を示す．

さらに，2 つのベクトル空間のバランスを調整するために導入する，高評価ベクトル空間と低評価ベクトル空間での予測評価値の混合比 α は，学習データをさらに設定用学習データと設定用テストデータに分割し，交差検証法により最適化する．具体的には，設定用学習データで Item2Vec を行い 2 つのベクトル空間を構成して設定用テストデータの評価値を予測する．さらに，混合比 α を 0 から 1 まで 0.1 ずつ変化させた全パターンに対して MAE を求める．そして，交差検証法により分割された 5 つの設定用テストデータに対して求めた MAE の平均が最も低い α を最適な混合比とする．また，高評価アイテム群と低評価アイテム群の分散表現モデルの違いを確認するために，ベクトル空間が異なることによるアイテム間の類似度の差異についても検証する．

5.2 実験結果と考察

図 1 は，混合比 α を 0 から 1 まで変化させた場合の設定用テストデータに対して求めた MAE の推移を表す．

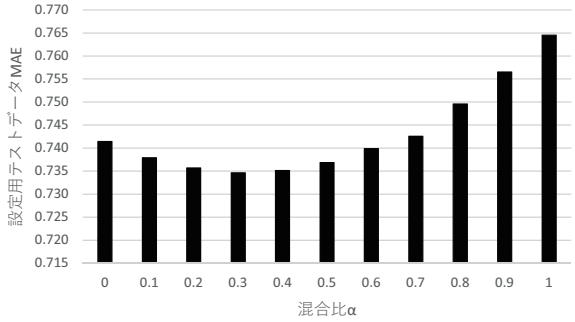


図 1: 混合比を変化させた際の MAE の推移

図 1 より，α=0.3 のときに最も MAE が小さくなった．そこで，最適な混合比 α を 0.3 と設定した時の評価値予測実験の結果を表 1 に示す．また，比較手法として従来手法と高評価ベクトル空間，低評価ベクトル空間の片方のみを用いて評価値予測をした結果を示す．

表 1: 各手法における MAE

手法	MAE
従来手法 (Kuzmin の手法)	0.7263
高評価ベクトル空間のみを用いた場合 ($\alpha = 0.0$)	0.7264
低評価ベクトル空間のみを用いた場合 ($\alpha = 1.0$)	0.7434
提案手法 ($\alpha = 0.3$)	**0.7214**

表 1 より，提案手法は従来手法と比べて予測精度が向上していることが分かる．高評価ベクトル空間のみを用いた場合と低評価ベクトル空間のみを用いた場合において予測精度が低下したのは，学習データを高評価と低評価に分割する必要があり，モデルの学習に用いるデータが相対的に少なくなってしまうためと考えられる．しかし，これらのモデルを統合して評価値を予測することで，アンサンブル効果により従来法よりも予測精度を向上させることが可能であることが表 1 からも確認できる．

以降では，高評価アイテム群と低評価アイテム群の分散表現モデルの違いを確認するために，ベクトル空間が異なることによるアイテム間の類似度の差異について，実際のアイテムの組み合わせの例を用いて検証を行う．まず，表 2 に，高評価ベクトル空間，低評価ベクトル空間で共に類似度が高いアイテムの一例を示す．

表 2: 高評価ベクトル空間，低評価ベクトル空間で共に類似度が高いアイテムの組み合わせ

映画タイトル	高評価 ベクトル空間	低評価 ベクトル空間
スタートレック 4 スタートレック 6	0.8540	0.9068
フリッパー パーフェクトワールド	0.7697	0.7990
バイオドーム クロウ	0.7651	0.7486
Go FisH カジノ	0.8523	0.8921
スポーン スニーカーズ	0.8132	0.8189
StarWars6 キリングフィールド	0.8239	0.8432
めぐり逢えたら 星に願いを	0.8334	0.8336
奴らに深き眠りを コンタクト	0.8665	0.8410

表 2 より，例えばスタートレック 4 とスタートレック 6 は，高評価ベクトル空間と低評価ベクトル空間で，共に高い類似度を示した．すなわち，スタートレック 4 を高く評価しているユーザは，スタートレック 6 を同時に高く評価している．また，スタートレック 4 を低く評価しているユーザも，同じくスタートレック 6 を低く評価していることがわかる．そのため，2 つの作品は同一ユーザに見られやすく，かつ，評価の基準の軸も似ていると言える．

次に，表 3 に，高評価ベクトル空間，低評価ベクトル空間で共に類似度が低いアイテムの組み合わせの一例を示す．

表 3: 高評価ベクトル空間，低評価ベクトル空間で共に類似度が低いアイテムの組み合わせ

映画タイトル	高評価 ベクトル空間	低評価 ベクトル空間
Sweet Hereafter 地球が静止する日	0.2239	0.2698
クルックリン ゲーム	0.2392	0.1881
シャイニング 評決のとき	0.4183	0.3997
戦火の勇気 タイタニック	0.2604	0.1866
おしゃれキャット Critical Care	0.2969	0.2780
ジョーズ 2 グース	0.2941	0.2441
クラッシュ ジョージア	0.2291	0.2246
シャイニング 評決のとき	0.4183	0.3997
エマ ベン・ハー	0.2677	0.2924

表 3 より，例えば Sweet Hereafter と地球が静止する日は，高評価ベクトル空間と低評価ベクトル空間で，共に低い類似度を示した．すなわち，Sweet Hereafter を高く評価しているユーザは地球が静止する日を高く評価しないことが分かる．また，Sweet Hereafter を低く評価しているユーザは地球が静止する日を低く評価しないことが分かる．このことから，ユーザが評価する際の基準の軸が 2 つの作品では全く異なるという

ことが分かる．

そして，表 4 に，高評価ベクトル空間では類似度が高く，低評価ベクトル空間では類似度が低いアイテムの組み合わせの一例を示す．

表 4: 高評価ベクトル空間では類似度が高く，低評価ベクトル空間では類似度が低いアイテムの組み合わせ

映画タイトル	高評価 ベクトル空間	低評価 ベクトル空間
ニューシネマパラダイス StarWars5	0.7017	0.3456
トランスフォーマー フェノミナン	0.6573	0.3570
セブン ニキータ	0.6215	0.3519
ニューシネマパラダイス ライフ・オブ・ブライアン	0.7012	0.4338
クリムゾン・タイド フリントストーン	0.7212	0.4201
グッドフェローズ ファーザーズ・デイ	0.5746	0.3586
スリング・ブレイド シャイニング	0.6211	0.3525
アナコンダ ディアボロス	0.5769	0.3802

表 4 より，例えば，ニューシネマパラダイスを高く評価しているユーザは，StarWars5 も高く評価している傾向があるが，低評価ではその傾向が見られない．つまり，2 つの作品がユーザに高評価される基準は同じ傾向があるが，低評価される基準の軸が作品によって異なることを意味する．

最後に表 5 に，高評価ベクトル空間では類似度が低く，低評価ベクトル空間では類似度が高いアイテムの組み合わせの一例を示す．

表 5: 高評価ベクトル空間では類似度が低く，低評価ベクトル空間では類似度が高いアイテムの組み合わせ

映画タイトル	高評価 ベクトル空間	低評価 ベクトル空間
U ターン 大脱走	0.1970	0.6002
トップガン バットマンリターンズ	0.4928	0.8012
ガス燈 ワン・ナイト・スタンド	0.4960	0.8007
ピノキオ バッドボーイズ	0.4743	0.7332
クルックリン トゥルー・クライム	0.4726	0.7862
未来は今 ピアノ・レッスン	0.4314	0.7639
ベン・ハー アンフォゲッタブル	0.2749	0.7276
ジュニア 理由	0.3983	0.7845

表 5 より，例えば，U ターンを低く評価しているユーザは大脱走も低く評価している傾向があるが，高評価ではその傾向が見られない．つまり，2 つの作品がユーザに低評価される基準は同じ傾向があるが，高評価される基準の軸が作品によって異なることを意味する．

このように，高評価アイテム群の背後に存在するユーザの嗜好と，低評価アイテム群の背後に存在するユーザの嗜好を独立に学習することで，ユーザの嗜好を詳細に把握することを可能とし，予測精度の向上に寄与していると考えられる．

6. まとめと今後の課題

本研究では，よりユーザの嗜好を捉えたアイテムの分散表現を獲得するために，高評価ベクトル空間と低評価ベクトル空間を独立に学習を行う手法を提案した．さらに，2 つのベクトル空間のバランスを調整するための混合比を導入することで，各ベクトル空間上から推定される評価値の加重平均で評価値予測を行うモデルを提案した．また，ベンチマークデータを用いた実験により提案手法の有効性を示した．さらに，ベクトル空間毎のアイテムの類似度の組み合わせを 4 種類示し，提案手法が予測精度の向上に寄与する原因について考察を行った．

今後の課題としては以下の 3 点が挙げられる．本提案モデルでは，異なるベクトル空間上で予測した評価値を統合するために，混合比 α を全アイテムに対して一律に設定したが，アイテムによって異なる α を決定する方法について検討する余地がある．また，本提案モデルにおいては，公開データセットで実験を行い有意性を検証したが，異なるデータセットに対して提案手法を適用させ，汎化性能を検証する必要がある．最後に，評価値予測だけでなく Top$N$ 精度でアイテムに対する推薦精度の測定をすることが挙げられる．

参考文献

[神嶌 2003] T.Kamishima,“Nantonac collaborative filtering :recommendation based on order responses,”in Proc. of *The 9th International Conference on Knowledge Discovery and Data Mining,* pp. 583-588, Aug, (2003).

[Kuzmin 2017] Vitali Kuzmin,“Item2Vec-based Approach to a Recommender System,”*University of Tarutu*, (2017).

[Barkan 2016] Oren Barkan, Noam Koenigstein,

“ Item2Vec: Neuralitem embedding for collaborative filtering,”*2016 IEEE 26th International Workshop on MachineLearning for Signal Processing*, (2016).

[Mikolov 2013] T. Mikolov, K. Chen, G. Corrado, and J. Dean,“Efficient Estimation of Word Representations in Vector Space,” *ICLR Workshop*, (2013).

[Mikolov 2013] T. Mikolov, I. Sutskever, K. Chen, G. Corrado, and J. Dean,“ Distributed Representations of-Words and Phrases and their Compositionality,”*Advances in NIPS26*, pp. 3111-3119, (2013).

[Lens] MovieLens Dataset, https://grouplens.org/datasets/movielens/, 2019 年 1 月 18 日閲覧.

General Session | General Session | [GS] J-2 Machine learning

[2P3-J-2] Machine learning: advances in neural networks

Chair:Masayuki Okamoto Reviewer:Masakazu Hirokawa

Wed. Jun 5, 2019 1:20 PM - 3:00 PM Room P (Front-left room of 1F Exhibition hall)

[2P3-J-2-01] Proposal of optimization method of local receptive field using gradient descent

○So Tazume[1], Masanao Ochi[1], Ichiro Sakata[1], Junichiro Mori[1] （1. The University of Tokyo）

1:20 PM - 1:40 PM

[2P3-J-2-02] Acceleration of Neural Architecture Search by Policy Gradient with Credit Assignment

○Rei Sato[1,2], Youhei Akimoto[1,2], Jun Sakuma[1,2] （1. University of Tsukuba, 2. RIKEN Center for Advanced Intelligence Project）

1:40 PM - 2:00 PM

[2P3-J-2-03] Progressive Data Increasing as Initialization of Neural Network

○Ryosuke Sato[1], Masanari Kimura[1] （1. Ridge-i Inc.）

2:00 PM - 2:20 PM

[2P3-J-2-04] Efficient learning in machine language instruction sequence classification by transfer learning

○Yuhei Otsubo[1,2], Akira Otsuka[2], Yoshihiro Iwata[1], Mamoru Mimura[3], Takeshi Sakaki[4] （1. National Police Agency, 2. Institute of Information Security, 3. National Deffense Academy, 4. University of Tokyo）

2:20 PM - 2:40 PM

[2P3-J-2-05] A Style Transfer Method using Wasserstein Autoencoder

○Hidekmoto Nakada[1], Hideki Asoh[1] （1. National Insitutite of Advanced Industrial Science and Technology）

2:40 PM - 3:00 PM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

勾配降下法を用いたニューラルネットワークにおける局所受容野の最適化手法の提案

Proposal of optimization method of local receptive field using gradient descent

田爪 聡 [1]　大知 正直 [1]　坂田 一郎 [1]　森 純一郎 [1]

So Tazume[1], Masanao Ochi[1], Ichiro Sakata[1], and Junichiro Mori[1]

[1] 東京大学

[1]The University of Tokyo

Abstract: In this research, we try to design a method to search the optimum model according to individual data.In the existing structure search algorithm, the applicable types of data are limited.In this study, we will input the receptive field of the convolutional layer , It is possible to apply various types of data to the convolutional neural network.In concrete terms, by interpreting the receptive field as an index that associates inputs and weights in the convolutional layer We designed a new layer expressing the receptive field in a matrix and also made it possible to learn receptive field by gradient by relaxing its matrix to continuous value.The result of the experiment The proposed method for the data whose data structure is unknown By using the method proposed in this paper, it is expected that the spread of IoT and the sensor Relative big data that is expected to increase in the improvement of technology, the neural network is expected to be effectively applied.

1　はじめに

近年ニューラルネットワークの研究が盛んに行われており，産業分野への導入事例も年々増加している．しかし研究分野で扱われるデータと比べて，実応用で用いられるデータの多くはデータの構造に関する知見が十分に得られていないケースが多い．それらの理由からモデルの設計にコストがかかり，導入が進んでいないという課題がある．そこで本研究では個別のデータに応じて最適なモデルを探索する手法の設計を試みる．

個別のデータに対応する最適なモデルを設計する手法としてメタラーニングに関する研究が盛んに行われている．それらの研究の多くはレイヤー間の接続を最適化する手法を用いており，画像処理や自然言語処理など一部のデータに対して優れた性能を示している．しかし既存の構造探索アルゴリズムでは適用可能なデータの種類が限られている．そこで本研究では畳み込み層の受容野を入力に対して適切に対応付けることで，様々な種類のデータを畳み込みニューラルネットワークに適用することを可能とした．具体的には畳み込み層において入力と重みを対応付けするインデックスとして受容野を解釈することで受容野を行列で表現する新たな層を設計した．またその行列を連続値に緩和することで勾配による受容野の学習を可能とした．

MNIST を用いた精度評価実験ではこれまで画像分野で用いられてきた畳み込み層の受容野と一部一致する受容野が学習によって得られ，精度評価に関しても同等の性能を観測した．また気象庁のホームページから収集した日本の過去の気象データを用いた精度比較実験では小さいネットワークで既存の分類手法より優れた結果を示した．

これらの結果からデータ構造が未知のデータに対して提案手法が有効であることを示した．

2　関連研究

2.1　畳み込みニューラルネットワークの受容野に関する研究

Yu らは画像データに対して等間隔空けたピクセルを受容野にすることでより広域の情報を畳み込む dilated 畳み込み層を提案した [1]．Jeon らは画像データに対して中心となる受容野以外の受容野の位置を可変とし，位置も含めて学習することで受容野形状を最適化する手法を提案した [2]．

Niepert らはグラフに対して畳み込みニューラルネットワークを適用する手法の提案をした [3]．入力となるノードをグラフデータに関する知見を元に選択し，それらのノードを受容野として畳み込みニューラルネットワークへの適用を行った．

2.2　ニューラルネットワークの構造探索アルゴリズム

ニューラルネットワークの構造探索の手法として様々な手法が挙げられる．Zoph らは様々な構造のモデルを

生成する RNN を生成されたモデルの分類精度を報酬として，強化学習を用いて学習する手法を提案した [4]．また Liu らは離散値であるネットワークのトポロジーを連続値に緩和することで勾配降下法を用いたネットワークの構造最適化を行う手法を提案した [5]．ニューラルネットワークのモデルを最適化する手法の多くはレイヤー間の接続を最適化する．それらの手法は画像分野や自然言語処理分野で特に高い性能を示している．

2.3 本研究の位置づけ

モデルの構造に関する研究はレイヤーの接続に関する研究と畳み込み層の受容野に関する研究が主に挙げられる．また構造の自動探索に関する研究も多数発表されているが，そのほとんどはレイヤーの接続の最適を扱っている．そこで本研究では，構造探索手法ではあまり研究が行われていない受容野の最適化に関する研究を行う．また計算量を抑えるために勾配降下法を元に構造の探索を行う．

3 勾配降下法を用いた畳み込み受容野の最適化

3.1 緩和畳み込み層の提案

本節では受容野テンソルを導入した緩和畳み込み層について説明する．緩和畳み込み層は受容野行列 L とカーネルの重み W から構成されており，入力 I に対して 2 回の行列計算を施す．まず 1 回目の行列計算は入力 I と受容野行列 L のテンソル積を計算している．これは入力の各成分とカーネルの重み W の各成分を対応付ける操作と対応している．そして得られたテンソルとカーネルの重み W のテンソル積を出力に用いている．受容野行列が従来の画像の畳み込み層と同様の受容野を表している場合，$I \otimes L$ の n 軸方向のベクトルは近隣ピクセルの値を成分にもつベクトルになる．また緩和畳み込み層の順伝播の式を式 1 で示す．O は出力テンソル，I は入力テンソル，W はカーネルの重み，L は受容野テンソルをそれぞれ表す．

$$O = I \otimes L \otimes W \tag{1}$$

3.2 受容野のテンソルの最適化の概要

前節の定義に基づいた場合，受容野テンソルは離散値となるが離散値では勾配を用いた最適化手法を適用することができない．そこで本手法では受容野テンソルを学習する段階では L と同型のテンソル R に対し被畳み込み軸方向に Softmax 関数を適用することで，受容野テンソルの値を 0 から 1 の間の連続値として扱った．Softmax 関数はベクトルに対し適用される関数であり入力ベクトルを x，出力ベクトルを y とすると，y の各成分は以下の式 2 で計算される．

$$y_i = \frac{e^{x_i}}{\sum_{j=1}^{N} e^{x_j}} \tag{2}$$

このとき N は x 及び y の成分数である．本研究では L と同型のテンソル R を直接学習することで受容野テンソルを間接的に学習する．Softmax 関数で計算された受容野テンソルを以降では連続受容野テンソル L_c，テンソル R を受容野元テンソルと呼ぶことにする．またネットワークを学習する段階では，受容野テンソルは被畳み込み軸方向で one-hot である必要があるため，受容野テンソルを受容野元テンソルを用いて計算する．このとき，R に対して被畳み込み軸方向に Max 関数を適用する．Max 関数は以下で定義する．

$$y_i = \begin{cases} 1 & (i = \underset{i'}{argmax}\ x_{i'}) \\ 0 & (otherwise) \end{cases} \tag{3}$$

R を元に Max 関数で計算された受容野テンソルを離散受容野テンソル L_d とする．

図 3.1 に学習の概要を図示する．W の更新は上の枠線で囲まれた領域で示した．b_{train} がネットワークに入力されることで $\mathcal{L}_W$ が計算される．W は $\mathcal{L}_W$ を最小化する方向に更新される．また下の枠線で囲まれた領域で R の更新を示した．R の更新段階ではネットワークに b_{train} と b_{val} を入力することで $\mathcal{L}_R$ を計算する．R は $\mathcal{L}_R$ を最小化する方向に更新される．

W と R の両方の更新の段階において b_{train} と R と W は共有される．

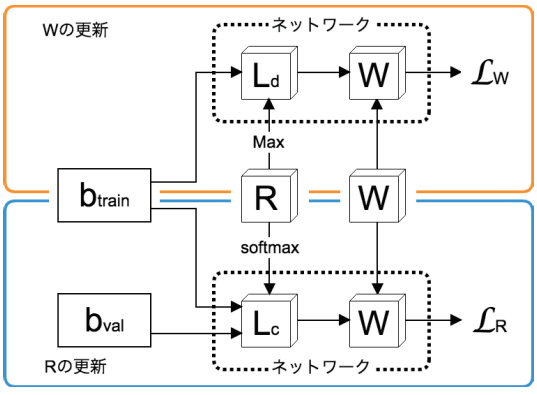


図 3.1 提案手法の学習の概要図

3.3 損失関数

次に本手法で用いる損失関数について説明する．本手法ではネットワークのパラメータの学習に用いる損失関数と受容野元行列の学習で用いる損失関数に異なる関数を導入した．パラメータ W の学習にはソフトマックスクロスエントロピー関数を用いている．受容野元行列 R の学習では Liu らの考案した損失関数を用いた [5]．その関数を次の式 4 で示す．

$$\mathcal{L} = \mathcal{L}_{val}(W - \gamma \nabla_W \mathcal{L}_{train}(W, R), R) \qquad (4)$$

この損失関数を最小化するような受容野元テンソルを計算することで，損失関数の更新幅が大きくなるような受容野が得られる．

4 実験と結果

4.1 実験の詳細

本研究では実験結果を可視化することで受容野を定性的に評価するために緩和畳み込み層の構造を多少変更した．本実験では受容野行列の解釈を考察するという目的を達成するために受容野行列に制約を課した．その制約は受容野行列の受容野軸方向の成分のうち 1 つを単位行列に固定するという制約である．また本研究では固定された単位行列によって定められた受容野を受容野の中心と呼ぶこととする．

4.2 MNIST を用いた実験

本実験では提案手法の妥当性を評価するために，画像分類タスクで頻繁に用いられる MNIST を用いて精度評価の実験を行った．

本実験では受容野元行列を学習し，その行列を定数としてネットワークのパラメータを学習した．図 4.1 に学習で得られた受容野の一部を可視化した．

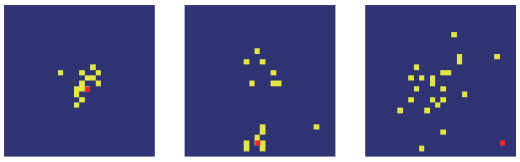


図 4.1 学習で得られた受容野

受容野の中心を定め，それと同時に畳み込まれている他のピクセルを同じ図にまとめた．一番左上のピクセルを (1,1) とした時，それぞれの受容野の中心はそれぞれで (15,15),(13,25),(25,25) である．他の受容野は白色で示してある．次に比較実験の結果を示す．比較実験として，線形結合層のみから作られているネットワークと画像の畳み込みニューラルネットワークも同様に実験を行った．精度は以下の表 4.1 ようになっている．精度は CNN と近い結果が得られた．

表 4.1 各種手法による MNIST の分類精度

手法	分類精度
提案手法	97.37%
CNN	97.47%
Linear	96.21%

4.3 Shuffled MNIST を用いた実験

次に手書き文字画像を並び替えたデータセットに対して提案手法を適用した．画像の畳み込みニューラルネットワークは隣接ピクセルの値を畳み込むことでその精度を向上させたが，その受容野は画像処理の知見に基づき設定されたものであった．知見が十分に得られていないデータや位置情報を持っていないデータに対しては畳み込みの受容野を決定することが難しいという課題がある．そこで Shuffled MNIST では擬似的にそのようなデータを再現した．

各手法の精度を表 4.2 にまとめた．テストデータを用いた精度比較において CNN の精度は著く下がっていることが確認できる．しかし提案手法はデータの加工前と同等の精度を示した．

表 4.2 各種手法による Shuffled MNIST の分類精度

手法	分類精度
提案手法	97.49%
CNN	95.89%
Linear	96.27%

4.4 気象庁データベースを用いた実験

本実験では気象庁データベースからダウンロードしたデータに対して提案手法を適用した．気象庁データベースからダウンロードしたデータは日本の各地点の気象状況を格納したデータセットとなっている．そこで本実験では日毎の気象データからその日の月を推定する問題に対して提案手法を適用した．

また各種手法の精度を表 4.3 にまとめた．それぞれの手法のハイパーパラメータはグリッドサーチで選ばれたものを用いた．

表 4.3 各種手法の日本気象データセットの分類精度

手法	分類精度
提案手法	**80.08**%
Linear	76.62%
線形カーネルを用いた SVM	75.79%
RBF カーネルを用いた SVM	75.86%
決定木	61.61%
ランダムフォレスト	71.19%
k-近傍法	58.54%
ロジスティック回帰	65.36%

5 考察

本節では実験によって学習された受容野について考察することで提案手法の妥当性について議論する．

MNIST データセットに対して受容野を学習したところ中央付近のピクセルでは近傍のピクセルを畳み込んでいた．また画像の外側を受容野の中心とする受容野は広がりを持って分布していた．この結果より MNIST に対して受容野の学習を行った結果，画像の中央付近では従来の画像畳み込みと類似の受容野が学習で得られた．また画像の外側付近で受容野が広がりを持っていた理由として，MNIST はクラスの特徴を表すピクセルが中央付近に集めるようにデータセットが作られている．つまり画像の外側では局所的な特徴量を捉える必要がない．そこで外側のピクセルに関しては画像の全体を畳み込むことの方が MNIST というデータセットの構造を捉えられているのではないかと考えられる．

次に日本の気象データに対して提案手法を適用した結果について議論する．受容野の中心が北海道の各地または那覇の時，その他の受容野も同じ地方に集中した．しかしそれ以外の地域を受容野野中心とした時，受容野は南北に幅広く分布していた．気象予報士の方にお話を伺ったところ，日本各地のその日の気象データから月を予測するというタスクにおいて，各月の特徴をもっとも捉えている気象条件の 1 つに前線の位置が挙げられるとのことである．前線とは気団同士の境界上に観測され，気象的に不連続境界となる．畳み込み層は受容野内の構造的特徴を捉える役割を持つことから，受容野を南北に広く分布させることで前線の位置をモデルが獲得しているのではないかと考えられる．そして那覇と北海道は前線の南限と北限の外側にあり，気候区分も日本の他の地域とは異なる．そこで異なる気候区分が受容野に含まれないように受容野の学習が進んだのではないかと考えられる．

6 結論

本研究の目的は，知見が十分に研究されていないようなデータに対して畳み込みニューラルネットワークの受容野を緩和，学習することによってそのデータに対して最適な受容野を獲得することであった．この目的に対する本研究の結論について述べる．

MNIST の実験では得られた受容野は画像の中心付近では近隣ピクセルを畳み込んでいた．画像の端付近では受容野が広がりを持っていたが，これは MNIST データセットにおける文字が中央に位置するという特徴を捉えたためだと解釈でき，本手法がデータの特徴を捉えるという点で有用であることを示せた．

気象庁のデータベースから作成したデータセットを用いて実験で学習された受容野を観察したところ地理的，気候的に特徴的な箇所に集中しており，タスクに対する最適なデータの構造を捉えられていた．また実験の結果，既存手法に比べてより高い精度を示しており，学習された受容野が精度向上に寄与したことが示された．

以上から，本研究は特にデータに対する知見が少ない場合において有効性を示し，データの構造を自動で捉えてより効率的に学習するネットワークの構造を探索する手法を提案した．

今後の展望として，受容野元テンソルのパラメータ数の削減を行うことが考えられる．例えば k 次のテンソル分解を適用することでパラメータの数を減らすことができ，より効率的に学習が進むのでは無いかと考えられる．

参考文献

[1] Fisher Yu and Vladlen Koltun. Multi-scale context aggregation by dilated convolutions. *arXiv preprint arXiv:1511.07122*, 2015.

[2] Yunho Jeon and Junmo Kim. Active convolution: Learning the shape of convolution for image classification. *CoRR*, Vol. abs/1703.09076, , 2017.

[3] Mathias Niepert, Mohamed Ahmed, and Konstantin Kutzkov. Learning convolutional neural networks for graphs. In *International conference on machine learning*, pp. 2014–2023, 2016.

[4] Barret Zoph and Quoc V Le. Neural architecture search with reinforcement learning. *arXiv preprint arXiv:1611.01578*, 2016.

[5] Hanxiao Liu, Karen Simonyan, and Yiming Yang. Darts: Differentiable architecture search. *arXiv preprint arXiv:1806.09055*, 2018.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

貢献度分配を導入した方策勾配による Neural Architecture Search の高速化

Acceleration of Neural Architecture Search by Policy Gradient with Credit Assignment

佐藤 怜 *1　秋本 洋平 *1　佐久間 淳 *1
Rei Sato　Youhei Akimoto　Jun Sakuma

*1筑波大学　*1理化学研究所 革新知能統合研究センター
University of Tsukuba　RIKEN Center for Advanced Intelligence Project

Neural architecture search is gathering attention as an approach to automatically designing the architecture of deep neural networks. Aiming at accelerating neural architecture search without compromising its performance, we propose a novel one-shot architecture search algorithm that optimizes the weights and the architecture of a network simultaneously. Our algorithm is inspired by the notion of credit assignment in policy gradient. An advantage of each architecture component is defined and the gradient of the architecture parameter is computed using the advantage values. In our experiments, we observe that the proposed method achieves, with lower computational time, the final performance comparable to recently proposed gradient-based one-shot architecture search algorithms.

1. はじめに

深層学習と呼ばれる一連の技術が画像認識や音声認識をはじめとする種々のタスクに適用され, 目覚ましい精度向上を成し遂げている. 深層学習ではモデルのアーキテクチャと呼ばれるハイパーパラメータ (e.g. 畳み込み層のフィルタ数, Pooling の種類) が所望のタスクに対する精度に大きく寄与する. しかしアーキテクチャは数十から数百にもなるハイパーパラメータの組み合わせで定義され, これらの組み合わせを改良していく作業には多大な時間と労力を要する. このような背景から近年, 深層学習モデルのアーキテクチャをアルゴリズムによって最適化する研究が盛んになっている.

アーキテクチャの最適化は, 精度 (あるいは精度と計算コストのトレードオフを考慮した指標) を最大化するアーキテクチャを探索する問題として定式化され, 強化学習や遺伝的アルゴリズム等を用いて行われることが多い. しかし異なるアーキテクチャの深層学習モデルは異なるパラメータ (e.g. 重み, バイアス) を持つため, これらを学習させない限りそのアーキテクチャを評価することができない. 従って, 従来のアーキテクチャ探索では候補となるアーキテクチャに対応するモデルを学習し, 評価するというサイクルを繰り返す必要があり, 膨大な学習コストが問題となっていた.

このような課題に対して近年, アーキテクチャとパラメータを同時に最適化することでパラメータの学習コストを削減する手法が複数提案されている. これらの手法は 1 度 (あるいは再学習を含めて 2 度) の学習プロセスで両者を最適化することから one-shot アーキテクチャ探索と呼ばれている.

本研究では one-shot なアプローチのうち, 勾配法に基づく探索法 [Liu 19][Xie 19] に着目する. これらの研究では, 従来カテゴリカル変数として表現されていたアーキテクチャを連続変数を用いて表すことで, 微分可能な目的関数を定義する. 勾配法による最適化は, 遺伝的アルゴリズムを用いた探索手法と異なり, 探索空間に合わせた手法の設計が不要であり, 実装が容易であるというメリットを持つため, 注目を集めている.

本研究では one-shot でアーキテクチャを探索する手法の高速化を目的とし, 強化学習の Actor-Critic 法に着想を得た勾配法による探索手法を提案する. ここでの高速化とは, アーキテクチャ探索にかかる総時間の削減を意味しており, 提案手法は 1 イテレーションの高速化とイテレーション数の削減の両面からアプローチする.

数値実験により, 勾配法に基づく one-shot アーキテクチャ探索を行う先行研究と比較して, 同程度の精度を得られるアーキテクチャをより高速に発見することができることを示す.

連絡先: 佐藤怜, 筑波大学情報科学類, 茨城県つくば市天王台 1-1-1, reisato@bbo.cs.tsukuba.ac.jp

2. Neural Architecture Search

2.1 有向非巡回グラフとしての DNN

本稿では DARTS[Liu 19] の定式化に倣い, 深層学習モデル (以下 DNN) を図 3 のような有向非巡回グラフと見なし, 各ノードを特徴 x, 各エッジをオペレーション $\mathcal{O}$ と捉える.

順伝播を行う際は, まずこの有向非巡回グラフの入力ノードにデータ (e.g. 画像ベクトル) を代入する. 以降はエッジの接続に基づいてエッジに割り当てられたオペレーション $\mathcal{O}$ で特徴 x を変換して順伝播する.

エッジ $i \in \mathcal{I}$ のオペレーション $\mathcal{O}$ で変換した出力の特徴を y_i と表記する. あるノード ℓ の状態となる特徴 x_ℓ は, ノード ℓ の入力となるエッジの集合を $\mathcal{E}_\ell$ として, $x_\ell = F(\{y_l | l \in \mathcal{E}_\ell\})$ と計算する. 関数 F は複数の特徴を受け取り, 1 つの特徴を返す何らかの関数 (e.g. 和, 結合) である. エッジ i の入力となるノードの添字を $Q(i)$ と表記する. すなわち, エッジ i のオペレーション $\mathcal{O}$ の入力となる特徴は $x_{Q(i)}$ と表記される.

エッジ i でのオペレーション候補の添字の集合を $\mathcal{J}_i$ とする. 本稿では全てのエッジで候補となるオペレーションの数は同じとし, 以降は簡単のため $\mathcal{J} = \mathcal{J}_i$ と表記する. また, エッジ i での $j \in \mathcal{J}$ 番目のオペレーション候補を $\mathcal{O}_j^i$ と表記する.

このような有向非巡回グラフは, エッジに割り当てるオペレーション $\mathcal{O}$ に多様な関数 (e.g. Convolution, Pooling) を選ぶことで, 幅広い DNN アーキテクチャを表現することができる. この有向非巡回グラフの接続は予め決められているが, オペレーション候補に zero-operation(零写像) を含めることで, ノード間の接続の不在も表現できる.

本稿ではアーキテクチャ探索を, DNN 上の $|\mathcal{I}|$ 箇所のエッジにおいて, それぞれ $|\mathcal{J}|$ 個のオペレーション候補から最終的に 1 つを選択する問題として取り扱う. このような各エッジに

ついて 1 つのオペレーションのみを選択し実行するアーキテクチャをバイナリベクトル $a \in \{0,1\}^{|\mathcal{I}||\mathcal{J}|} = \mathcal{A}$ で表現する. $a_i \in \{0,1\}^{|\mathcal{J}|}$,$|a_i| = 1$ は one-hot ベクトルとして各エッジのアーキテクチャを表現しており, a_{ij} が 1 のとき, エッジ i ではオペレーション j が選択されていることを意味する.

従って, エッジの出力 y_i は以下で与えられる.

$$y_i = \sum_{j \in \mathcal{J}} a_{ij} \mathcal{O}_j^i(x_{Q(i)}) \tag{1}$$

2.2 One-shot Architecture Search

関数 $R(a; w_a)$ は, 広義にはアーキテクチャa と a に対応する学習済みパラメータ w_a を受け取り, a の評価を返す関数である. 従来は w_a を得るために a に基づくモデルを学習していたが, 本稿ではこの学習コストの削減を目的として one-shot なアーキテクチャ探索を考える. 本稿で探索時に用いる DNN の各エッジは, そのエッジにおける全てのオペレーション候補が必要とするパラメータを保存する. この冗長な DNN のパラメータは誤差逆伝播を用いてアーキテクチャ変数と同時に更新される. この冗長なモデルのパラメータを $\hat{w}$ と表記すると, あるアーキテクチャa を評価するのに必要な学習済みパラメータ w_a は $\hat{w}$ の一部として得られる. 表記法のわずかな乱用を許せば, $R(a; w_a)$ は $R(a; \hat{w})$ と置き換えられ, a が変化した際に w_a を再学習する必要がなくなるため, 学習コストを大幅に削減できる. 簡単のため, 以降は $R(a; \hat{w})$ を $R(a)$ と表記する.

本稿では画像認識モデルのアーキテクチャ探索を対象とするため, $R(a)$ には a に基づいて適当なミニバッチを伝播した際の負の交差エントロピー誤差関数を採用する.

3. 関連研究

本章では, one-shot アーキテクチャ探索に関する既存研究を紹介する. 本稿で扱う探索手法は勾配が確率変数の期待値で定義される場合があるが, 本研究では先行研究 [Pham 18][Cai 19] に倣い期待値をサンプル数 1 のモンテカルロ法で近似する.

3.1 ENAS[Pham 18]

ENAS[Pham 18] は, REINFORCE[Williams 92] を用いたアーキテクチャ探索法である. 関数 $p_\theta(a)$ を θ でパラメトライズされた $\mathcal{A}$ 上の確率分布とする. REINFORCE を用いた探索は, 目的関数 $\mathbb{E}_{a \sim p_\theta(a)}[R(a)]$ を θ について最大化する最適化問題として定式化される. この最適化を行うために, 下式で目的関数の勾配を計算する.

$$\nabla_\theta \mathbb{E}_{a \sim p_\theta(a)}[R(a)] \quad = \quad \mathbb{E}_{a \sim p_\theta(a)}[R(a) \nabla_\theta \log(p_\theta(a))] \tag{2}$$

最終的に, $p_\theta(a)$ が最大となる $a \in \mathcal{A}$ が探索結果のアーキテクチャとなる.

3.2 DARTS[Liu 19]

DARTS[Liu 19] では $\theta \in \mathbb{R}^{|\mathcal{I}||\mathcal{J}|}$ とする. DARTS では $\mathcal{A}$ 上の関数として定義されていた評価関数 R を $[0,1]^{|\mathcal{I}||\mathcal{J}|}$ 上へ拡張する. これは式 (1) の $a \in \mathcal{A}$ を, 以下で定義される operation mixing weights $\mu(\theta)$ で置き換えることで実現される.

$$\mu_{ij}(\theta) = \frac{\exp(\theta_{ij})}{\sum_{k \in \mathcal{J}} \exp(\theta_{ik})} \tag{3}$$

DARTS では目的関数 $R(\mu(\theta))$ の θ についての最大化を行う. この最適化を行うために, 次のように勾配を計算して θ を更新する.

$$\nabla_\theta R(\mu(\theta)) = \frac{\partial R(\mu(\theta))}{\partial \mu(\theta)} \frac{\partial \mu(\theta)}{\partial \theta} \tag{4}$$

最終的に, エッジ i のオペレーションには $\mu_{ij}(\theta)$ が最大となる j が選択され, これが探索結果のアーキテクチャとなる. このアーキテクチャを表現する a は $a_{ij} = \lim_{\lambda \to 0}[\mu_{ij}(\theta/\lambda)]$ で得られる. 本稿ではこの操作を one-hot 化と呼ぶ.

3.3 SNAS[Xie 19]

SNAS[Xie 19] は DARTS と同様に連続値のアーキテクチャ変数を考えるが, その方法が異なる.

SNAS では G_{ij} を標準 Gumbel 乱数, λ_t をステップ t での温度パラメータ ($\lim_{t \to \infty} \lambda_t = 0$), $\theta \in \mathbb{R}^{|\mathcal{I}||\mathcal{J}|}$ として, 次のように確率的なアーキテクチャ変数を定義する.

$$m_{ij}(\theta, G) = \frac{\exp((-\log(\mu_{ij}(\theta)) + G_{ij})/\lambda_t)}{\sum_{k \in \mathcal{J}} \exp((-\log(\mu_{ik}(\theta)) + G_{ik})/\lambda_t)} \tag{5}$$

SNAS では $\mathbb{E}_G[R(m(\mu(\theta), G))]$ の θ に関する最大化を考える. 各エッジでの順伝播は, 式 (1) の a_{ij} の代わりに式 (5) で計算した $m_{ij}(\theta)$ を用いて行う. 勾配は下式で計算される.

$$\begin{aligned} &\nabla_\theta \mathbb{E}_G[R(m(\mu(\theta), G))] \\ &\quad = \mathbb{E}_G \left[\frac{\partial R(m(\mu(\theta), G))}{\partial m(\mu(\theta), G)} \frac{\partial m(\mu(\theta), G)}{\partial \mu(\theta)} \frac{\partial \mu(\theta)}{\partial \theta} \right] \end{aligned} \tag{6}$$

探索結果のモデルは DARTS と同様にして得られる.

3.4 ProxylessNAS[Cai 19]

$\theta \in \mathbb{R}^{|\mathcal{I}||\mathcal{J}|}$ とし, $z_i(\mu(\theta), N)$ を $\mu(\theta)$ と乱数 N を受け取り two-hot ベクトル $z_i(\mu(\theta), N) \in \{0,1\}^{|\mathcal{J}|}, |z_i(\mu(\theta), N)| = 2$ を出力する関数として定義する. この関数値 $z_{ij}(\mu(\theta), N)$ は, $\mu_{ij}(\theta)$ を確率パラメータとするサンプル数 2 の多項分布の実現値だが, 必ず $z_i(\mu(\theta), N)$ が two-hot ベクトルになるよう修正を行う.

ProxylessNAS[Cai 19] では $\mathbb{E}_N[R(z(\mu(\theta), N))]$ の θ についての最大化を考える. 各エッジでの順伝播は式 (1) の a_{ij} の代わりに $z_{ij}(\mu(\theta), N)$ を用いて行う. 勾配は次のように計算する.

$$\begin{aligned} &\nabla_\theta \mathbb{E}_N[R(z(\mu(\theta), N))] \\ &\quad = \mathbb{E}_N \left[\frac{\partial R(z(\mu(\theta), N))}{\partial z(\mu(\theta), N)} \frac{\partial z(\mu(\theta), N)}{\partial \mu(\theta)} \frac{\partial \mu(\theta)}{\partial \theta} \right] \\ &\quad \approx \mathbb{E}_N \left[\frac{\partial R(z(\mu(\theta), N))}{\partial z(\mu(\theta), N)} \frac{\partial \mu(\theta)}{\partial \theta} \right] \end{aligned} \tag{7}$$

各イテレーションで θ の更新を行った後, $z_{ij}(\mu(\theta), N) = 0$ となる ij について $\mu_{ij}(\theta)$ が更新されないよう後処理を行う. 探索結果のモデルは DARTS, SNAS と同様にして得られる.

3.5 計算コストの比較

本研究ではアーキテクチャ探索の総探索時間の削減に着目しており, このうち 1 イテレーションの計算時間の観点から以上の先行研究を比較する. DARTS, SNAS のような連続値のアーキテクチャ変数を扱う手法は, 式 (1) の順伝播において各エッジで $|\mathcal{J}|$ 個のオペレーション候補の出力を計算する必要があるため, 1 イテレーションの計算コストが $|\mathcal{J}|$ に依存するという欠点を持つ. 一方, REINFORCE や ProxylessNAS のような離散値のアーキテクチャをサンプリングする手法の場合, 式 (1) では常に 1 つまたは 2 つのオペレーション候補の出力を計算するため, 1 イテレーションの計算コストが $|\mathcal{J}|$ に依存しないという利点がある.

4. 提案手法

本研究では REINFORCE に貢献度分配の考え方を導入することで効率的にアーキテクチャの確率分布を更新する手法を提案する．提案手法はサンプリングベースの手法である REINFORCE を改良したものであり，DARTS や SNAS とは異なり 1 イテレーションの計算コストが $|\mathcal{J}|$ に依存しない．

4.1 貢献度

関数 $p_{\theta_i}(a_i)$ を $\theta_i \in \mathbb{R}^{|\mathcal{J}|}$ でパラメトライズされたカテゴリ分布とする．つまり，オペレーション候補が各エッジについて独立にサンプリングされるようなアーキテクチャの分布を考える．ここで，$a_{ij} = 1$ となる確率は $\mu_{ij}(\theta)$ で与えられる．最適化のプロセスでは，まず全てのエッジ $i \in \mathcal{I}$ について $p_{\theta_i}(a_i)$ から one-hot な列ベクトル a_i を生成し，エッジ i での順伝播を式 (1) で計算する．

ここで，各エッジのアーキテクチャの分布 $p_{\theta_i}(a_i)$ が独立であることに注意すると，REINFORCE で計算される θ への勾配は下式である．

$$\mathbb{E}_{a\sim p_\theta(a)}[R(a)\nabla_\theta \log(p_\theta(a))] \tag{8}$$

$$= \mathbb{E}_{a\sim p_\theta(a)}\left[R(a)\nabla_\theta \log(\prod_{i\in\mathcal{I}} p_{\theta_i}(a_i))\right] \tag{9}$$

$$= \mathbb{E}_{a\sim p_\theta(a)}\left[\sum_{i\in\mathcal{I}} R(a)\nabla_{\theta_i} \log(p_{\theta_i}(a_i))\right] \tag{10}$$

上式より，REINFORCE では全てのエッジの確率分布 $p_{\theta_i}(a_i)$ を更新する勾配を，アーキテクチャ全体の評価 $R(a)$ でスケールしていることがわかる．

ここで，REINFORCE の探索の効率化を目的として，貢献度分配の考え方を導入する．アーキテクチャは複数のエッジの集合だから，実行結果に基づくアーキテクチャ全体の評価 $R(a)$ が良くても (悪くても)，各エッジではところどころ悪い (良い) オペレーション候補が実行されているはずだと考えられる．そこで，アーキテクチャ全体の評価 $R(a)$ ではなく，特定のエッジの評価だけを計算し，これを各エッジの評価として方策勾配を計算することを考える．各エッジの評価で方策勾配を計算することで $p_{\theta_i}(a_i)$ が的確に更新され，探索を高速化 (すなわち同じイテレーション数で探索を行ったときにより良いアーキテクチャを発見) できると考える．

$S_i \in \{0,1\}^{|\mathcal{I}-1||\mathcal{J}|}$ を，S_i と a_i を連結することで a が復元されるような a の要素の集合として，$S_i = \{a_g | g \in \mathcal{I}, g \neq i\}$ と定義する．あるエッジで選択されたアーキテクチャを表す one-hot ベクトル a_i の評価を返す関数を貢献度と呼ぶことにし，これを次のように定義する．

$$A(a_i, S_i) = R(a_i, S_i) - R(\vec{0}, S_i) \tag{11}$$

式 (11) は，a 全体の評価から S_i の評価を引いたものは，あるエッジ a_i だけの評価に相当するという解釈に基づく．

4.2 効率的な貢献度の計算

定義 (11) に基づいて貢献度を計算すると R を複数回評価する必要があり計算コストが課題になる．そこで次のように $R(a)$ の a_i 方向への方向微分を考え貢献度を近似する．

$$A(a_i, S_i) = R(a_i, S_i) - R(\vec{0}, S_i)$$

$$= \frac{R(a_i, S_i) - R(a_i - \Delta a_i, S_i)}{\Delta}|_{\Delta=1} \approx \frac{\partial R(a)}{\partial a_i^t} a_i \tag{12}$$

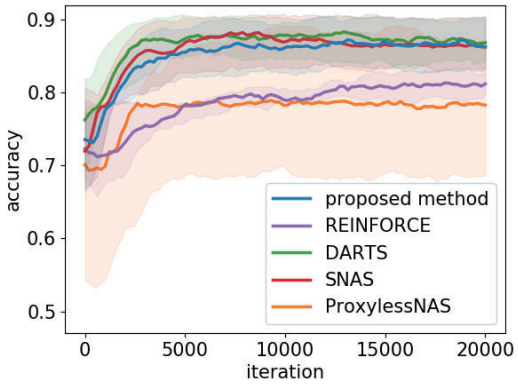


図 1: 探索過程で one-hot 化したモデルの accuracy

a は $\{0,1\}^{|\mathcal{I}||\mathcal{J}|}$ を取るが，微分を計算するために擬似的に連続空間での点として取り扱う．近似した式 (12) は 1 度の順逆伝播で計算できるため，式 (11) と比較して計算効率が向上している．

以上の議論から，θ_i を更新する勾配を式 (14) で計算する．

$$\mathbb{E}_{a\sim p_\theta(a)}\left[A(a_i, S_i)\nabla_{\theta_i} \log(p_{\theta_i}(a_i))\right] \tag{13}$$

$$\approx \mathbb{E}_{a\sim p_\theta(a)}\left[\frac{\partial R(a)}{\partial a_i^t} a_i \nabla_{\theta_i} \log(p_{\theta_i}(a_i))\right] \tag{14}$$

5. 実験

貢献度分配の効果の確認や類似手法との比較を行うため，2 種類の実験を行う．まず，各手法の最適化性能を比較するため，ニューラルネットの重みを固定し，アーキテクチャの探索のみ行う．次に CIFAR-10 データセットを用いて，one-shot アーキテクチャ探索としての各手法の比較を行う．

5.1 Toy Problem

まず Toy Problem での実験を行う． 比較対象は REINFORCE, DARTS, SNAS, ProxylessNAS, 提案手法の 5 つである．教師モデルを 2 層 (入力ノード数 500, 中間ノード数 500 出力ノード数 2) の全結合ニューラルネットとし，中間層には活性化関数を適用する．活性化関数には x,x^2,x^3,ReLU(x),sigmoid(x) の 5 つの候補を用意する．教師モデルの各中間ノードの活性化関数は予めランダムに選択する．

入力として，ミニバッチサイズ 100 の一様乱数を毎イテレーション生成する．生徒モデルは教師モデルと同じ構造の全結合ニューラルネットとし，教師モデルと等しい重みを与える．重みは学習せず，生徒モデルの中間層の活性化関数を探索することで教師モデルとのソフトマックス後の出力の交差エントロピー誤差を最小化する．手法毎の勾配ノルムの違いを吸収するために，アーキテクチャ変数の更新には Adam を用いる．

5.1.1 結果

Toy Problem の実験を行った際の探索中の accuracy を図 1 に示す．線は 10 試行の中央値で，領域は四分位範囲である．ここで，DARTS, SNAS, ProxylessNAS は複数の候補の重み付き和を計算する手法だが，全ての手法で one-hot 化を行って accuracy を測っている．提案手法は DARTS, SNAS に迫る効率的な探索を行えていることがわかる．ここではイテレーション数で比較をしているが，実際のアーキテクチャ探索では 1 イテレーションにかかる時間が DARTS, SNAS に比べ $1/|\mathcal{J}|$ 程度に減少するため，総探索時間の短縮が期待される．

表 1: 探索によって得られたモデルの比較. accuracy は再学習の結果. 提案手法と REINFORCE は 3 試行の結果

method	#param(K)	accuracy	time(hour)
提案手法	509 ± 3	92.34 ± 0.21	25.83 ± 0.84
REINFORCE	486 ± 10	91.85 ± 0.16	22.85 ± 0.81
DARTS	508	92.16	79.77
SNAS	512	92.11	75.63
ProxylessNAS	473	91.12	37.44
ランダム (5 回)	473 ± 5	91.37 ± 0.54	0

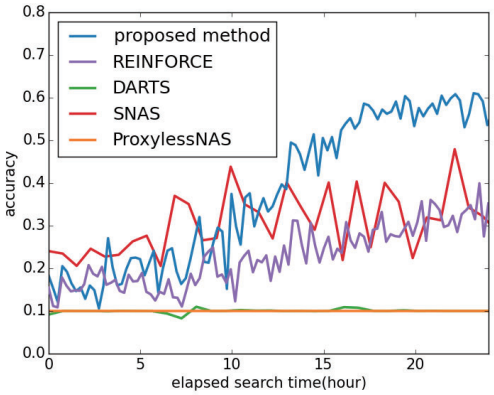


図 2: 探索過程で one-hot 化したモデルの test accuracy

5.2 アーキテクチャ探索

次に, 実際のアーキテクチャ探索で各探索手法の性能を比較する. 探索空間やハイパーパラメータについては全ての手法で [Liu 19] に準ずる. 詳細を以下に示す.

DNN はセルと呼ばれるマイクロアーキテクチャの 8 つの積み重ねで構成する. 各セルは 14 箇所のエッジと 7 箇所のノードを持つ. c 番目のセルには $c-1$, $c-2$ 番目のセルの出力が入力され, これがセルの 1, 2 番目のノードの特徴 x となる. セルの 7 番目のノードの特徴は当該セルの出力として以降のセルの入力となる. 実験では normal cell と reduction cell(セルの 1, 2 番目のノードを入力とするオペレーションのストライドが 2) の 2 種類の探索を行う. 2 種類のセルの計 28 箇所のエッジにおいて, 3*3/5*5 separable convolution, 3*3/5*5 dilated separable convolution, 3*3 max pooling, 3*3 average pooling, identity mapping(恒等写像), zero-operation(零写像) の計 8 つの候補から 1 つを選択する. 各 Convolution の入出力チャネル数は 16 とする. データセットは CIFAR-10 を用いる.

最適化は 150 エポックで行うが, 候補選択における重みの初期値への依存を減らすために, いずれの手法も最初の 50 エポックでは θ の更新を行わない. また, 重みの学習には安定性のために GradientClipping(1.0) を適用した.

提案手法を用いたアーキテクチャ探索では, 計算コストの削減を目的としていない場合でもスパースなモデルが得られる傾向にある. これは, zero-operation の貢献度は恒等的に 0 であるが, 他のオペレーションは実験的に負の貢献度を得る場合が多いため, zero-operation が選ばれやすいことに起因する. ここで直感的には, zero-operation は計算コスト 0 で識別には貢献しない候補だから, 最も低い貢献度を得ている他の候補に近い貢献度を与える. これを $\min_j \ \mathbb{E}_{a\sim p_\theta(a)}[\frac{\partial R(a)}{\partial a_{ij}} a_{ij}]$ のように定義し, エッジ i の zero-operation の貢献度として与えた. 期待値は指数移動平均で近似した.

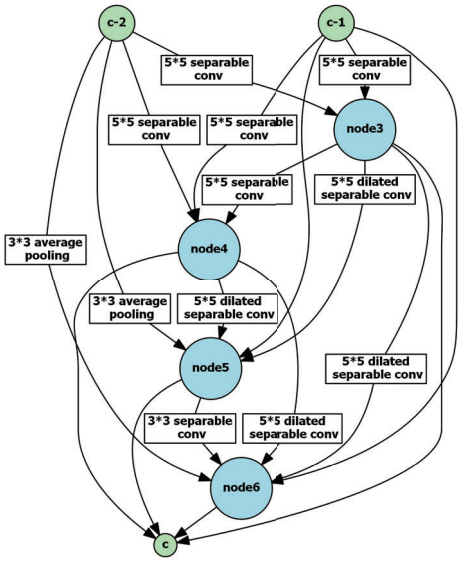


図 3: 提案手法を用いて得られた reduction cell

5.2.1 結果

探索結果で得られたモデルを one-hot 化し, 300 エポックで重みを再学習する. 重みの再学習は従来研究においても実施されている. この結果を表 1 に示す. 提案手法による探索では, DARTS, SNAS より短い探索時間でより高い精度のモデルを発見することができた. また, 探索中にアーキテクチャを one-hot 化した際の accuracy を図 2 に示す. 提案手法は先行研究と比較して同程度の探索時間でより accuracy の高い a とパラメータ w_a の組を得ていることがわかる. しかしいずれの手法においてもより高い accuracy を得るためには再学習が必要であることが示唆されている. 図 3 には, 提案手法を用いて探索を行った結果の reduction cell を図示する.

6. おわりに

本研究では, アーキテクチャ探索の高速化を目的として方策勾配に貢献度分配を導入した手法を提案した. 提案手法は DARTS, SNAS と比較して 1 イテレーションの計算コストが候補数 $|\mathcal{J}|$ に対して定数になるというメリットがあり, イテレーション回数で比較した際もこれらに迫る性能を示した.

参考文献

[Cai 19] Cai, H., Zhu, L., and Han, S.: ProxylessNAS: Direct Neural Architecture Search on Target Task and Hardware, in *ICLR* (2019)

[Liu 19] Liu, H., Simonyan, K., and Yang, Y.: DARTS: Differentiable Architecture Search, in *ICLR* (2019)

[Pham 18] Pham, H., Guan, M., Zoph, B., Le, Q., and Dean, J.: Efficient Neural Architecture Search via Parameters Sharing, in *ICML*, pp. 4095–4104 (2018)

[Williams 92] Williams, R. J.: Simple statistical gradient-following algorithms for connectionist reinforcement learning, *Machine Learning*, Vol. 8, No. 3, pp. 229–256 (1992)

[Xie 19] Xie, S., Zheng, H., Liu, C., and Lin, L.: SNAS: stochastic neural architecture search, in *ICLR* (2019)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

部分データ集合に基づくパラメータ初期化による ニューラルネットワークの学習安定化

Progressive Data Increasing as Initialization of Neural Networks

佐藤利鷹理 *1　木村正成 *2
Ryosuke Sato　Masanari Kimura

*1株式会社 Ridge-i　*2株式会社 Ridge-i
Ridge-i inc.　Ridge-i inc.

Deep neural networks (DNNs) have recently been achieving state-of-the-art performance on a variety of tasks. With the improvement of the hardware performance, the structure of the neural network becomes more and more complicated, and the amounts of data used for training networks are becoming larger.Although these changes greatly contributed to the recognition accuracy of the neural network, it often leads to training instability in some cases.In this paper, we propose to use a subset of training data for initialization of neural networks. We found that it can help us to stabilize the training process.

1. はじめに

近年，ディープニューラルネットワークは様々なタスクにおいて大きな成功を収めている [1, 2]．こうした成功の多くは，学習データの大規模化とネットワークの複雑化によってもたらされている．しかし，こうしたネットワーク構造と学習データの複雑化によって，ニューラルネットワークの学習が不安定になってしまうケースが多く存在する．

我々は，ネットワークの重みの初期値問題に着目することでこうした問題を解決することを目指す．本論文における提案手法は，学習データ全体の小規模な部分データ集合を用いて，ネットワークの重みをタスクやドメインにとって適切に初期化を行うことで，学習の安定化を達成する．実験結果から，提案手法がニューラルネットワークにとって望ましい重みの初期値を導出できることを示す．

2. ニューラルネットワークの重み初期化

我々は，大規模データにおける DNNs の学習の不安定性を，ネットワークの重みの初期値問題の視点から考える．DNNs の学習の安定性および最終的な認識性能はネットワークの重みの初期値に依存する．こうした DNNs の初期化に関する研究はいくつか存在する [3, 4, 5]．

2.1 Kaiming Initialization

特に Kaiming He ら [5] が提案した初期化手法は，現在最も用いられている手法のうちの 1 つである．

ネットワークの順伝播において，第 i 層の出力は，

$$y^i = W^i x^i + b^i \tag{1}$$

と表現できる．$x_i \in \mathbb{R}^{n_i}$ は i 番目の入力，$W_i \in \mathbb{R}^{d,n}$ は重みフィルタである．活性化関数 $f(\cdot)$ の出力は，

$$x^{i+1} = f(W^i x^i + b^i) \tag{2}$$

$$= f(y^i) \tag{3}$$

ここで，He らはネットワークの初期値について以下のような仮定を置いている．

連絡先: 佐藤利鷹理，株式会社 Ridge-i，東京都千代田区大手町 1-6-1　大手町ビル 442，rsato@ridge-i.com

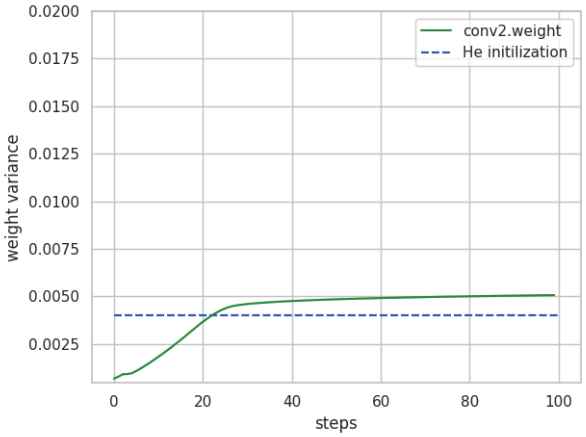


図 1: 部分データ集合を用いたネットワークの重み初期化によって得られる重みの分散．CIFAR10 データセットから 0.1%の部分集合を抽出して，3 層の畳み込みニューラルネットワークについて初期化を行い，2 層目の畳み込み層の重みの分散を図示している．

- W_i と x_i の各要素の初期値はそれぞれ独立であり，同じ分布からサンプリングされる
- W_i と x_i は互いに独立である

これに基づき，He らは第 i レイヤーの重みを 平均 0, 分散 $2/n_i$ の正規分布を用いて初期化している．

$$Var[W^i] = \frac{2}{n_i} \tag{4}$$

この分布を用いた重みパラメータの初期化は，従来の初期化手法と比べてより良い実験結果を得ることができている．

2.2 Progressive Data Increasing as the Initializer

与えられた N 件の学習データを $D^{d\times N} = \{(\boldsymbol{x}_i, \boldsymbol{y}_i)\}_{i=1}^N$ とし，$\boldsymbol{x}$ をデータ点，$\boldsymbol{y}$ をラベル，d をデータの次元数とする．一般的な機械学習のタスクでは，$D^{d\times N}$ を用いて任意の損失関数 L を最小化するようにモデルを学習させる．しかし，デー

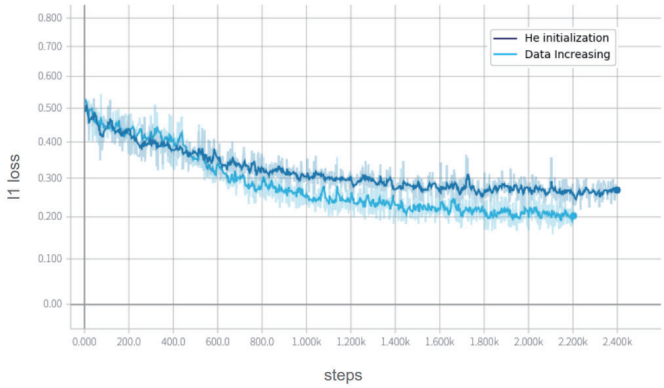


図 2: He Initialization と提案手法の VAE による画像生成の比較実験の結果．提案手法では，CIFAR10 データセットから 0.1%の部分集合を抽出して重みの初期化を行った後，データセット全体を用いて学習させている．

タの次元数 d が大きい場合やネットワーク構造が複雑である場合，学習が不安定になってしまうケースが多く存在する．

我々は，こうした観測がネットワークの重みの初期値が不適切なまま大量のデータで学習を試みていることに起因すると仮定し，学習データの小規模な部分集合を用いて重みを擬似的に初期化する Progressive Data Increasing を提案する．重みの初期化に用いる部分データ集合 S は，

$$S^{d\times M} = \{(\boldsymbol{x}_i, \boldsymbol{y}_i) \sim P(\boldsymbol{x}, \boldsymbol{y}),\ \forall(\boldsymbol{x}_i, \boldsymbol{y}_i) \in D\}_{i=1}^{M} \qquad (5)$$

と表現できる．ここで M は初期化に用いる部分データ集合のサイズ，P は任意の分布とする．$S^{d\times M}$ によって学習されるモデル f は，

$$f_{t^0} = \arg\min_{t} L(S, f, t) \qquad (6)$$

であり，t^0 は初期化によって得られるモデルのパラメータである．我々はこの t^0 に対するいくつかの分析を行い，t^0 がニューラルネットワークの重みの初期値として望ましい性質を満たすことを示す．

3. 実験結果

図 2.1 に，提案手法で得られる初期値の分散を図示する．図から，部分データ集合を用いた初期化で得られる重みの分散は，He らが導出した，ネットワークにとって望ましい重みの分散とほぼ一致することがわかる．提案手法を用いることで，He らの初期化と同様に，重みの分散は $2/n_i$ の周辺に収束し，学習の安定性を損なわないような初期値を得られている． 実験では CIFAR10 データセット [*1] を用いている．図では 2 層目の重みをプロットしているが，それ以外の層でも類似した実験結果が得られた．

また，図 2.2 に He らの初期化手法と提案手法を適用した Variational Auto Encoder （VAE）の学習曲線の比較を示す．表 1 は，この実験で得られた最終的なスコアの比較である．実験に用いた VAE のネットワーク構造は 162 層からなる深い Resnet 構造 [6] を用いている．また，生成画像のサイズは 1024×1024，データセットは CIFAR10 を対象としている．比較から，複雑なネットワークアーキテクチャによる学習では，提案手法を用いることで，He らの初期化手法と比べてより安定した学習ができることを示している．

∗1 https://www.cs.toronto.edu/ kriz/cifar.html

表 1: He Initialization と提案手法の VAE による画像生成の比較実験の定量評価．

Initializers	L1 Loss
Kaiming He	0.2418
Progressive Data Increasing	**0.1860**

4. おわりに

本論文では，学習データセットの部分集合を利用してニューラルネットワークの重みの初期化を擬似的に行い，学習の安定性を向上させる手法を提案した．提案手法はどのようなネットワーク構造，データセットおよびタスクにおいても汎用的に適用可能である．また，実験結果から提案手法が学習の安定化に対して有効であることを示した．

今後の研究課題としては，初期化に用いる部分データ集合の選択を，より効果的に行うことなどが考えられる．現在は与えられた学習データの中から無作為に小規模な部分集合を抽出し，それをネットワークの初期化に用いている．この部分集合をより学習の安定化に寄与するように選択することができれば，さらなる学習の安定化およびネットワークの汎化性能向上につながり得る．

参考文献

[1] 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.

[2] Ronan Collobert, Jason Weston, Léon Bottou, Michael Karlen, Koray Kavukcuoglu, and Pavel Kuksa. Natural language processing (almost) from scratch. *Journal of Machine Learning Research*, Vol. 12, No. Aug, pp. 2493–2537, 2011.

[3] Dmytro Mishkin and Jiri Matas. All you need is a good init. *arXiv preprint arXiv:1511.06422*, 2015.

[4] Xavier Glorot and Yoshua Bengio. Understanding the difficulty of training deep feedforward neural networks. In *Proceedings of the thirteenth international conference on artificial intelligence and statistics*, pp. 249–256, 2010.

[5] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. In *Proceedings of the IEEE international conference on computer vision*, pp. 1026–1034, 2015.

[6] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770–778, 2016.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

転移学習による機械語命令列分類における学習の効率化

Efficient learning in machine language instruction sequence classification by transfer learning

大坪 雄平 *1*2 Yuhei Otsubo　大塚 玲 *2 Akira Otsuka　岩田 吉弘 *1 Yoshihiro Iwata　三村 守 *3 Mamoru Mimura　榊 剛史 *4 Takeshi Sakaki

*1警察庁 National Police Agency　*2情報セキュリティ大学院大学 Institute of Information Security　*3防衛大学校 National Deffense Academy　*4東京大学 University of Tokyo

In this paper, we propose a learning method for a machine language instruction sequence which is difficult to prepare a large-scale data set, e.g., packer classification. We used the learning result of the compiler classification which is easy to prepare a large-scale data set. Our examination result shows that it is possible to classify with accuracy of 92% even if only 10 samples of each class are gathered in 30 class classification.

1. はじめに

深層学習において，高精度な分類の実現には大規模なデータセットが重要な要因の 1 つとされている．過去の我々の研究で，ファイルの断片から実行コードを 99%以上の精度で認識できる手法（o-glasses）を提案した [Otsubo 18]．この手法は，入力データを x86/x86-64 実行コードとみなし，これを固定長命令に変換したものを 1d-CNN に入力している．CNN の局所受容野と重み共有の仕組みを固定長命令に適用させることで 99%という精度が実現されている．過去の研究においては，オープンソースから機械語命令列を生成することにより比較的容易に大規模なデータセットを準備することができた．しかしながら，サンプルを大量に集めることが困難であったり，集められたとしても正確なラベル付けが困難であったり，現実には容易に大規模なデータセットを準備できない問題も数多く存在する．

そこで我々は，機械語命令列の分類問題の中で大規模なデータセットを準備することが困難な分野の問題について，転移学習を活用することにより効率的に学習する手法を提案する．本論文では，データセットの大規模化が困難な分類問題として，パッカー推定を例に実験を行った．その結果，各クラスで 10 サンプルしか準備できない場合においても，比較的容易に大規模なデータセットが準備できるコンパイラ推定問題のデータセットの学習結果を転移学習することで 30 クラス分類で 92.0%の Accuracy で分類できることが明らかとなった．これは，転移学習を用いない場合と比較して 1.7%の精度向上であった．

提案手法は，既存手法と同程度のデータセットを準備できる場合は同程度の性能が得られる．加えて，十分にデータセットを準備できない場合は既存手法より良い性能が得られる可能性がある．そのため，提案手法は既存手法より多様な領域に適用可能であると考えられる．

2. 予備知識

2.1 パッカー

パッカーとは，プログラムをパッキング（暗号化／圧縮）するソフトウェアツールの総称である．マルウェアの多くは，静的解析 *1 を妨害するために，パッキングという技術を用いている．そのため，解析をする際は，解析者はパッキングツールの種類を特定してから，パッキングを解除するための手順を考え，マルウェア本来のコード（以下，オリジナルコード）を抽出しなければならない．さらに，UPX[Markus 96] や Themida[Oreans Technologies] などのパッカーを使用するだけでマルウェアをパッキングすることができる．そのため，攻撃者の労力はほぼない．加えて，多くの種類のパッカーが流通しているため，あるマルウェアに対してどのパッカーが使用されたかはマルウェア取得時点では解析者側には分からない．そのため，取得のたびに使用されているパッカーの特定やアンパッキングをしなければならない．そこで，パッカーの種類を自動的に特定することができれば，オリジナルコードを取り出すまでにかかる手間が削減でき，解析の効率化につながる．また，オリジナルコードを自動で抽出するツールの作成にもつながる可能性がある．

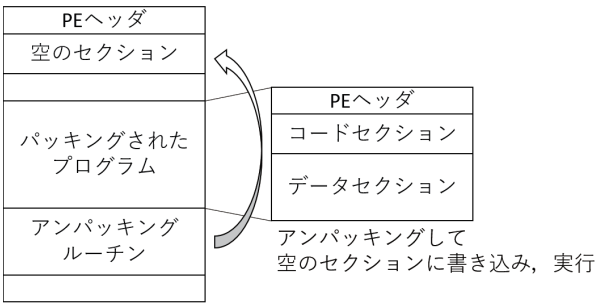


図 1: UPX でパッキングされたプログラムのファイル構造と挙動

パッカーは対象のプログラムをパッキングし，それにアンパッキングルーチンを付加する．このアンパッキングルーチンにより，自己解凍及び実行が可能となっている．例として，UPX でパッキングされたプログラムのファイル構造を図 1 に示す．UPX でパッキングされたプログラムは，PE ヘッダと空のセクション，パッキングされたオリジナルプログラム，アンパッキングルーチンで構成されている．プログラムが実行されると，アンパッキングルーチンが先に実行され，パッキングされたプログラムをアンパッキングし，メモリ上に展開する．アンパッキングされたオリジナルプログラムは空のセクションに書き込まれた後，実行される．

UPX は非常に単純なパッカーだが，Themida や

連絡先: 氏名，所属，住所，電話番号，Fax 番号，電子メールアドレスなど

*1 マルウェアを動作させることなく，プログラミングコードから情報を得る解析

ASProtect[StarForce Technologies Ltd.] などは複雑なパッキングアルゴリズムを有しており，パッキングに使用されたパッカーによりプログラムの動きは異なってくる．

3. 関連研究

パッカー推定によく使われるツールとして PEiD [*2] があげられる．PEiD は非常に高い精度でパッカーを検知できるものの，パターンマッチングを用いていることから，誤検知率を抑えたシグネチャの作成に手間がかかる上に，シグネチャが複雑になる傾向がある．また，新しいパッカーに対応するためには，新しいパッカー用のシグネチャの作成だけでなく，既存のシグネチャを修正する必要もあり，性能の維持にコストがかかる．

上記の課題を解決するため機械学習を用いたパッカー推定について，様々な研究がされている．この中で本論文と最も関連の深いものは伊沢らの手法 [Isawa 14] である．伊沢らは，プログラムのエントリポイント部分（EP）にパッカーの特徴が最も現れると考え，EP から 15 バイト分のバイナリデータを SVM で学習させた．26 種類のパッカーと 3 種類のパッキングされていないプログラムの計 29 クラスを含む約 4,000 のサンプルを用いた実験では，99.46 %という非常に高い Accuracy で分類できることが確認されている．

4. o-glasses

この節では，過去に我々が提案した o-glasses[Otsubo 18] について述べる．この手法は，入力データを x86/x86-64 実行コードとみなし，これを固定長命令に変換したものを畳み込みニューラルネットワーク（CNN [LeCun 89]）に入力している．CNN の局所受容野と重み共有の仕組みを固定長命令に適用させることで，実行コードの分類が 99%という精度で実現されている．

入力データは，2048bit 値配列で，128bit 固定長命令に変換された実行コードを 16 命令分としている．1 層目は 1d-CNN で，フィルタサイズを 128，ストライドを 128 とし，1 命令分の局所受容野を形成している．出力されるチャンネルの深さは 96 である．2 層目も 1d-CNN で，フィルタサイズを 2，ストライドを 1，チャンネルの深さを 256 としている．この層により，2 つの命令間の関係の特徴を得ることを期待している．3〜5 層目は全結合で，ノード数は 400,400，n としている．ここで，n は分類するクラス数である．また，3〜4 層目の入力部分には，ネットワークの学習プロセスをより安定化させ高速化するため，Batch Nomalization[Ioffe 15] を取り入れている．中間層の活性化関数は ReLU を，出力層の活性化関数は Softmax 関数を使用している．

この手法は，実行コードか否かの認識に留まらず，様々な分野に適用できる可能性がある．例えば，この手法を用いて実行コードを生成したコンパイラの推定できるか実験を行ったところ，コンパイラの種類，対象アーキテクチャ，最適化レベル等の 15 クラス分類について，16 命令というコード断片から 95%以上の精度で分類できることが確認されている [大坪 18]．

5. 提案手法

本論文では，パッカーの推定手法として，伊沢らの手法 [Isawa 14] と同様にプログラムの EP に格納されている機械語命令列に着目する．具体的には，EP を起点として L 個の命令を入力データとして o-glasses に入力し，パッカー推定を行う．この EP の機械語命令列に着目したパッカー推定は，前述のコンパイラ推定と比較して学習用データセットの作成について課題がある．コンパイラ推定の場合，1 つのプログラムに含まれる機械語命令すべてをデータセットに組み込めるため，データセットの大規模化は容易である．一方，EP の機械語命令列に着目したパッカー推定の場合，1 つのプログラムから作成できるサンプルは 1 つだけである．加えて，攻撃者が使用しているパッカーの入手が困難な場合がある．その場合，実際の攻撃で観測されたマルウェアからサンプルを作成することとなる．一般的なプログラムと比較してマルウェアの入手はより困難であることから，データセットの大規模化は更に困難なものとなる．

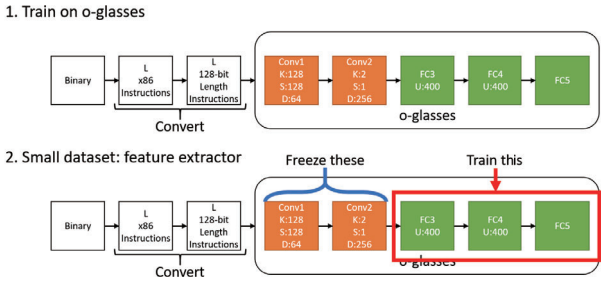


図 2: 提案手法の概要

そこで我々は o-glasses の学習フェーズで転移学習を行う．転移学習は，ある領域で学習させたモデルを別の領域に適応させる技術のことであり，少ないデータで精度の高い学習結果を得ることができるというメリットがある．提案手法の概要を図 2 に示す．

具体的には以下の手順で学習を行う．まずは，o-glasses のネットワーク全体でコンパイラ推定用のデータセットを用いて学習を行う．我々はこの学習済みネットワークに，以下の特徴を有していることを期待している．

- 1 層目の CNN で 1 命令分の局所受容野の形成
- 2 層目の CNN で 2 つの命令間の特徴を得る
- プログラムとして成立する命令列か否かの判別

この学習済みネットワークの第 1 層と第 2 層の CNN における重み（パラメータ）を固定し，パッカー推定用のデータセットの学習を行う．パッカー推定用のデータセットはコンパイラ推定用のデータセットと比較して非常に小規模なものであるが，転移学習を用いることで効率的に学習を行うことが期待される．

6. 評価実験

提案手法の有効性を評価するため，以下の手順で実験を行った．

6.1 コンパイラ推定用のデータセットによる事前学習

コンパイラ推定用のデータセットの概要を表 1 に示す．このデータセットは，オープンソースから誰でも収集することができ，大規模なデータセットを容易に作成できる．具体的には以下の手順で作成した．GitHub[*3] 上でオープンソースソフト

*2 最新のバージョン 0.95 は次の Web サイトからダウンロード可能：https://www.softpedia.com/

*3 https://github.com/

表 1: Number of elements in each of our datasets

Label	Compiler	Arch.	Opt.	File	Code
Program	VC2017	32bit	None	1,170	369,605
			Max	1,147	255,143
		64bit	None	1,456	540,568
			Max	1,242	542,020
	VC2003	32bit	None	1,350	292,277
			Max	1,306	270,743
		64bit	None	-	-
			Max	-	-
	GCC	32bit	None	2,111	227,004
			Max	1,844	239,821
		64bit	None	1,582	283,276
			Max	1,580	287,775
	Clang	32bit	None	1,205	101,024
			Max	1,196	86,521
		64bit	None	1,892	332,278
			Max	1,883	246,500
	ICC	32bit	None	1,761	1,494,677
			Max	1,724	1,161,499
		64bit	None	1,796	1,419,705
			Max	1,728	1,046,958
Others				130	912,958
Total				28,103	10,110,352

ウェアを収集し，複数のコンパイラ（VC[*4], GCC[*5], Clang[*6], ICC[*7]）で最適化レベルを「なし」と「最大」に変えながらコンパイルを行った．VC2003 は 32bit のみでコンパイルし，それ以外は 64bit および 32bit の両方でコンパイルした．コンパイルに成功したオブジェクトファイルのヘッダ情報を元に実行コード部分のみを取り出し，先頭から順番に L 個の命令ずつ切り出すことでデータセットを作成した．表 1 は $L = 16$ のときのデータセットの概要を示している．また，入力データが実行コードとみなせない機械語命令列にも対応するため，「Others」とラベル付けしたデータセットも作成した．これは，文書ファイルを元に作成した．文書ファイルは，文章，画像，メタデータなど様々な種類のデータが含まれている．その一方で，この文書ファイルがマルウェアでなければ，実行コードが含まれている可能性は極めて少ないと思われる．そこで，我々は検索エンジンを用いて「rtf」,「doc」,「docx」および「pdf」の 4 種類のファイルを収集し，VirusTotal[*8] を利用し，ウイルス対策ソフトでそのファイルがマルウェアとして検知されないことを確認した．その上で，文書ファイルを機械語命令列の集合とみなして，先頭から順番に強制的に逆アセンブルして L 個の命令ずつデータを切り出すことで，「Others」とラベル付けしたデータセットを作成した．

$L = 16$ の場合．19 クラスで延べ 28,103 個のファイルから合計 10,110,352 個の訓練データができた．このデータセットに含まれる命令の長さの平均を調べたところ，「Program」カテゴリで 3.69 バイト，「Others」カテゴリで 2.38 バイトであった．各クラス毎のサンプル数に偏りがあるため，学習に使用する各クラス毎のサンプル数の上限を 10 万 $\times L \div 16$ に設定し，$L = 16$ のときは、19 クラスで約 190 万のサンプルで事前学習を行った．なお，事前学習の epoch 数は 50 を選択した．

∗4 Microsoft Visual C++: 2003 and 2017
∗5 the GNU Compiler Collection: 6.3.0
∗6 a C language family frontend for LLVM: 5.0.2
∗7 Intel C++ Compiler: 19.0.0.117 Build 20180804
∗8 https://www.virustotal.com/

表 2: クラス分類結果

分類器	Accuracy	入力データ	クラス数
PEiD	66.53	シグネチャベース	29
伊沢ら SVM	99.46	EP から 15 バイト	29
提案手法	98.89	EP から 16 命令	30
提案手法	98.94	EP から 8 命令	30
提案手法	99.21	EP から 4 命令	30

6.2 既存手法と提案手法の性能比較

コンパイラ推定用のデータセットで学習した o-glasses のネットワークの 1 層目と 2 層目の重みを固定し，パッカー推定用データセットによる転移学習を行った．なお，転移学習の epoch 数は 500 を選択した．

データセットおよび既存手法との比較結果の概要を表 2 および表 3 に示す．

パッカー推定用データセットには 27 種類のパッカーでパッキングされたプログラムとパックする前のオリジナルのプログラム 3 種類（32bit，64bit および.NET）の計 30 のクラスが含まれる．表 3 の「Num.(1)」は準備したプログラムの数であり，「Num.(2)」は伊沢らが正常に動作（アンパッキングおよび実行）することを確認できたプログラムの数である．「PEiD」はパターンマッチングを用いたパッカー等を検知するツールであり，「伊沢ら SVM」は関連研究で取り上げた手法 [Isawa 14] である．この 2 つの既存手法の実験は「Num.(2)」に該当するデータを 10 分割交差検証で実験したものであり，論文 [Isawa 14] から実験結果を引用した．「Num.(2)」以外のプログラムについて，我々が確認したところ，全てではないが複数のプログラムで正常動作を確認することができた．そこで，提案手法の実験については，データセットの規模を大きくするため，正常に動作しなかったものも含む「Num.(1)」に該当するデータを用いた．このデータで伊沢らと同様に 10 分割交差検証で各クラスの Precision（P）および Recall（R）を求めた．

実験の結果，同規模のデータセットを使用した場合，提案手法は既存の伊沢らの手法とほぼ同等の性能を獲得していることが明らかとなった．

6.3 小規模データセットを用いた実験

より小規模データセットにおける提案手法の性能を評価するため，10 分割交差検証に使用する各クラスのサンプル数の上限を S とし，S を変化させた場合の Accuracy の変化を求めた．実験の結果を表 4 に示す．実験の結果，$S = 10, 20$ のような非常に小規模なデータセットにおいて，転移学習を用いる方が高い Accuracy でパッカーを分類できることが明らかとなった．

7. おわりに

本論文では，機械語命令列の分類問題について，容易に大規模なデータセットを準備できる分類問題の学習結果を転移学習することにより，大規模なデータセットの準備が困難な分類問題を効率的に学習する手法を提案した．データセットの準備が困難な分類問題の例としてパッカー推定の実験を行った結果，転移学習を活用することにより，各クラスのサンプル数が 10 個しか集まらない場合でも 92%という精度で分類できることを示した．

提案手法は，既存手法と同程度のデータセットを準備できる場合は同程度の性能が得られる．加えて，十分にデータセット

表 3: クラス分類結果. (Num.): サンプル数, (P): precision, (R): recall, (NaN): PEiD が未対応のもの.

		Num.		PEiD		伊沢ら SVM		提案手法 (L=16)		提案手法 (L=8)		提案手法 (L=4)	
No.	Class	(1)	(2)	P	R	P	R	P	R	P	R	P	R
1	Unpacked(64bit)	475	432	NaN	0.0	100.0	99.8	99.8	100.0	100.0	99.6	100.0	99.8
2	Armadillo 4.00.0053	203	203	100.0	99.0	98.5	100.0	99.0	100.0	98.2	100.0	99.0	100.0
3	MoleboxPro 2.6.4	203	195	100.0	99.0	100.0	100.0	99.1	100.0	99.5	100.0	100.0	100.0
4	Themida 1.8.5.5	195	194	100.0	99.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
5	PESpin 1.330	194	191	100.0	99.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
6	obsidium 1.3.5.4	191	188	NaN	0.0	100.0	100.0	98.0	100.0	99.5	100.0	99.0	100.0
7	ASProtect 2.100	188	185	100.0	98.9	100.0	100.0	99.5	100.0	99.5	100.0	100.0	100.0
8	yoda's protector 1.020	194	170	100.0	98.9	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
9	Unpacked(32bit)	212	165	98.1	89.4	95.3	94.7	96.8	93.8	95.7	94.3	96.3	95.3
10	obsidium 1.4.5	165	143	NaN	0.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
11	nPack 1.1.300	201	141	100.0	11.2	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
12	eXPressor 1.5.0.1	182	139	NaN	0.0	100.0	100.0	100.0	100.0	100.0	100.0	99.5	100.0
13	ASPack 2.12	194	127	100.0	98.6	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
14	PECompact 2.64	201	126	100.0	98.4	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
15	Unpacked(32bit&.net)	144	122	100.0	95.2	100.0	99.2	100.0	98.6	100.0	98.6	100.0	98.6
16	NsPack 3.7	203	116	100.0	98.4	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
17	RLPack 1.2	200	116	NaN	0.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
18	FSG 2.0	203	111	100.0	99.1	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
19	UPX 3.08	194	99	97.4	99.1	98.2	99.1	99.5	100.0	99.5	100.0	98.5	100.0
20	ASPack 2.11	147	99	100.0	98.0	100.0	100.0	99.3	100.0	96.9	100.0	100.0	100.0
21	Mew11SE 1.2	189	88	100.0	98.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
22	ACProtect pro 1.32	88	75	98.7	87.5	95.6	98.9	87.1	92.1	88.8	92.2	92.8	97.8
23	WWPack32 1.2	108	64	100.0	98.7	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0
24	AntiCrack 1.32Pro	64	64	NaN	0.0	100.0	95.3	91.0	77.9	90.1	81.4	98.6	90.7
25	PETITE 2.2	90	63	100.0	95.2	96.8	96.8	98.2	97.8	99.0	97.8	99.0	97.8
26	exe32pack 1.4.2	97	62	100.0	96.8	100.0	98.4	100.0	98.9	100.0	98.9	100.0	98.9
27	tElock 0.98	74	55	100.0	98.2	100.0	100.0	98.9	100.0	98.9	100.0	100.0	100.0
28	PKLITE 32	20	20	100.0	85.0	90.0	90.0	93.3	90.0	91.7	90.0	93.3	90.0
29	Upack 0.39	201	10	100.0	90.0	100.0	100.0	96.7	97.0	97.1	97.0	97.2	96.5
30	WinUpack 0.31beta	197	-	-	-	-	-	97.1	95.3	97.0	95.4	96.6	95.9

表 4: o-glasses における転移学習の評価実験結果

	Accuracy				
S	10	20	40	80	制限なし
転移学習あり	92.0	95.8	97.3	98.2	99.2
転移学習なし	90.3	94.3	98.0	98.2	99.1

を準備できない場合は既存手法より良い性能が得られる可能性がある．そのため，提案手法は既存手法より多様な領域に適用可能であると考えられる．

謝辞

本研究では，パッカーのデータセットを国立研究開発法人情報通信機構サイバーセキュリティ研究所の伊沢亮一博士に提供いただいた．ここに感謝する．

参考文献

[Ioffe 15] Ioffe, S. and Szegedy, C.: Batch normalization: Accelerating deep network training by reducing internal covariate shift, *arXiv preprint arXiv:1502.03167* (2015)

[Isawa 14] Isawa, R., Ban, T., Guo, S., Inoue, D., and Nakao, K.: An Accurate Packer Identification Method Using Support Vector Machine, *IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences*, Vol. 97, No. 1, pp. 253–263 (2014)

[LeCun 89] LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., and Jackel, L. D.: Backpropagation applied to handwritten zip code recognition, *Neural Computation*, Vol. 1, No. 4, pp. 541–551 (1989)

[Markus 96] Markus, F. O., Lszl, M., and John, F. R.: the Ultimate Packer for eXecutables, `https://upx.github.io/` (1996)

[Oreans Technologies] Oreans Technologies, : Themida, `https://www.oreans.com/themida.php`

[Otsubo 18] Otsubo, Y., Otsuka, A., Mimura, M., Sakaki, T., and Goto, A.: o-glasses: Visualizing x86 Code from Binary Using a 1d-CNN, *ArXiv e-prints*, p. arXiv:1806.05328 (2018)

[StarForce Technologies Ltd.] StarForce Technologies Ltd., : ASPack Software, `http://www.aspack.com/asprotect32.html`

[大坪 18] 大坪 雄平, 大塚 玲, 三村 守, 榊 剛史, 受川 弘, 岩田 吉弘 F コード断片からのコンパイラ推定手法, コンピュータセキュリティシンポジウム 2018(CSS2018), pp. 4C2–1 (2018)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

Wasserstein Autoencoderを用いた画像スタイル変換

A Style Transfer Method using Wasserstein Autoencoder

中田 秀基 *1　　麻生 英樹 *1
Hidemoto NAKADA　　Hideki ASOH

*1産業技術総合研究所 人工知能研究センター
Artifical Intelligence Research Center, National Institute of Advanced Institute of Technology

We propose a image style transfer method based on Wasserstein Autoencoder. Style transfer is an area of image generation technique that generates an image that shows content taken from one image with a style taken from another image. While there are extensive researches in this area, most of them requires some 'training' time to generate images with specific style. The proposed method does not require training time which trains a network that can be used for any style and content image. The network encode images into content latent variables and style latent variables. We can transfer image style by simply replacing style latent variables. We tested the proposed method with images from CelebA and confirmed that it can generate style transferred images.

1. はじめに

画像スタイル変換とは、コンテント画像に対してスタイル画像から抽出したスタイルを適用することで、任意のコンテントを任意のスタイルで描画することを実現する技術である。Gatys ら [Gatys 15][Gatys 16] の手法は、画像そのものを最適化することでスタイル変換を実現するため、スタイル変換に時間がかかるという問題がある。

これに対して、Johnson ら [Johnson 16] はフィードフォワードネットワークのみでスタイル変換を行う手法を提案した。この手法は、スタイル変換自体は瞬時に行うことができるが、スタイルにあわせてフィードフォワードネットワークを訓練する必要があり、これには一定の訓練時間が必要となる。

われわれは、Variational Autoencoder を用いたスタイル変換の研究を進めてきた [中田 18]。本稿では、Wesserstein Autoencoder[Tolstikhin 18] を用いてスタイル変換を行う手法を提案する。スタイルを表す隠れ変数へのエンコーダ、コンテントを表す隠れ変数へのエンコーダ、2 つの隠れ変数からのデコーダを同時に学習させることで、任意のスタイル画像と任意のコンテント画像からの変換済み画像の生成を実現する。学習した結果のネットワークは、任意のスタイル画像に対するスタイル変換を行う汎用のフィードフォワードネットワークとなるので、

本論文の構成は以下の通りである。2. で本研究の背景を概説し、3. で提案手法について述べる。4. で実験結果を示す。5. で関連する研究を議論する。6. では、まとめと今後の課題について述べる。

2. 背景

2.1 画像スタイル変換

Gatys ら [Gatys 15][Gatys 16] は、物体を識別するように訓練された CNN の各レイヤのレスポンスからスタイルを表す特徴量を構成することが可能であることを示した。この特徴量は、各レイヤを構成する各フィルタ（チャンネル）におけるレスポンスの相関をとったグラム行列で、レイヤ l のフィルタ i, j に対して特徴マップをベクタにしたものを $\mathbf{F_i}$,$\mathbf{F_j}$ として、$G^l_{i,j} = \mathbf{F_i} \cdot \mathbf{F_j}$ と表される。ここで $\cdot$ はベクタの内積を表す。以降これをスタイル特徴量と呼ぶ。

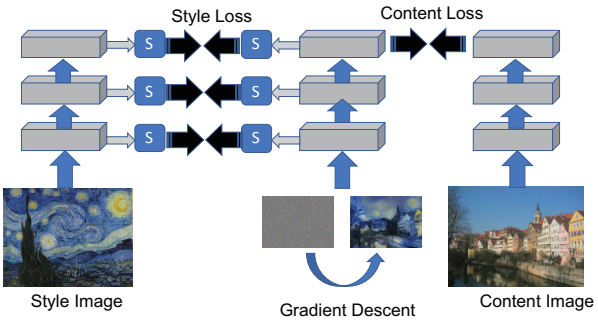


図 1: Gatys らの手法。図中の画像は [Gatys 15] より。

1）スタイルロス：生成画像とスタイル画像のスタイル特徴量の差、2) コンテントロス：コンテント画像と生成画像の上位レイヤでのレスポンスの差、とし、この 2 つのロスの線形和をロス関数とする。Gatys らの手法は、このロス関数が最小になるように、ノイズで初期化した生成画像を勾配降下法で最適化する。図 1 にこの様子を示す。左右に 3 つ並んでいるネットワークはすべて事前に ImageNet を学習した同一のネットワークで、固定されている。画像生成時には、スタイル画像を左のネットワークに、コンテント画像を右のネットワークに、ノイズで初期化した生成画像を中央のネットワークに与え、ロス関数を用いて、生成画像を最適化する。この手法は、非常に解像度の高い画像が得られる一方で、画像の生成に勾配降下法を用いるため、時間がかかる。

この問題点を解決するために Johnson ら [Johnson 16] はフィードフォワードネットワークのみでスタイル変換を行う手法を提案した。この手法は Gatys らの提案したものと同じロス関数を用いて画像を変換するネットワークを訓練する。スタイル変換はフィードフォワードネットワークに一度通すだけで行われるため、変換時の計算負荷は小さい。一方で、画像変換ネットワークの訓練にはコストが掛かり、個々のスタイルに対して、GPU を用いても数時間の訓練が必要となる。

丹野ら [丹野 17] は、一つのネットワークに複数のスタイルを学習させる方法を提案しているが、スタイルごとに学習が必要であるという意味では、本質的な解決とはなっていない。

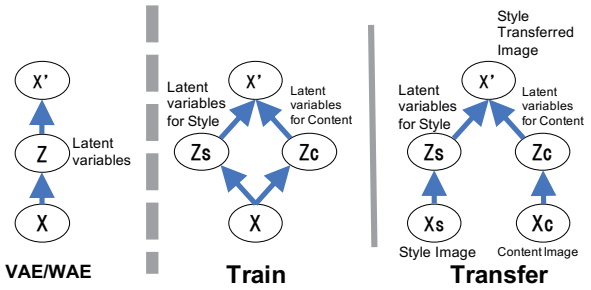


図 2: 左: VAE の構造。右：提案手法の概要

2.2 Variational Autoencoder と Wesserstein Autoencoder

Variational Autoencoder[Kingma 14][Doersch 16]（変分オートエンコーダ以下 VAE）は、隠れ変数 $\mathbf{z}$ から学習データ $\mathbf{x}$ を生成する確率分布 $p(\mathbf{x}|\mathbf{z})$ を学習する教師なし学習の一種である。具体的には、隠れ変数 $\mathbf{z}$ がある確率分布に従うことを仮定し、学習データ $\mathbf{x}$ から $\mathbf{z}$ へ変換するエンコーダネットワークと $\mathbf{z}$ から再構成データ $\mathbf{x}'$ へ変換するデコーダネットワークを同時に学習する。この際、$\mathbf{x}$ と $\mathbf{x}'$ の差と、隠れ変数 $\mathbf{z}$ と仮定した確率分布の差（KL ダイバージェンス）をロス関数として、エンコーダとデコーダを最適化する (図 2 左)。一般には仮定する $\mathbf{z}$ の事前確率分布として、平均 0 分散 1 の正規分布を用いる。

Wesserstein Autoencoder（以下 WAE）は、VAE が隠れ変数と仮定した確率分布の差の KL ダイバージェンスを最小化するのに対して、Wesserstein 距離を最小化する。生成画像を比較すると、WAE は VAE よりも良好な FID(Frechet Inception Distance) スコアを示すことが示されている。このため本稿では、WAE を用いた。

3. 手法

3.1 概要

本手法の基本的な発想は、スタイルとコンテントを隠れ変数として分離して学習させることにある (図 2 中央)。これを実現できれば、図 2 右のようにスタイル画像からスタイル隠れ変数を、コンテント画像からコンテント隠れ変数を取り出したものをデコーダネットワークに与えることで、スタイル変換を実現できる。

3.2 提案手法

提案手法では、スタイル隠れ変数を Gatys らのスタイル行列から抽出し、コンテント隠れ変数は通常の WAE で学習する。図 3 に提案手法の学習時のネットワークを示す。

左辺のネットワークには、Imagenet を用いて事前学習された VGG16[Simonyan 14] ネットワークを用いる。このネットワークを用いてスタイル行列を作り、それからニューラルネットワークを介してスタイル隠れ変数を構成する。このネットワークは学習の対象ではない。右辺のネットワークは通常のコンボリューションを用いたエンコーディングネットワークでこれからコンテント隠れ変数を構成する。これら 2 つの隠れ変数から、デコーダネットワークを用いて、画像を再構成する。

学習時のロスとしては、通常の WAE と同様に再構成画像と入力画像の誤差と、隠れ変数の事前確率と事後確率の Wesserstein 距離を用いる。これらを用いてエンコーダネットワーク、デコーダネットワーク、スタイル行列から隠れ変数を構成するネットワークの 3 つを同時に学習する。

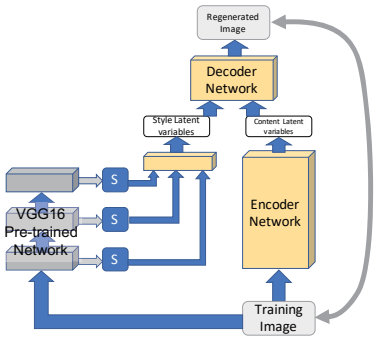


図 3: WAE を用いたスタイル変換の学習

表 1: エンコーダネットワークの構成

層	種類	入力	出力	カーネル	ストライド
1	Conv	64x64x3	64x64x8	3	1
2	Conv	64x64x8	32x32x32	4	2
3	Conv	32x32x32	16x16x128	4	2
4	Conv	16x16x64	8x8x256	4	2
5	Conv	8x8x128	4x4x512	4	2
6	Full	4x4x256	128 x 2	-	-

変換時には、左辺のスタイル隠れ変数導出ネットワークにスタイル画像を、右辺のエンコーダネットワークにコンテント画像を入力する。フィードフォワードネットワークの実行一回で任意のスタイル画像に対して任意のコンテント画像を適用する事ができる。

4. 実験

4.1 ロス

前述の通り、ロスは入力画像と再構成画像の誤差と、隠れ変数の事前確率と事後確率の Wesserstein 距離を用いる。前者の画像誤差としては、通常のピクセルの自乗誤差に加えて、スタイルネットワークの 3 層目までの出力の自乗誤差と、スタイル行列そのものの自乗誤差を用いた。これは、より強くスタイルを反映するようにするためである。各項の寄与はほぼ同等となるように重みで調整してある。

4.2 ネットワーク

図 3 に示したネットワークを、Tensorflow[ten] を用いて実装した。隠れ変数の数は、スタイル側を 1 層当たり 64 変数とし、3 層分まで用いた。したがって隠れ変数の数は 192 となる。スタイルとコンテントの隠れ変数の数の比率の影響を調べるため、コンテント側の隠れ変数の数を 512, 256, 128, 64, 32 と変化させて実験を行った。

エンコーダネットワークは標準的なコンボリューションネットワークである。このネットワークのパラメータを表 1 に示す。コンボリューション層では、max pooling 等は用いず、ストライドでサイズを小さくしていっている。活性化関数にはエンコーダでは eLU(Exponential Linear Unit) を、デコーダでは ReLU(Rectified Linear Unit) を用いた。

スタイル行列からスタイル隠れ変数を生成するネットワークには完全結合ネットワークを用いた。各層のレスポンスから生成したスタイル行列に対して、出力を 64x2 に設定した完全結合ネットワークを 3 段適用して、その結果を隠れ変数とした。

デコーダネットワークの構成を表 2 に示す。スタイル隠れ変数をサンプルしたものと、コンテンツ隠れ変数をサンプルした

表 2: デコーダネットワークの構成

種類	出力	カーネル	ストライド
Full	4x4x1024		
Subpixel conv	8x8x512	3x3	1
ResBlock	8x8x512		
ResBlock	8x8x512		
ResBlock	8x8x512		
Subpixel conv	16x16x256	3x3	1
Subpixel conv	32x32x128	3x3	1
Subpixel conv	64x64x64	3x3	1
Conv	64x64x3	5x5	1

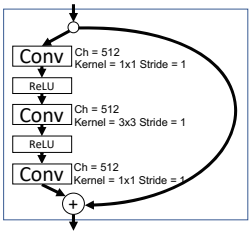


図 4: ResBlock の構造

ものを一本のベクトルにし、全結合ネットワークで、4x4x1024 に形を整えてから Subpixel Convolution[Shi 16] で 8x8x512 に変形してから図 4 に示す ResBlock[He 16] を 3 度通し、それをさらに Subpixel Convolution[Shi 16] で 3 回拡大して、64x64 の画像を得ている。

また、学習を高速化するために WeightNormalization[Salimans 16] を用いている。

4.3 データ

学習データ、変換前のコンテントデータとしては CelebA[cel] を用いた。スタイル画像としては図 5 に示す 8 枚の画像を用いた。また、学習データの多様性を確保するため、アニメ顔画像データセット [ani] と ImageNet[Russakovsky 15] の画像を一部用いた。

CelebA に関しては、OpenCV を用いて顔の中心を識別し顔のサイズが大まかにおなじになるようクロップして 64x64 とした。顔が小さい画像は排除したため、193,800 枚となった。

アニメ顔画像データセットは縦横いずれか長い方が 160 ピクセルの画像である。一辺が短辺の長さの正方形領域を切り出し、64x64 にリサイズして利用した。14,490 枚を利用した。

ImageNet に関しては色数が 3 で幅、高さがともに 64 以上のものを選択し、中心部 64x64 の領域を切り出して利用した。枚数は 196,371 枚を用いた。

4.4 結果

4.4.1 コンテント画像の再構成

スタイル変換の結果を示す前に、提案ネットワークの再現性能を示すために、コンテント画像（CelebA）を再構成したものを図 6(左) に示す。1 行目がオリジナル画像、2 行目-6 行目は CelebA のみで学習した場合、7 行目-11 行目はアニメ画像、IamgeNet を加えた学習した場合である 2 行目-6 行目、7 行目-11 行目はそれぞれ、コンテント画像の隠れ変数の数がそれぞれ、512, 256, 128, 64, 32 の場合の結果を示している。

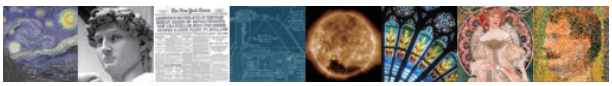


図 5: スタイル画像



図 6: 再構成画像。左:コンテント, 右:スタイル

学習データによる影響は見られない。コンテント画像の隠れ変数の数が増えるにしたがって、再現が正確になる傾向があることがわかる。

4.4.2 スタイル画像の再構成

同様にスタイル変換対象画像を再構成した結果を図 6(右) に示す。各行の意味は前項と同様である。

学習データの多様化による影響は大きく、アニメ画像、ImageNet を加えた場合のほうが良好な再構成ができている。また、CelebA のみで学習したケースでは、入力にない顔のような構造が再構成画像に現れている。これは特にコンテント画像の数が少ない場合に顕著である。これは CelebA のみで学習した結果、顔を出力するよう生成ネットワークが訓練されてしまったためであると考えられる。

4.4.3 スタイル変換結果

スタイル変換の結果を図 7 に示す。1 行目がコンテント画像、2 行目がスタイル画像、上段（3 行目-7 行目）は CelebA のみで学習した場合、下段（8 行目-12 行目）はアニメ画像、IamgeNet を加えた学習した場合の結果で、コンテント画像の隠れ変数の数がそれぞれ、512, 256, 128, 64, 32 の場合を示している。いずれの場合も、基本的にスタイル画像の特徴を再現したスタイル変換ができているといえる。

また、上段、下段いずれの場合もコンテント隠れ変数が減少すると、スタイル画像による影響がおおきくなることがわかる。また上段の場合には、CelebA の平均的な顔画像に引きずられる傾向がある。

9 行目、10 行目（コンテント隠れ変数 256, 128）近辺で特に良好なスタイル変換を実現できているといえる。

5. 関連研究

Li ら [Li 17] は、コンテント画像に対して whitening という処理を施した後に、スタイル画像に基づく coloring という操作を各レイヤで施すことでスタイル変換を行う。この手法は、



図 7: WAE を用いたスタイル変換

提案手法同様に任意のスタイルを任意のコンテントに適用でき、非常に高品質な画像生成を達成している。提案手法とは全く異なるアプローチであるため、比較を行う必要がある。

6. おわりに

本稿では、Wesserstein Autoencoder を用いて、スタイル変換を行う手法を提案し、ネットワーク学習時に多様な画像を与えることで良好なスタイル変換が行えることを確認した。また、スタイル隠れ変数とコンテント隠れ変数の比率を変化させることでスタイルの寄与度を変更できることを確認した。

今後はより多様な画像への適用を行い、従来手法との比較を行う予定である。

謝辞

実装をお手伝いいただいた井上辰彦氏に感謝する。この成果の一部は、国立研究開発法人新エネルギー・産業技術総合開発機構 （ＮＥＤＯ）の委託業務の結果得られたものである。本研究は JSPS 科研費 JP16K00116 の助成を受けたものである。

参考文献

[ani] AnimeFace Character Dataset : `http://www.nurs.or.jp/~nagadomi/animeface-character-dataset/` Accessed: 2018-02-01

[cel] Large-scale CelebFaces Attributes (CelebA) Dataset, `http://mmlab.ie.cuhk.edu.hk/projects/CelebA.html` Accessed: 2018-02-01

[Doersch 16] Doersch, C.: Tutorial on Variational Autoencoders, arXiv:1606.05908v2 [stat.ML] (2016)

[Gatys 15] Gatys, L. A., et al.: A Neural Algorithm of Artistic Style, arXiv:1508.06576 (2015)

[Gatys 16] Gatys, L. A., et al.: Image Style Transfer Using Convolutional Neural Networks, in *Proc. of IEEE Computer Vision and Pattern Recognition* (2016)

[He 16] He, K., et al.: Deep Residual Learning for Image Recognition, in *Computer Vision and Pattern Recognition (CVPR)* (2016)

[Johnson 16] Johnson, J., et al.: Perceptual Losses for Real-Time Style Transfer and Super-Resolution, in *Proc. of European Conference on Computer Vision*, pp. 694–711 (2016)

[Kingma 14] Kingma, D. P. and Welling, M.: Auto-encoding variational Bayes, in *Proceedings of the 2nd International Conference on Learning Representations* (2014)

[Li 17] Li, Y., et al.: Universal Style Transfer via Feature Transforms, in *Advances in Neural Information Processing Systems 30*, pp. 385–395 (2017)

[Russakovsky 15] Russakovsky, O., et al.: ImageNet Large Scale Visual Recognition Challenge, *International Journal of Computer Vision (IJCV)*, Vol. 115, No. 3, pp. 211–252 (2015)

[Salimans 16] Salimans, T. and Kingma, D. P.: Weight Normalization: A Simple Reparameterization to Accelerate Training of Deep Neural Networks, *CoRR*, Vol. arXiv/1602.07868, (2016)

[Shi 16] Shi, W., et al.: Real-Time Single Image and Video Super-Resolution Using an Efficient Sub-Pixel Convolutional Neural Network, *CoRR*, arXiv/1609.05158, (2016)

[Simonyan 14] Simonyan, K. and Zisserman, A.: Very Deep Convolutional Networks for Large-Scale Image Recognition, *CoRR*, arXiv/1409.1556, (2014)

[ten] TensorFlow : `https://tensorflow.org/` Accessed: 2015-11-04

[Tolstikhin 18] Tolstikhin, I., et al.: Wasserstein Auto-Encoders, in *International Conference on Learning Representations* (2018)

[丹野 17] 丹野 良介, 下田 和, 柳井 啓司:複数スタイルの融合と部分的適用を可能とする Multi-style Feed-forward Network の提案, 人工知能学会全国大会予稿集 (2017)

[中田 18] 中田 秀基, 麻生 英樹 : Variational Autoencoder を用いた画像スタイル変換, 信学技報, vol. 117, no. 514, PRMU2017-192, pp. 121–126 (2018)

[2P4-J-2] Machine learning: industries and finance

Chair:Keisuke Otaki Reviewer:Junpei Komihyama

Wed. Jun 5, 2019 3:20 PM - 4:40 PM Room P (Front-left room of 1F Exhibition hall)

[2P4-J-2-01] Efficient estimation for red-zone in silicon wafers for solar cells using Level Set Estimation

○Shota Hozumi[1], Kota Matsui[2], Kentaro Kutsukake[2], Toru Ujihara[4], Ichiro Takeuchi[1,2,3] （1. Nagoya Institute of Technology, 2. RIKEN, 3. Center for Materials Research by Information Integration, National Institute for Materials Science, 4. Nagoya Universary）

3:20 PM - 3:40 PM

[2P4-J-2-02] Generating airfoil shape using conditional variational auto-encoder

○Kazuo Yonekura[1], Hitoshi Hattori[1], Takafumi Nishizu[1] （1. IHI Corporation）

3:40 PM - 4:00 PM

[2P4-J-2-03] Solar radiation prediction using RBF Network for Campus

○Yuta Hashiba[1], Shoichi Urano[1] （1. Meiji University）

4:00 PM - 4:20 PM

[2P4-J-2-04] A study of hybrid prediction model considering risk reduction for economic indicators forecasting

○Kodai Ogihara[1], Shoichi Urano[1] （1. Meiji University）

4:20 PM - 4:40 PM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

Level Set Estimationを用いた太陽電池用シリコンのレッドゾーンの効率的推定

Efficient estimation for red-zone in silicon wafers for solar cells using Level Set Estimation

穂積 祥太 *1 Shota Hozumi　松井 孝太 *2 Kota Matsui　沓掛 健太朗 *2 Kentaro Kutsukake　宇治原徹 *3*4*2 Toru Ujihara　竹内 一郎 *1*2*5 Ichiro Takeuchi

*1名古屋工業大学 情報工学専攻 Nagoya Institute of Technology
*2理化学研究所 革新知能統合研究センター RIKEN Center for Advanced Intelligence Project
*3名古屋大学 未来材料・システム研究所 Institute for Materials and Systems for Sustainability, Nagoya University
*4名古屋大学大学院 工学研究科 Department of Engineering, Graduate School of Nagoya University
*5物質・材料研究機構 情報統合型物質・材料研究拠点 Center for Materials Research by Information Integration, National Institute for Materials Science

For the task of estimating a spacial distribution of a physical quantity, it is common to fix the measurement positions to meshgrid points evenly allocated along the coordinates of the space. However, such fixed measurement positions often contain redundancy in the sense that not all the measurements in the meshgrid points are required for the target task. Especially when a measurement of the physical quantity is costly, it is thus beneficial to allocate the measurement points *adaptively* and reduce the number of measurements. In this study, we applied Level Set Estimation (LSE), which is a method to efficiently estimate the boundary position, to carrier lifetime mapping of silicon for solar cells, and estimated the low quality region. Our approach can reasonably estimate the boundary position by measuring less than 1% position compare to conventional approach.

1. 背景

太陽光電池の基板材料であるシリコンインゴッドの品質を測る尺度の 1 つとして，キャリアライフタイムの値がある．キャリアライフタイムは，光で励起されたキャリアが基底状態に戻るまでの時間であり，太陽電池の変換効率と正の相関がある [Sze & Ng 06]. 実際のインゴット製造では，材料のうちルツボに触れている外周部分は製造過程で不純物が入ってしまい，ライフタイムの値が低くなる．材料内でライフタイムの値が低い範囲は特に “レッドゾーン”と呼ばれ，この範囲が狭いほど，良い材料であるという 1 つの指標となっている [Ferrazza 02]. 通常, レッドゾーンの領域はインゴット表面で 1 点ずつライフタイムを測定し，その結果得られるライフタイムの分布から求められる [Hsieh et al. 14].

従来は，測定領域を格子状に区切り，各格子点上でライフタイムを測定することでレッドゾーンの広さを評価していた．しかし，材料内の 1 点のライフタイム値を測定するためには相応のコストがかかる．また，上述の測定方法ではレッドゾーンと無関係な領域にも大きな測定コストをかけてしまう可能性があり，非常に測定効率が悪い．したがって，少ない測定回数でレッドゾーンの広さを正確に推定する方法を開発することは重要な課題である．

本研究では，能動学習手法の 1 つであるレベルセット推定 (Level Set Estimation, LSE) [Gotovos 13] を用いてレッドゾーンの境界を推定する方法を提案する．提案法では, ライフタイム値の分布に対して統計モデルを仮定することでレッドゾーン境界に関する統計的推測を行い，これに基づいて次にライフタイム値を測定する点を適応的に選択する．太陽電池インゴッドのライフタイム値データを用いた実データ実験を通して，提案法が測定点数を劇的に減らすことができることを示す.

連絡先: 穂積祥太，名古屋工業大学大学院 竹内研究室所属，466-8555 愛知県名古屋市昭和区御器所町，hozumi.s.mllab.nit@gmail.com

2. 問題設定

あるブラックボックス関数 $f : \mathcal{X} \to \mathbb{R}$ と観測対象の候補点 $\{\boldsymbol{x}_i\}_{i=1}^N$ が与えられているとする．ここで, $\mathcal{X}$ は測定点の空間を表し, 測定値は実数値であるとする．また，入力 $\boldsymbol{x} \in \mathcal{X}$ に対する関数値 $f(\boldsymbol{x})$ の観測値 y は，誤差 $s \sim \mathcal{N}(0, \sigma^2)$ を伴って $y = f(\boldsymbol{x}) + s$ と表されるとする．本研究で考察するレベルセット推定 (Level Set Estimation，LSE)[Gotovos 13] は，ある閾値 $h \in \mathbb{R}$ に対して，

$$\boldsymbol{x}_i \in \{\boldsymbol{x} \in \mathcal{X} \mid f(\boldsymbol{x}) > h\} \quad \text{or} \quad \boldsymbol{x}_i \in \{\boldsymbol{x} \in \mathcal{X} \mid f(\boldsymbol{x}) \leq h\} \tag{1}$$

を判定する判別問題として定式化される．

特に，本研究で取り扱うレッドゾーン推定問題では，f として試料表面上の 2 次元座標を入力，その座標におけるライフタイムの値を出力とするような 2 入力 1 出力の関数を考える．通常の回帰分析の文脈では，入力 $\boldsymbol{x}$ と誤差を伴った出力 y の複数のペア $\{(\boldsymbol{x}_i, y_i)\}_{i=1}^n$ を学習データとして f を推定することで，新たな入力に対する判別を行うことができる．しかし，材料科学をはじめとする基礎科学分野では，入力 $\boldsymbol{x}$ に対する出力 y を観測するのに大きなコストがかかる場合が少なくなく，本研究で対象とするライフタイム値の測定も同様である．したがって，できるだけ少ない y の観測回数 (すなわち，少ないデータ数) で (1) の判別問題を解くことがしばしば要求される．

Algorithm 1 Level Set Estimation

Require: sample set D, GP prior$(m(\boldsymbol{x}) = a, k, \sigma_0)$
threshold ratio ω , accuracy parameter $\varepsilon = a/5$, max iteration T
Ensure: predicted sets $\hat{H}$, $\hat{L}$, U_t

$H_0, L_0, U_0, Z_0 \leftarrow \emptyset, C_0(\boldsymbol{x}) \leftarrow \mathbb{R}, t \leftarrow 1$
while $U_{t-1} \neq \phi$ and $t \leq T$ **do**
  $H_t \leftarrow H_{t-1}, L_t \leftarrow L_{t-1}, U_t \leftarrow U_{t-1}, Z_t \leftarrow Z_{t-1}$
  for all $\boldsymbol{x} \in D$ **do**
    $h_t^{opt} \leftarrow \omega \ \max_{\boldsymbol{x} \in Z_{t-1}} \max(Q_t(\boldsymbol{x}))$
    $f_t^{pes} \leftarrow \max_{\boldsymbol{x} \in Z_{t-1}} \min(Q_t(\boldsymbol{x}))$
    $h_t^{pes} \leftarrow \omega f^{pes}$
    if $\min(Q_t(\boldsymbol{x})) + \varepsilon \geq h_t^{opt}$ **then**
      $U_t \leftarrow U_t \backslash \{\boldsymbol{x}\}$
      if $\max(Q_t) < f_t^{pes}$ **then** $H_t \leftarrow H_t \cup \{\boldsymbol{x}\}$
        else $M_t^H \leftarrow M_t^H \cup \{\boldsymbol{x}\}$
    else if $\max(Q_t(\boldsymbol{x})) - \varepsilon \geq h_t^{pes}$ **then**
      $U_t \leftarrow U_t \backslash \{\boldsymbol{x}\}$
      if $\max(Q_t) < f_t^{pes}$ **then** $L_t \leftarrow L_t \cup \{\boldsymbol{x}\}$
        else $M_t^L \leftarrow M_t^L \cup \{\boldsymbol{x}\}$
    end if
  end for
  $Z_t \leftarrow U_t \cup M_t^H \cup M_t^L$
  $\boldsymbol{x} \leftarrow \arg\max_{\boldsymbol{x} \in Z_t}(w_t(\boldsymbol{x}))$
  $y_t \leftarrow f(\boldsymbol{x}) + n_t$
  Compute $\mu_t(\boldsymbol{x})$ and $\sigma_t(\boldsymbol{x})$, for all $\boldsymbol{x} \in D$
  $t \leftarrow t + 1$
end while
$\hat{H} \leftarrow H_{t-1} \cup M_{t-1}^H, \hat{L} \leftarrow L_{t-1} \cup M_{t-1}^L$

本研究では，f を, ブラックボックスかつ少データゆえの不確実性の下で適応的に推定するために統計モデルを導入し，モデルに基づいて得られる予測を用いて (1) を効率的に解くアプローチを提案する．

3. 提案手法

以下では，まずブラックボックス関数としての f の不確実性を考慮に入れたガウス過程によるモデリング [Rasmussen & Williams 06] を説明し，その後 (1) の判別問題のための提案アルゴリズムについて説明する．

3.1 ガウス過程によるモデリング

まず，ブラックボックス関数としての f の不確実性を考慮するため，f の統計モデルとしてガウス過程事前分布

$$f(\boldsymbol{x}) \sim GP(m(\boldsymbol{x}), k(\boldsymbol{x}, \boldsymbol{x}'))$$

を仮定する．ここで，$GP(m(\boldsymbol{x}, k(\boldsymbol{x}, \boldsymbol{x}')))$ は平均関数 m とカーネル関数 k で特徴付けられるガウス過程を表す．本研究では，k として Matern3/2 カーネル

$$k(\boldsymbol{x}_i, \boldsymbol{x}_j|\theta) = \beta_f^2(1 + \frac{\sqrt{3}r}{\beta_l}) \exp(-\frac{\sqrt{3}r}{\beta_l})$$

を用いる．ここで，$r = \sqrt{(\boldsymbol{x}_i - \boldsymbol{x}_j)^T(\boldsymbol{x}_i - \boldsymbol{x}_j)}$ とおいた．Matern カーネルは，ガウスカーネルと比較してより非滑らかな関数を表現しやすいという特徴を持つ．このとき，観測点 $\boldsymbol{x}_{1:n} = \{\boldsymbol{x}_1, ..., \boldsymbol{x}_n\}$ に対して，関数値ベクトル $\boldsymbol{f} = (f(\boldsymbol{x}_1), ..., f(\boldsymbol{x}_n))$ は，定義から n 変量の正規分布に従う

$$\boldsymbol{f}|x_{1:n} \sim \mathcal{N}(\boldsymbol{m}, \boldsymbol{K})$$

ここで，$\boldsymbol{m} = (m(\boldsymbol{x}_1, ..., m(\boldsymbol{x}_n)))$, $\boldsymbol{K}_{i,j} = k(\boldsymbol{x}_i, \boldsymbol{x}_j)$ である．以上より，データ $\mathcal{D}_n = \{(\boldsymbol{x}_i, y_i)\}_{i=1}^n$ が観測された下での新たな入力 $\boldsymbol{x}$ の観測値 $f(\boldsymbol{x})$ の予測分布は $\mathcal{N}(\mu_n(\boldsymbol{x}), \sigma_n^2(\boldsymbol{x}))$ と書ける．ただし，

$$\mu_n(\boldsymbol{x}) = m(\boldsymbol{x}) + \boldsymbol{k}(\boldsymbol{x})^T(\boldsymbol{K} + \sigma^2\boldsymbol{I})^{-1}(\boldsymbol{y} - \boldsymbol{m})$$
$$\sigma_n(\boldsymbol{x}) = k(\boldsymbol{x}, \boldsymbol{x}) + \boldsymbol{k}(\boldsymbol{x})^T(\boldsymbol{K} + \sigma^2\boldsymbol{I})^{-1}\boldsymbol{k}(\boldsymbol{x})$$

はそれぞれ予測平均と予測分散を表す．

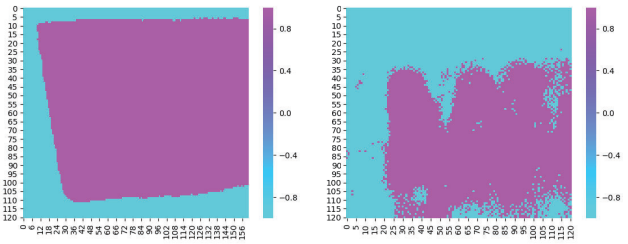


図 1: 左図:データ 1 のライフタイム値のプロット，右図:データ 2 のライフタイム値のプロット．青い領域がライフタイム値が低い低品質領域 (レッドゾーン) を表す．実験では，上図を正解とし，提案法がどの程度復元できたかを評価指標の 1 つとしている．

3.2 レベルセット推定 (LSE)

LSE では，前節のモデリングに基づいて confidence region

$$Q_n(\boldsymbol{x}) := [\ \mu_{n-1}(x) \pm \beta_t^{1/2}\sigma_{n-1}(\boldsymbol{x})\ ]$$

を構成し，閾値 h と $Q_n(\boldsymbol{x})$ の関係から $\boldsymbol{x}$ が h を超えるかどうかの判定を行う．具体的には，閾値に対するマージン ε を導入して, $\min(Q_n) + \varepsilon \geq h$ であれば上側領域, $\max(Q_n) - \varepsilon \geq h$ であれば下側領域であると判別する．ただし，実問題では h が未知であったり，一度どちらかの領域に判別された点でも，不確実性が大きい場合は後の反復で領域が反転したりするといった状況が起こりうるため，より詳細な判別基準を設ける必要がある．以上の考察に基づき，提案する LSE のアルゴリズムを Algorithm 1 に示す．

提案法では，未判定点の集合 U，$\boldsymbol{x}_i \in \{\boldsymbol{x} \in \mathcal{X} \mid f(\boldsymbol{x}) > h\}$ かつ不確実性が十分小さいと判定された点の集合 H，$\boldsymbol{x}_i \in \{\boldsymbol{x} \in \mathcal{X} \mid f(\boldsymbol{x}) > h\}$ かつ不確実性が大きいと判定された点の集合 M^H，$\boldsymbol{x}_i \in \{\boldsymbol{x} \in \mathcal{X} \mid f(\boldsymbol{x}) \leq h\}$ かつ不確実性が十分小さいと判定された点の集合 L，$\boldsymbol{x}_i \in \{\boldsymbol{x} \in \mathcal{X} \mid f(\boldsymbol{x}) \leq h\}$ かつ不確実性が大きいと判定された点の集合 M^L の 5 つの集合を繰り返し更新し，全ての観測候補点が H または L に振り分けられた時点で終了する．

提案法では，最も不確実性の高い点で次の関数値を測定する (uncertainty sampling) アプローチを採用する．これは，獲得関数

$$w_t(\boldsymbol{x}) = \max(Q_t(\boldsymbol{x})) - \min(Q_t(\boldsymbol{x}))$$
$$= 2\beta_n^{1/2}\sigma_{n-1}(\boldsymbol{x})$$

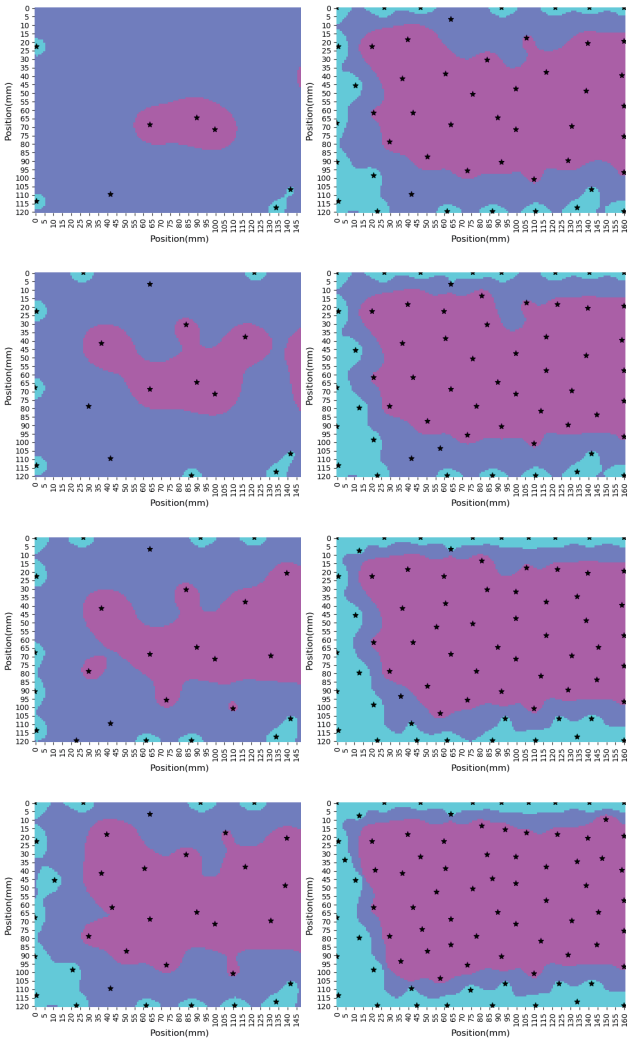


図 2: データ 1 に対する提案法の挙動．左上段から左下段に向けて，獲得点数が 10，20，30，40 時点，右上段から右下段に向けて，獲得点数が 50，60，70，80 時点の推定レッドゾーン (水色領域) を表し．濃青領域は，不確実性が残っていることを表す．また，黒点はライフタイムの観測を行った座標を示す．

の最大値を与える点として特徴付けられる．アルゴリズムの各ステップで，この基準で選ばれた $\boldsymbol{x}$ に対して y の値を観測し，ガウス過程を更新する．

4. 計算機実験

4.1 実験設定

本研究では，太陽電池インゴッドのライフタイム値を測定した 2 種類のデータを解析した．データ 1 については試料表面の 2 次元平面上に格子点を 19481 点，データ 2 については 14641 点とり，その上でライフタイム値の測定を実施したものである．計算機実験では，レッドゾーンの閾値をライフタイム値の最大値の 15 %値と定め，これを下回る範囲をレッドゾーンと定義する．図 1 にそれぞれのデータにおけるライフタイム分布のプロットを示す．図の青い領域が真のレッドゾーンを表している．本実験ではライフタイムを評価する点の数の最大値を 100 に固定し，アルゴリズムが停止した時点で推定されたレッドゾーンを F 値及び可視化によって評価した．

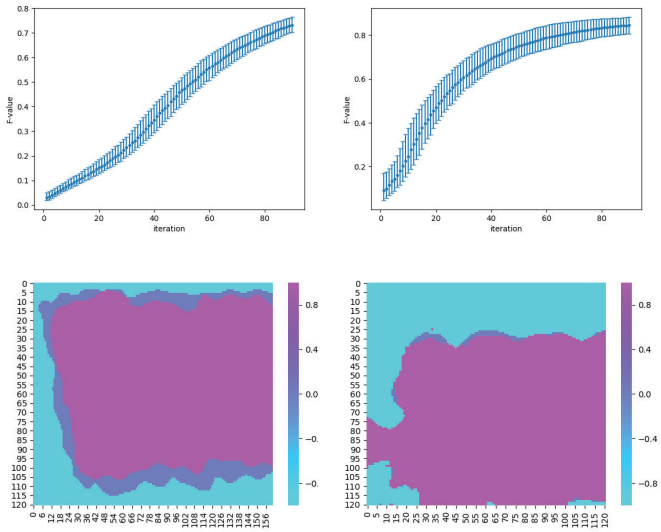


図 3: 上段:F 値のプロット，下段:推定されたレッドゾーンの可視化 (水色領域)．左側がデータ 1，右側がデータ 2 の結果をそれぞれ示す．

ガウス過程に基づく LSE では，観測誤差の分散 σ^2 をデータから推定するとともに，次の 5 種類のハイパーパラメータを設定する必要がある:

1. カーネル関数の分散 β_f
2. カーネル関数の長さスケール β_l
3. ガウス過程の平均関数 $m(\boldsymbol{x})$
4. LSE における分類マージン ε
5. confidence region Q_n で平均と標準偏差のバランスを制御するパラメータ β_t.

文献 [Gotovos 13] では，ライフタイム値の取りうる範囲を被覆するように取ったデータの一部をを用いて，対数尤度最大化に基づいてパラメータの設定を行っている．しかし，実際の実験ではライフタイム値の取りうる範囲が未知であるため，この方法でパラメータを調整しておくことが難しい．本研究では，経験的な知見から $\sigma = 0.001, \beta_l = 25, \beta_t = 1.96$ と設定した．他のパラメータ設定は，まず一様ランダムに 10 点のライフタイム値を測定し，その中央値の半分の値を a とおき，$\beta_f^2 \in [25a, 100a], m(x) = a, \varepsilon = a/5$ とするヒューリスティクスを用いた．特に β_f に関しては，各反復で 1 点のライフタイムを測定する毎に上記の範囲内で対数尤度最大化に基づいて適切な値を設定した．

4.2 実験結果

計算機実験は 1000 回の試行を行い，平均的な振る舞いを観察した．まず，データ 1 に対する提案法の挙動を図 2 に示す．探索初期では大部分が濃青の不確実な領域を占めているが，探索が進むにつれて不確実性が減少していき，徐々にレッドゾーンが推定されていっていることが見てとれる．また，実際にライフタイム値を観測する点も適応的に選択されており，格子点上を全探索する従来のアプローチに比べて探索が効率的になっ

ていることがわかる．次に，データ 1 及びデータ 2 に対する結果をそれぞれ図 4. に示す．図 4. 上段の F 値のグラフは中央値を中心にエラーバーの上限は第一四分位数，下限は第三四分位数として描画した．F 値は，データ 1 で 0.7325，データ 2 で 0.8458 程度を達成した．また，推定されたレッドゾーンを可視化した図 4. の下段と真のレッドゾーンを示した図 1 及び図 4. の下段を比較すると，最大 100 点の測定で比較的外形が良く推定できていることがわかる．ここで，図 4. 下段の濃青の領域は，境界周辺の不確実性がまだ残っていることを表している．真のレッドゾーンを同定するために測定したデータ点数に対しては，データ 1 で 0.5%（100/19481），データ 2 で 0.6%（100/14641）の測定点数で上記の推定結果を得ることができた．探索コストを大幅に削減できていることがわかる．

5. まとめ

本研究では, 太陽電池インゴッドの品質管理において, ライフタイム値の低い低品質領域 (レッドゾーン) を推定するために, レベルセット推定に基づく能動学習を提案した．レベルセット推定は, ライフタイムをブラックボックス関数としてガウス過程でモデリングすることで, レッドゾーンの推定とデータの測定を適応的に行うことができるため, 探索効率の改善が期待できる．計算機実験によって, レッドゾーンを正確に同定できる一方で探索コストの非常に高い格子点上測定に対して, 提案法では非常に少ない探索コストでレッドゾーンの概形を推定することができた．本研究における課題として, レベルセット推定は欠損値を含むデータには適用できない, という点が挙げられる．今回の実験では, データに対して専門家の知識を利用した欠損値処理などの前処理が多数行われているが, 実際の実験でリアルタイムにレベルセット推定を行う場合, これらの前処理を同時に実施することは難しい．今後は, 欠損値を含むデータに対して適用できるようにレベルセット推定アルゴリズムを拡張し, リアルタイムの実験に適用したい．

参考文献

[Ferrazza 02] Ferrazza, F. (2002). Large size multicrystalline silicon ingots. Solar energy materials and solar cells, 72(1-4), 77-81.

[Gotovos 13] Gotovos, A., Casati, N., Hitz, G., & Krause, A. (2013). Active learning for level set estimation. In IJCAI (pp. 1344-1350).

[Hsieh et al. 14] Hsieh, C. C., Lan, A., Hsu, C., & Lan, C. W. (2014). Improvement of multi-crystalline silicon ingot growth by using diffusion barriers. Journal of Crystal Growth, 401, 727-731.

[Rasmussen & Williams 06] Rasmussen, C. E., & Williams, C. K. (2006). Gaussian process for machine learning. MIT press.

[Sze & Ng 06] Sze, S. M., & Ng, K. K. (2006). Physics of semiconductor devices. John wiley & sons.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

Conditional variational auto-encoderを用いた翼形状生成

Generating airfoil shape using conditional variational auto-encoder

米倉一男 *1　服部均 *1　西津卓史 *1
Kazuo Yonekura　Hitoshi Hattori　Takafumi Nishizu

*1株式会社ＩＨＩ
IHI Corporation

We train an inference model for airfoil shape in application of mechanical design. It is important to obtain a reasonable shape that shows a specific performance that designers need. We use conditional variational auto-encoder to train inference model. We use NACA airfoil to evaluate the proposed method, and show the method outputs reasonable shapes. However, when we use naive discretization method of shapes, generated shape involves small perturbation which leads self-intersection. Since such perturbation is not desired in view of mechanical desing, we use Gaussian process to smooth the shape.

1. はじめに

航空用エンジンや車両用過給機などをはじめとする機械の設計では，要求仕様を満足したうえでなるべく性能の良い形状を見つけ出すことが重要である．さらに，コスト削減のために，設計にかかる時間をなるべく短縮することが求められる．また機械設計ではそれまでの設計実績や文献等を参考にして行われることがあるため，その場合においても，設計時間の短縮が求められる．

機械設計では設計実績や検討段階の形状および性能値の情報が蓄積されている．[Yonekura 2014] は，形状を複数集めて主成分分析を用いて分析することで形状の特徴量を抽出して形状最適化を行う手法を構築した．[Nita 2014] はその手法を文献で公開された多くの形状を集めて適用することで，高性能なタービン翼の冷却孔を創出した．しかしこの手法は特徴量を抽出するだけで性能値を指定して形状を創出することはできないという特徴があったため，短時間で所望の性能の形状を見つけ出すことが難しかった。

主成分分析と同様に特徴量抽出を行う手法の一つとして，auto-encoder (AE) や variational auto-encoder (VAE) [Kingma 2015] などがある．これらはニューラルネットワークを利用してデータの特徴量抽出と再構成に使用される．例えば文献 [佐藤 2018] では VAE を材料の欠陥判定に用いている．VAE にラベルを処理するノードを付加して，条件付きの特徴量抽出を行う手法が conditional VAE (CVAE) [Sohn 2014] である．本報告では CVAE を用いて前述の課題を解決し，指定した性能の翼を生成する手法を提案する．CVAE を用いれば短時間で所望の性能の翼が得られ，設計作業が行いやすくなる．さらに性能値と関係づけた特徴抽出ができるため，物理現象に対するより深い洞察を得られることが期待される．本稿では翼形状を用いて数値実験を行い，提案した CVAE の有効性を検証する．

2. 形状生成手法

本稿では形状を点列を用いて表現する．したがって曲線を折れ線近似することになる．機械設計における性能計算で広く使用される CFD（Computational Fluid Dynamics）計算では，形状に沿うように計算格子を設定して微分方程式を数値的に解く．このとき，形状は計算格子に沿った線分で近似されるため，形状を線分の集合として表現すること自体には問題はない．しかし一方で，線分の集合はジグザグになったり交差する可能性がある．これは前述の数値計算の観点からも許容できず，滑らかな線分近似になる必要がある．

本稿では扱う形状は二次元形状とし，二通りの方法で点列を扱う．一つ目は図 1 に示すように，等間隔の X 座標に対する Y 座標を変数とする方法である．これは [Yonekura 2014] と同じ手法である．これを手法 A と呼ぶ．手法 A を用いれば線分同士の交差が発生しにくいという特徴があるが，X 方向の軸長さが一定である必要があり，使用できる形状が限定される．二つ目は形状を任意の方法で離散化し，その X，Y 座標を変数とする方法である．これを手法 B と呼ぶ．この方法では線分同士の交差が起こりやすくなるが，任意の形状を扱えるため自由度が高い．

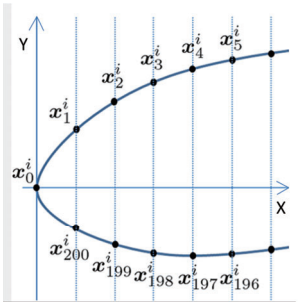
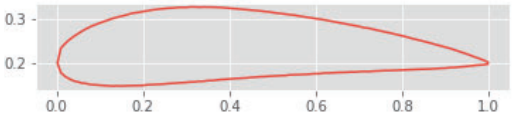


図 1: 形状の離散化手法 A [Yonekura 2014].

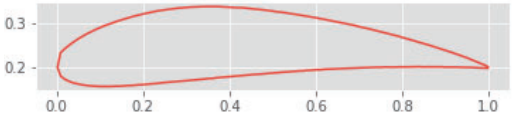
3. 数値実験

本章では，二次元層流翼形である NACA 翼 [Abbott 1949] を用いた形状生成を行う．機械学習ライブラリとして Chainer [Tokui 2015] を使用した．NACA 翼は NACA が体系的に調査した翼のデータベースで，パラメータを指定すれば一意に翼形状が定まる．今回は 4 桁系列と呼ばれる翼を対象とし，ラベルとして揚力係数（CL; Lift Coefficient）を用いる．あらかじめ

連絡先: 米倉一男，株式会社ＩＨＩ，神奈川県横浜市磯子区新中原町１，kazuo_yonekura@ihi.co.jp



(a) 指定値 1.0，再計算値 0.9860.



(b) 指定値 1.2，再計算値 1.2237.

図 2: 手法 A で生成した形状の例

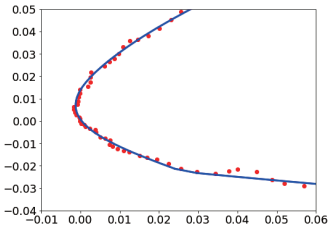


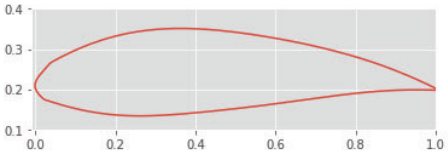
図 3: 手法 B で生成した形状とその平滑化の例.

手法 A は 189 個，手法 B は 4560 個の形状を作成して揚力係数を計算し，それぞれ CVAE で学習した．ただし揚力係数は正規化した．手法 A を用いて生成した形状を図 2 に示す．CL を指定して点列を生成し，その点列を用いて再度 CFD 計算によって揚力係数を計算した．手法 B を用いた場合，生成された点列がいびつな形をしているため，ガウス過程を用いて平滑化した．図 3 に点列と平滑化された曲線を示す．ただし座標は翼弦長を単位長さとしている．いびつな形をしている理由は，収束の過程における残差が残っているためと考えられる．点列と平滑曲線との距離は翼長さに対して約 0.5% 程度と小さいが，このようにいびつな点列では CFD 計算ができない場合がある．平滑な曲線を用いて揚力係数を再計算した結果を図 4 に示す．滑らかな翼形状が得られ，指定値に近い性能値が得られた．

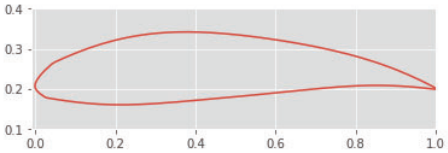
最後に，指定した性能値に対する実際の性能値を比較する．揚力係数を 0.8 から 1.2 まで 0.05 刻みで変更して手法 A，B それぞれで形状を生成し，再度性能値を計算した．その性能値の平均相対誤差を表 1 に示す．手法 A と B のどちらも 2.3% 以下の誤差で大きな差は無く，離散化手法による差は小さいと考えられる．ただし，手法 A では例えば翼長さが一定でなければならないなどの制限があり，一般的な形状に対して使用できる手法ではない．

4. 結論

本稿では CVAE を用いた翼形状生成手法を提案した．本手法を用いることで，指定した性能の形状を短時間に得ることができる．NACA 翼を使用した数値実験では，生成した形状の性能値の誤差は 3% 以内と小さく，本手法は有効であると考えられる．しかし形状の離散化手法によっては形状に凹凸があったり線分同士が交差して形状として成立しない場合があるため，後処理として滑らかにすることが必要である．



(a) 指定値 1.0，再計算値 1.0152.



(b) 指定値 1.2，再計算値 1.2028.

図 4: 手法 B で生成した形状の例

表 1: 指定値との平均相対誤差.

	手法 A	手法 B
平均相対誤差	2.16%	2.25%

参考文献

[Yonekura 2014] Yonekura, K. and Watanabe, O.: A Shape Parameterization Method Using Principal Component Analysis in Applications to Parametric Shape Optimization, Journal of Mechanical Design, Vol. 136 (12), 121401, (2014).

[Nita 2014] Nita, K., Okita, Y., Nakamata, C., Kubo, S., Yonekura, K., and Watanabe, O.: Film Cooling Hole Shape Optimization Using Proper Orthogonal Decomposition, ASME Turbo Expo 2014, GT2014-27239, (2014).

[Kingma 2015] Kingma, D.P., Rezende, D.J., Mohamed, S., Welling, M.:Semi-supervised learning with deep generative models, Advances in Neural Information Processing Systems 27, pp. 3581–3589, (2014).

[Sohn 2014] Sohn, K., Lee, H., and Yan, X.: Learning Structured Output Representation using Deep Conditional Generative Models, Advances in Neural Information Processing Systems 28, pp. 3483–3491, (2015).

[佐藤 2018] 佐藤玄, 前田宗彦, 鈴木一将, 大島誉寿, 内田雄太, 米倉一男: 形状特徴項を用いた VAE の復元性能の向上, 第 21 回情報論的学習理論ワークショップ, D1-36, (2018).

[Abbott 1949] Abbott, I.H. and Von Doenhoff, A.E.: Theory of Wing Sections Including a Summary of Airfoil Data, Dover, (1949).

[Tokui 2015] Tokui, S., Oono, K., Hido, S. and Clayton, J., Chainer: a Next-Generation Open Source Framework for Deep Learning, Proceedings of Workshop on Machine Learning Systems(LearningSys) in The Twenty-ninth Annual Conference on Neural Information Processing Systems (NIPS), (2015) .

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

RBF ネットワークを用いたキャンパスにおける日射量予測

Solar radiation prediction using RBF Network for Campus

羽柴 雄太[*1]　　浦野 昌一[*1]
Yuta Hashiba　　Shoichi Urano

[*1] 明治大学
Meiji University

In this paper, we propose a prediction method with fewer kinds of data using RBF network for solar radiation prediction on campus. In recent years, the introduction of renewable energy has advanced in Japan, among which the introduction of photovoltaic power generation system is the top. Therefore, for optimal power operation such as small area, it is necessary to predict the amount of solar radiation that affects PV output. We will develop and verify a model that can predict solar radiation amount with high accuracy from past solar radiation performance data in small area. We report the result that we can predict if there is a tendency similar to the past in the prediction model used this time even without weather information, and report that there is a possibility of further improvement in accuracy by adding cloud amount data.

1. はじめに

近年環境問題とともに再生可能エネルギーに注目が集まる中，国内では太陽光発電（Photovoltaic：以下 PV）の導入が最も進んでいる．大規模発電施設以外にも各家庭や事業所単位での導入は現在一般的となっている．ただ太陽光発電には発電量が天候に大きく左右されてしまうといった不安定性があり，大規模導入時には火力発電機の稼働台数にも影響を及ぼす．導入が増えるにつれ系統安定化を図るためにはより精度の高い太陽光発電量予測が必要となってくる．PV の出力は日射量に大きく依存するため太陽光発電量予測は日射量予測と捉えることができる．また，近年ではスマートコミュニティなどの小規模エリアにおける電力の地産地消なども実施されている．そのため需給運用に関する計画や制御を的確に行うためにはコミュニティ単位での予測も重要となってくる．それに加え，2016 年 4 月 1 日の電力の全面自由化により，新電力の小売業への参入が始まり，全ての消費者が電力会社を自由に選択できるようになり電力売買が活発化している．そのため経済的な観点からも効率的な需給運用が必要となる．

2. 日射量の予測

日射量とは，一定の期間に降り注がれる太陽からの光エネルギーである．従来から天気予報・気象衛星データ・衛星画像データなどを用いたいくつかの手法がすでに研究されている．ただ 1 日に発電される電力の総量には大きな変動があり，天候によっては 0kWh になってしまうこともある．こういった観点からその他の再生可能エネルギーの発電量予測や電力需要予測などの予測と比べると不安定な要素が大きい[羽柴 18]．図 1 に明治大学駿河台キャンパスで計測した日射量波形を示す．波形の急降下等から変動が激しいことが分かる．

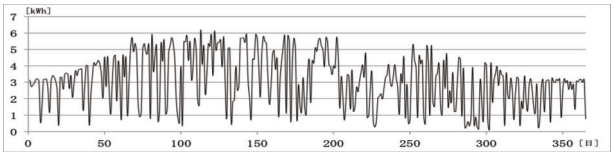


図 1. 明治大学駿河台キャンパス日射量

連絡先：羽柴雄太，明治大学大学院先端数理科学研究科，
cs183018@meiji.ac.jp

3. 日射量予測モデルの構築

本稿では，日射量予測モデルに用いるデータは，日射量の実績値と気象データから得られる雲量の実測値を用いる．予測モデルとしてはニューラルネットワークの一種である動径基底関数（Radial Basis Function：以下 RBF）ネットワークを用いる．

3.1 クラスタリング

RBF ネットワークの予測モデル構築の際，中間層に用いられる重心ベクトルの決定についてクラスタリングに k-means 法を用いる．k-means 法は対象のクラスタの分類と代表ベクトルの再計算を交互に繰り返し行う．この手法は，(1)式の評価関数 ϕ を最小化するクラスタ中心を見つけることによって，データ X を任意の k 個のクラスタに分割する．

$$\phi = \sum_{x_j \in \mathbf{X}} \min_{i \in k} \left\| x_j - c_i \right\|^2 \tag{1}$$

但し　x_j：入力データ（j∈1…N）
　　c_i：各クラスタの中心ベクトル

3.2 RBF ネットワーク

RBF ネットワークとは重み付き線形和を用いたニューラルネットワークの手法の一種であり，有限個である入出力データを補完する手法である．基本的な階層型ニューラルネットワークのニューロンの出力関数にシグモイド関数が多く使われるのに対し，RBF ネットワークではガウス関数を用いる．図 2 に示すように入力層，中間層，出力層の 3 層構造となっており，多層パーセプトロンと同じく任意の非線形関数の近似が可能である[森　02]．RBF ネットワークの中間層のガウス関数は(2)式で表現される．

$$h_i(x) = \exp\left(-\frac{\left| \mathbf{x} - \mu_i \right|^2}{2\sigma_i^2} \right) \tag{2}$$

但し　x：入力データベクトル　μ_i：重心のベクトル
　　σ_i^2：各クラスタ内の分散

本稿では，中間層と出力層間の重みは勾配法により学習を行う．出力層の出力を以下の(3)式に示す

$$y = \sum_{i=1}^{M} w_i h_i(\mathbf{x}) \tag{3}$$

但し x:入力データベクトル h_i:中間層の出力
w_i:中間層と出力層の結合重み

本稿で用いる RBF ネットワークの中間層のユニット数は，3.1 で示したクラスタリングによって決定する．σ^2 で表す基底関数の幅は，各クラスタの分散を用いてチューニングすることで決定する．

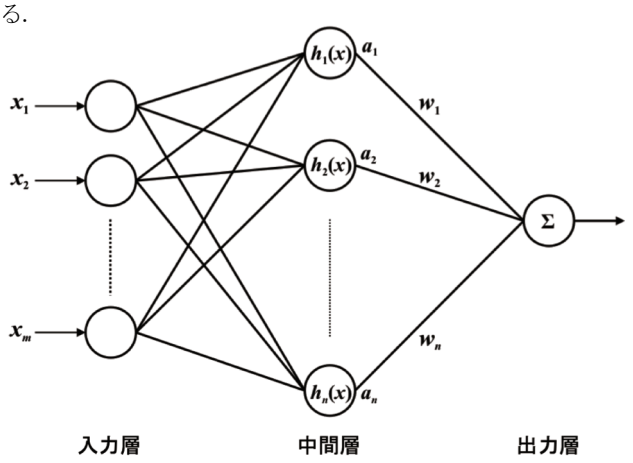


図 2 RBF ネットワークの構造

4. シミュレーション

本稿では日射量予測の対象として明治大学駿河台キャンパスの日射量を予測し，実測値と比べ精度を検証していく．

(1) シミュレーション条件

予測に用いるデータは，明治大学駿河台キャンパスにおける太陽光発電システムの日射量実績データと気象庁が公開するエリアごとの雲量実績データである[気象 18]．日射量実測データは 24 時間分の合計として 1 日の総量を用いた．雲量データは，本来は予測時の予報値を用いるが，今回は長期間のデータセット作成のため現在入手可能である実測値を用いる．実績値は気象庁が公開する実績値のうち日射量の観測地点から最も近い東京地点のデータを用いた．データの期間は，2016 年 1 月 1 日から 2017 年 12 月 31 日の 2 年間を使用した．RBF ネットワークのパラメータを以下に示す．

<RBF ネットワーク>
入力変数:4
中間層のユニット数:6(クラスタリングにより最適化)
学習回数:5000
重み修正幅:0.1

またシミュレーションのフローを図 3 に示す．まず日射量実測データからクラスタリングを行う．これは過去の似た傾向から未来の予測を行うための特徴量を分類することを目的とする．またクラスタリングの結果から得られた最適なクラスタ数から RBF ネットワークの中間層のユニット数と代表ベクトルが決定される．その後構築された RBF ネットワークに過去 1 年間分の学習データを与えることでパラメータを学習させる．最終的には予測値と実測値を比較し評価を行っていく．

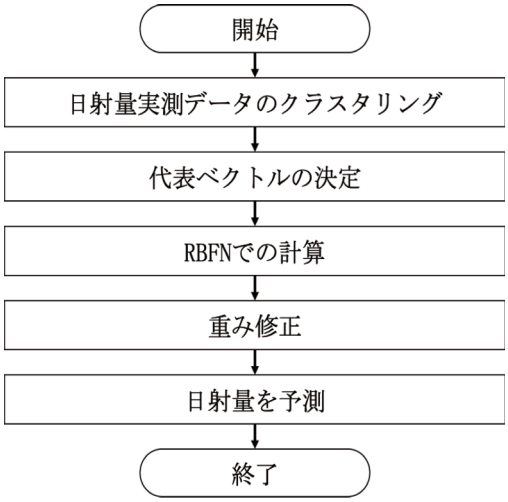


図 3 フローチャート

(2) シミュレーション結果

表1にシミュレーション結果の一例を示す．これは日射量実績データのみを用いて，ある 7 日間の予測を行った．7 日間の予測結果から，誤差率が高い日と低い日が混在していることが分かる．誤差率の高い日は，過去の傾向からでは捉えきれない当日の突発的な天候などが影響していると考えられ，雲量データなどの気象データの重要性が示唆された．また，今回の予測モデルでは入力データの特徴によって過去に同じ傾向が多いものは，予測精度が良いが過去に似た傾向が少ないと予測結果に反映されにくく誤差率が大きくなることが確認された．以上より，日射量予測においては，日射量データと雲量データを組み合わせることで予測精度向上を可能とすることから，引く続きシミュレーションを通して検証を行なっていく．

表 1 実測値と予測値の比較

	1日目	2日目	3日目	4日目	5日目	6日目	7日目	平均
実測値(kWh)	3.09	3.52	3.96	2.80	3.72	3.44	3.39	
予測値(kWh)	3.20	2.80	3.36	3.00	4.20	3.74	2.79	
誤差率(%)	3.56	20.45	15.15	7.14	12.90	8.72	17.70	12.23

5. まとめ

本稿では，RBF ネットワークに対して過去の日射量実績データと雲量データによる日射量予測を提案した．シミュレーション結果例から限られたデータセットを用いることでも，ある程度の予測精度が確保できることを確認した．今後はさらなる予測精度の向上のための検証を行なっていく．また，本稿で用いた予測モデルを他の小規模エリアの日射量予測に適用することで汎用性や予測精度の確認を行なっていく．

参考文献

[森 02] 森啓之·青山光·山中俊幸·浦野昌一: DA 前処理付き大域的構造を持つ RBFN の電力系統事故検出への応用，電学論 B, 122, 12, pp. 1355-1366 , 2002.

[気象 18] 気象庁・過去の気象データ(雲量データ:東京地点)(https://www.jma.go.jp/jma/index.html)

[羽柴 18] 羽柴雄太・浦野昌一: ARIMA モデルと RBF ネットワークを用いた電力需要予測の検討，電力技術/電力系統技術合同研究会，No.PE-18-171 PSE-18-147 , 2018.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

リスク低減を考慮した経済指標予測のための Hybrid 予測モデルの検討

A study of hybrid prediction model considering risk reduction for economic indicators forecasting

荻原 航大[*1]
Koudai Ogihara

浦野 昌一[*1]
Shoichi Urano

[*1] 明治大学
Meiji University

In this paper, we have proposed the hybrid prediction model considering risk reduction for economic indicators forecasting. The proposed hybrid prediction model consists of multiple regression model and artificial neural network. We apply the proposed hybrid prediction model to Nikkei 225 futures price. Based on the simulation results, we report the result that it is possible to avoid risk by suppressing the maximum prediction error rate and standard deviation while keeping prediction accuracy in the proposed hybrid prediction model with Nikkei 225 futures price.

1. はじめに

昨今，世界情勢は大きく変動している．世界各国の政策や国家間の関係などが複雑に絡み合い，世界規模での不安定な経済状況となっている．このような情勢の中では，規模の大きさに関わらず企業の中長期的な経営戦略の決定や，強いては個人単位でもリスクマネジメントが必要となってくる．そのためにも，経済状況を把握し，予測を立て，経済の動向を追っていくことが必要である．そこで本稿では，経済動向の分析のための経済指標予測に対して精度の向上，及び，リスク低減を目指す．

筆者等は先行研究[荻原 18]において，重回帰モデルと Artificial Neural Network（以下 ANN）を組み合わせて新たな予測値を算出する Hybrid 予測モデルを構築し，リスク低減を目的として，翌日最大電力需要予測に適用してきた．そこで本稿では，経済指標予測におけるテクニカル分析に役立てるため，これまで構築してきた Hybrid 予測モデルを適用し，リスク低減を考慮した経済指標予測モデルを提案する．シミュレーションより，予測対象を日経 225 先物価格とした Hybrid 予測モデルでは，予測精度を確保しつつ，最大予測誤差率と標準偏差を抑制し，リスク回避を可能とする結果を得たので報告する．

2. 経済指標予測

経済指標予測とは，各国の公的機関等が発表する，経済状況を構成する要因を数値化した指標を用いており，経済の現状や過去からの変化を正確に把握するために必要である．将来の経済状況の方向性を推し量る為に必要な分析方法には大きく分類して，テクニカル分析とファンダメンタル分析が挙げられ，様々な研究がなされている[田村 18]．本稿では，テクニカル分析に役立てるための経済指標予測モデルを提案する．

2.1 日経 225 先物価格

本稿では，日経 225 先物価格を予測対象として扱う．日経 225 先物価格とは，日本経済新聞社により算出，公表されている日経平均株価を原資産とする株価指数先物取引の価格であり，日本経済の状態を表す TOPIX と並ぶ重要な株価指数として知られている．

連絡先：荻原航大，明治大学大学院先端数理科学研究科
cs183008@meiji.ac.jp

3. 予測手法

3.1 重回帰モデル

回帰モデルとは，被説明変数を説明変数で表現するものである．被説明変数 y を一つの説明変数 x で表現するものが単回帰モデルであり，単回帰モデルを拡張し，複数の説明変数 $x_{\{i\}}$（i=1，2，3，・・・，n）で表現するものが重回帰モデルである．

また，回帰係数(β_0，β_1，…，β_n)は最小 2 乗法で決定され，重回帰モデルの回帰式は(1)式で表現される．

$$y = \beta_0+\beta_1x_1+\beta_2x_2+\beta_3x_3+\cdots+\beta_nx_n \quad (1)$$

3.2 ニューラルネットワーク

機械学習の一つである ANN は，人間の脳の基本構成要素である，神経細胞（ニューロン）同士の繋がり，つまり神経回路網を人工ニューロンという情報処理のための数式で表現したものである．階層型の ANN は，入力層，中間層，出力層からなり，各層は適当な数のニューロンから構成される．また，各層間は接続するニューロン同士の繋がりの強さを示す結合強度である重みが配置される．一般的に階層型 ANN の学習で用いられる手法は誤差逆伝播学習法である．

3.3 提案法

筆者等は，先行研究で電力系統における翌日最大電力需要予測へ重回帰モデルと ANN を並列に組み合わせた Hybrid 予測モデルを提案した．本稿では，提案モデルを，日経 225 先物価格の一日の高値の予測へと適用する．

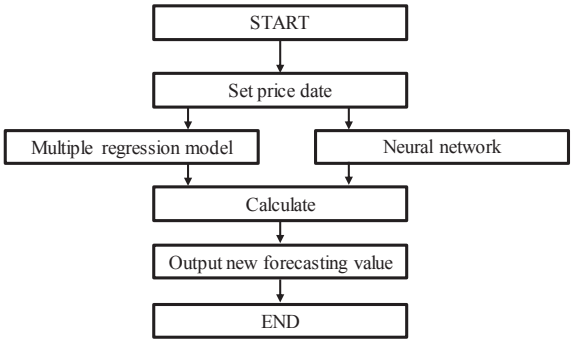


図 1　提案法のフロー

提案法のフローを図 1 に示す. また, 提案法の手順を以下に示す.

（1）重回帰モデルと ANN により同じ時点の予測値を複数のモデル化期間で算出

（2）算出した複数の予測値から値の近い予測値を指定個選択

（3）選択した指定個の予測値の平均値にて新しい予測値を算出

尚, 本稿では, 重回帰モデルの回帰式を決定するモデル化期間とANNの結合重み, 閾値を学習する学習期間をモデル化期間と総称する.

本稿では, 重回帰モデルと ANN に対してモデル化期間としてそれぞれ同じ 13 期間を適用し, 計 26 個の予測値を算出する. その 26 個の予測値から, いくつか値の近い予測値を抜き出し, 平均化することで算出した値を新たな予測値とする. 今回は, 3 個以上の予測値を抜き出すこととした.

提案する Hybrid 予測モデルにより, 最大予測誤差率, 標準偏差の抑制によりリスク回避及び, 予測精度の向上を目指す.

4. シミュレーション

4.1 シミュレーション条件

本稿では, 公開されている過去の日経 225 先物価格のデータのみを使用し, その他の指標を用いず, 予測を行うこととする. 今回は, 一日を午前 9:00～翌午前 5:00 と設定する. 始値は午前 9:00 の価格, 終値は翌午前 5:00 の価格, 高値は一日の中での最も高い価格, 安値は一日の中で最も安い価格, 出来高は一日での取引への参入量である.

(1) モデル化期間の設定

本稿では, 営業日のみを用いて予測を行うものとする. そこで, 一週間を 5 日, 一ヶ月を 20 日として, モデル化期間を以下に示す 13 期間に設定した.

10 日, 20 日, 40 日, 60 日, 80 日, 100 日, 120 日
140 日, 160 日, 180 日, 200 日, 220 日, 240 日

なお, モデル化期間を 240 日までとしたのは, 一週間を 5 日と考えるとモデル化期間での一年（240 日）を誤差改善の区切りとみなしたためである.

シミュレーションには, 2016 年 1 月 4 日から 2018 年 12 月 28 日までの公開されている日経 225 先物価格のデータを使用した.

(2) 説明変数, 入力変数の設定

筆者等は先行研究[荻原 18]での経済指標において, 重回帰モデルにおける説明変数, ANN における入力変数である入力要素として始値, 高値, 安値, 終値, 出来高の 5 つを用いることで有効な結果を得たので, 本稿においてもこの 5 つの入力要素を採用することとする.

重回帰モデルの説明変数, ANNの入力変数と中間層のユニット数, 学習回数を以下に示す.

<重回帰モデル>　説明変数：5

<ANN>　入力変数：5
中間層のユニット数：5
学習回数:10000

(3) 予測検証期間, 予測対象値の設定

今回のシミュレーションでは, 日経 225 先物取引の 2018 年営業日一年間を検証期間とし, 一日の高値を予測対象値とする. 予測は逐次予測とする.

4.2 提案法による予測

重回帰モデル, ANN それぞれに対して設定したモデル化期間により算出した計 26 個の予測値に提案法を適用し, 2018 年の日経 225 先物取引営業日一年間の一日の高値予測の結果を表 1 に示す.

本稿では, リスク低減を目指す観点から, 最大予測誤差率に着目する. 表 1 には, 提案法, 重回帰モデル単独, ANN 単独における最大予測誤差率の最良の結果を示す. 提案法は, 計 26 個の予測値から 12 個の予測値を選択し新たな予測値を算出した値であり, 重回帰モデルはモデル化期間 160 日, ANNはモデル化期間 200 日を適用し算出した値となっている. それぞれ平均予測誤差率, 最大予測誤差率, 最小予測誤差率, 標準偏差を示す.

表 1 より, 平均予測誤差率では重回帰モデルが 0. 55162%で最良の結果となっているが, 最大予測誤差率, 標準偏差では提案法がそれぞれ 3. 24710%, 0. 52846 となっており, 最良の結果となっていることが分かる. シミュレーション結果より, 提案法による予測は重回帰モデル, ANN それぞれ単独による予測に比べて, 予測精度を確保しながら, 最大予測誤差率と標準偏差を抑制しリスク回避を可能としていることが分かる.

表 1　提案法による予測結果

	提案法	重回帰モデル	ANN
平均予測誤差率(%)	0.57304	0.55162	0.61871
最大予測誤差率(%)	3.24710	3.27940	3.87510
最小予測誤差率(%)	0.00083	0.00036	0.00129
標準偏差	0.52846	0.52882	0.55751

5. まとめ

本稿で得られた結果は以下の通りである.

＜1＞複数のモデル化期間を用いて重回帰モデルと ANN により複数の予測値を算出し, それらの予測値からいくつかの予測値を選択し平均化することで新たな予測値を算出する, 重回帰モデルと ANN を並列的に組み合わせた Hybrid 予測モデルを日経 225 先物価格に適用した.

＜2＞シミュレーションにより, 提案法では予測精度を確保しつつ, リスク回避を可能とする結果を得たことから, 提案法の有効性を確認した.

＜3＞今後は, 入力要素の検討や, 提案法における予測値の選択方法の改良, 提案法の基となる予測手法の変更などに取り組み, 予測精度の向上と更なるリスク回避を可能とする手法を構築し, その有効性を確認していきたい.

参考文献

[田村　18]　田村浩一郎:深層学習を用いたアンサンブル学習による株主価値推定モデルの提案, 人工知能学会論文誌, vol33, No. 1, p.　A-H51_1-11, 2018.

[荻原　18]　荻原航大・浦野昌一: リスク回避を考慮した翌日電力需要予測の検討, 電力技術/電力系統技術合同研究会, No. PE-18-172 PSE-18-148 , 2018.

General Session | General Session | [GS] J-2 Machine learning

[2P5-J-2] Machine learning: medicine and heathcare

Chair:Jun Ozawa Reviewer:Yoshikuni Sato

Wed. Jun 5, 2019 5:20 PM - 7:00 PM Room P (Front-left room of 1F Exhibition hall)

[2P5-J-2-01] Prediction of depressive tendencies from health data considered unassociated with depressive states

Shiori Yamaguchi[1], ○Hiroki Tanaka[1], Hayato Maki[1], Shigehiko Kanaya[1,2], Nobutaka Suzuki[3], Satoshi Nakamura[1,2] （1. Nara Institute of Science and Technology, Graduate School of Science and Technology, 2. Nara Institute of Science and Technology, Data Science Center, 3. Kanazawa University, Graduate School of Medical Sciences）

5:20 PM - 5:40 PM

[2P5-J-2-02] Data Transformation method for Comprehensive Classification to Blood Test Data

○Takumi Yoshida[1], Matsui Tohgoroh[1] （1. Chubu University）

5:40 PM - 6:00 PM

[2P5-J-2-03] Medical image recognition of MRI brain images using deep logistic GMDH-type neural network and convolutional neural network

○Tadashi Kondo[1], Shoichiro Takao[1], Sayaka Kondo[2], Junji Ueno[1] （1. Tokushima University, 2. Tokushima medical informatics laboratory）

6:00 PM - 6:20 PM

[2P5-J-2-04] Mental Disorder Diagnosis using fMRI Images by Deep State-Space Model

○Koki Kusano[1], Tetsuo Tashiro[1], Takashi Matsubara[1], Kuniaki Uehara[1] （1. Kobe University）

6:20 PM - 6:40 PM

[2P5-J-2-05] Semi-supervised learning based target gene selection for medical data

○Akito Seki[1], Hirotaka Akita[1], Hisashi Kashima[1,2], Makoto Yamada[1,2] （1. Kyoto University, 2. RIKEN AIP）

6:40 PM - 7:00 PM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

うつと関連性が低いとされている生活習慣等からのうつ傾向予測

Prediction of depressive tendencies from health data considered unassociated with depressive states

山口 栞 *1 Shiori Yamaguchi
田中 宏季 *1 Hiroki Tanaka
真木 勇人 *1 Hayato Maki
金谷 重彦 *1*2 Shigehiko Kanaya
鈴木 信孝 *3 Nobutaka Suzuki
中村 哲 *1*2 Satoshi Nakamura

*1奈良先端科学技術大学院大学　先端科学技術研究科
Nara Institute of Science and Technology, Graduate School of Science and Technology

*2奈良先端科学技術大学院大学 データ駆動型サイエンス創造センター
Nara Institute of Science and Technology, Data Science Center

*3金沢大学　医薬保健学総合研究科
Kanazawa University, Graduate School of Medical Sciences

This study investigated firstly, which lifestyle habits and physical constitution are considered related to depressive states. Following the exclusion of the lifestyle habits and physical constitution that are related to depressive states, we examined that whether the rest can predict depressive tendencies. We used three classifiers for the prediction. In addition, we used a combination of undersampling and bagging approach to improve predictive performances in our imbalanced data. The finding was that we obtained recall of 0.65 from the logistic regression with L2 regularization. Moreover, some important questions for the prediction were included in DSM-5 or QIDS-SR, meaning that we found that not all main symptoms have been widely known.

1. はじめに

うつ病とは，気分障害の一種で，世界では 3 億人以上が患っており [WHO 17]，日本では，約 100 万人が患っている [Health]. 更に，うつ傾向が見られるものの，医療機関に受診していない人が多数いることが分かっている．

精神科医がうつ病を診断する際，北米心理学会が策定した診断ガイドラインである DSM-5 (Diagnostic and Statistical Manual of Mental Disorders, 5th Edition [Black 14] や，HAM-D (Hamilton's Rating Scale for Depression [Hamilton 80] などを用いる．DSM-5 によると，抑うつ気分，あるいは興味・関心の低下を現し，更に体重の著しい増減，睡眠障害，運動障害，疲労，無価値感や罪悪感，注意散漫，死について繰り返し考えるという症状の中から 5 つ以上，かつ 2 週間以上見られた場合にうつ病と診断される．

うつ病の早期発見や再発防止のため，K6 [Kessler 02] や QIDS-SR [Rush 03] などの自己検査が存在し，医療機関に行かなくても自身のうつ傾向を確認できる．Kessler Psychological Distress Scale (K6) は，過去 1ヶ月間における無価値や絶望的であるという感覚について尋ねる 6 問から構成される．0–24 点で評価され，点数が高いほどうつ傾向が高いとされる．13 点を閾値としてうつ傾向があるとみなすと，DSM-4 に定義されたうつ病を正確に検出することができる (AUC: 0.89) [Furukawa 03].

DSM-5 の診断基準からも見られるように，うつは生活習慣等に密接に関連していると考えられている．例えば，うつと生活習慣との関係について調査した先行研究で，高齢者の孤食傾向や不眠とうつの関係が指摘されている [Kimura 12, Johnson 06]. また，カフェインなど特定の成分とうつの関係も明らかにされている [Wang 16]．他にも，体質とうつの関係も明らかにされている [Yamaguchi 18].

連絡先: 山口　栞, 奈良先端科学技術大学院大学, 奈良県生駒市高山町 8916-5 情報棟 B712, 電話：0743-72-5264 電子メール：yamaguchi.shiori.yk7@is.naist.jp

このように，生活習慣は幅広くうつと関連しているが，実際，それらの関係が広く知られているか否かは調べられていない．うつの症状の多様性を知ることは，早期発見において大変重要なことである．

そこで本稿では，まず，どの生活習慣，気質，体質がうつ状態と関連していないとみなされているかを明らかにし，それらの生活習慣等の中で，実際には関係しているものを予測モデルを利用し特定することを目的とした．この時，実際のデータに近いうつ傾向が高い人が少ない不均衡なデータで試みた．

2. 提案手法

2.1 質問紙 I

質問紙 I は，うつ傾向を判定するために用いた K6 [Kessler 02] と，生活習慣等の質問からなる．生活習慣等に関する質問の中で，基本データ (年齢，性別，職業など)，喫煙習慣，運動習慣，食習慣 [Takahashi 01]，近所の人との関わり，健康状態，気質 (Big5) [Oshio 12]，睡眠 [Doi 00]，コミュニケーション，体質 [Zhu 05] の 10 カテゴリーから成る 219 問が解析に利用された．また，選択肢は，順序，名義，間隔，比例尺度の 4 つが用いられた．

これらの質問は，妥当性や信頼性が保証されている既存の質問紙の中から，過去の文献でうつと関連性があるものを参考にし，また，医師や栄養士などの医療識者と相談した上で選択した．

2.2 質問紙 II

質問紙 II は，質問紙 I で解析対象の質問が，うつ状態に関連すると思うか否かを 2 択で回答する質問からなる．

2.3 質問 I の実験協力者

20 – 85 歳かつ日本語で読み書き可能であることを条件として，実験協力者をクラウドソーシングを通じて募集した結果，987 名から協力を得た．

表 1: L2 正則化ロジスティック回帰の混同行列

	予測されたクラス 低うつ傾向	予測されたクラス 高うつ傾向
実際のクラス 低うつ傾向	102	47
実際のクラス 高うつ傾向	13	25

調査に 2 度以上参加した 43 名の実験協力者については，初回のデータのみを利用した．また，質問数が多く，疲労などの影響により実験協力者が真剣に回答しない可能性を考慮して，同じ質問を 3 問尋ね．それらの回答のうち，2 問以上異なる回答をした 5 名を除いた．その結果，男性 320 人，女性 615 人，合計 935 人の実験協力者が解析の対象となった．

年齢に関して，異常値は中央値で置き換えた．年齢の平均は 35.3 歳で，標準偏差は，9.2 であった．この実験協力者（935 人）において，K6 の点数の平均は 8.15，標準偏差は 5.3 だった．

2.4 質問 II の実験協力者

20 – 85 歳かつ日本語で読み書き可能であることを条件として，実験協力者をクラウドソーシングを通じて募集した結果，116 名から協力を得た．調査に 2 度以上参加した実験協力者の初回のデータのみを用いた結果，106 人 (男性 : 44 人，女性 62 人) のデータを用いた．

2.5 解析手法

生活習慣等を特徴量として，うつ傾向が高い群と低い群に分類するモデルを学習させた．K6 スコアが 13 点以上の実験協力者を高うつ傾向群，その他を低うつ傾向群として判定した．高うつ傾向群は 186 人に対し，低うつ傾向群は 749 人であった．

不均衡データに対して，予測精度を向上するのに効果的なアンダーサンプリングとバギングの組み合わせ [Wallace 11] を行なった．トレーニングでは，まずうつ傾向が低い実験協力者を重複を許したサンプリングをして，うつ傾向が高い実験協力者と同数のデータを 50，100，150 個作成した．その後，トレーニングを分割した 1 つの開発データを用いて多数決によって決められた予測ラベルの評価を行なった．その際，グリッドサーチを利用し，再現率が最大となるようなハイパーパラメータを探索した．再現率を採用した理由は，うつ傾向が高い実験協力者をできるだけ見逃さないようにするためである．最後に，開発データで得られたハイパーパラメータを用いて，不均衡のテストデータにおいての予測精度を評価した．このアプローチで得られた再現率と，ベースラインとなる何も行わなかった時の再現率を比較した．

分類手法として L1 と L2 正則化付きのロジスティック回帰とランダムフォレストを使用した．全実験協力者を学習，開発とテストに 8:2 の割合で分割し，15 分割のクロスバリデーションを行なった．

また，ランダムフォレストについては，予測に対する質問の重要性をジニ係数を用いて計算した．正則化付きのロジスティック回帰については，予測に対する質問の重要性を重みの絶対値を用いて計算した．

3. 結果

3.1 うつ状態に関連があるとみなされた質問

実験協力者の過半数が K6 の 6 問全てに対して，うつ状態に関連があると判断した．生活習慣等の質問からは，20 問がうつ状態に関連すると過半数の実験協力者が判断した．一番多くの実験協力者がうつ状態に関連すると判断した質問は，不眠がちか否かであった．

3.2 分類

うつ傾向の有無を予測するモデルで，ランダムフォレストの再現率は，0.14 だったのに対し，L1，L2 正則化付きロジスティック回帰の再現率は，それぞれ 0.35，0.59 だった．一方，アンダーサンプリングとバギングを組み合わせたアプローチを行なった場合，ランダムフォレストの再現率は，0.57 だったのに対し，L1，L2 正則化付きロジスティック回帰の再現率は，それぞれ 0.59，0.65 だった．表 1 は，再現率が一番高かったアンダーサンプリングとバギングを組み合わせたアプローチをした時の L2 正則化付きロジスティック回帰においての混同行列を示している．偽陽性の誤分類がなされた実験協力者は 47 名，一方偽陰性の誤分類がなされた実験協力者は 13 名だった．

再現率が高かった L2 正則化付きロジスティック回帰による予測への貢献が高い質問上位 5 問を表 2 に示す．カテゴリーとして，体質からの質問が予測に有効な質問として多く選ばれた．L2 正則化付きロジスティック回帰において 1 番貢献度が高かった「疲れやすいですか。」という質問では，高うつ傾向群は，低うつ傾向群と比べると疲れやすいと回答する傾向が見れた．2 番目に貢献度が高かった「現在の健康状態はいかがですか。」という質問では，高うつ傾向群は，“あまりよくない”，“よくない”と回答する傾向が見られた．

4. 考察

DSM-5 [Black 14] や，QIDS-SR [Trivedi 04] に含まれている不眠に関する質問などは，多くの実験協力者がうつ状態に関連しているとみなしていた．一方，DSM-5 や QIDS-SR [Trivedi 04] には含まれている疲れやすいか否かの質問は，うつ状態に関連していないとみなされることが分かった．したがって，うつの症状の中にも広く知られているものと，あまり知られていないものがあることが分かった．

季節の変わり目などによって息苦しくなるか否かなどの予測に有効な体質に関する質問は，QIDS-SR や DSM-5 には含まれていなく，知られていなかったうつ傾向に関連する体質が明らかにされた．

不均衡データにおいて，アンダーサンプリングとバギングを組み合わせたアプローチは予測精度を上げることが分かった．しかしながら予測精度がまだ高められる余地がある数値であったので，今後の研究で不均衡データに有効だとされている SMOTE [More 16] (少数のクラスのオーバーサンプリング) など他のアプローチも検討する必要がある．

5. まとめ

今回の研究では，うつ状態と関連していないとみなされた生活習慣等の中で，実際には関係しているものを予測モデルを利用し調べた．精度は，アンダーサンプリングとバギングの組み合わせを行なった時，再現率 0.65 を得た．予測に有効とされた質問の中には，DSM-5 や QIDS-SR に含まれているものもあり，うつの主症状全てが知られていないことが分かった．

表 2: L2 正則化ロジスティック回帰による予測への貢献上位 5 問

カテゴリー	質問
体質	疲れやすいですか。
健康状態	あなたの現在の健康状態はいかがですか。
体質	季節の変わり目，温度の変化，嫌な匂いなどによって息苦しくなることがありますか。
体質	胸が重苦しかったり，腹が張ったりしますか。
体質	息切れしますか。

参考文献

[Black 14] Black, D. W. and Grant, J. E.: *DSM-5 guidebook : the essential companion to the diagnostic and statistical manual of mental disorders, fifth edition.*, Washington, District of Columbia ; London, England : American Psychiatric Publishing (2014)

[Doi 00] Doi, Y., Minowa, M., Uchiyama, M., Okawa, M., Kim, K., Shibui, K., and Kamei, Y.: Psychometric assessment of subjective sleep quality using the Japanese version of the Pittsburgh Sleep Quality Index (PSQI-J) in psychiatric disordered and control subjects., *Psychiatry Research*, Vol. 97, pp. 165–172 (2000)

[Furukawa 03] Furukawa, T. A., Kessler, R., Slade, T., and Andrews, G.: The performance of the K6 and K10 screening scales for psychological distress in the Australian National Survey of Mental Health and Well-Being., *Psychological Medicine*, Vol. 33, pp. 357–362 (2003)

[Hamilton 80] Hamilton, M.: Rating depressive patients., *The Journal of Clinical Psychiatry*, Vol. 41, No. 12, pp. 21–24 (1980)

[Health] Health, Ministry of L. and Welfare, : `http://www.mhlw.go.jp/kokoro/speciality/detail_depressive.html`

[Johnson 06] Johnson, E. O., Roth, T., and Breslau, N.: The association of insomnia with anxiety disorders and depression: Exploration of the direction of risk., *Journal Of Psychiatric Research*, Vol. 40, pp. 700–708 (2006)

[Kessler 02] Kessler, R. C., Andrews, G., Colpe, L. J., Hiripi, E., Mroczek, D. K., Normand, S.-L. T., Walters, E. E., and Zaslavsky, A. M.: Short screening scales to monitor population prevalences and trends in non-specific psychological distress., *Psychological Medicine*, Vol. 32, pp. 959–976 (2002)

[Kimura 12] Kimura, Y., Wada, T., Okumiya, K., Ishimoto, Y., Fukutomi, E., Kasahara, Y., Chen, W., Sakamoto, R., Fujisawa, M., Otsuka, K., and Matsubayashi, K.: Eating alone among community-dwelling Japanese elderly: Association with depression and food diversity., *Journal of Nutrition, Health and Aging*, Vol. 16, pp. 728–731 (2012)

[More 16] More, A.: Survey of resampling techniques for improving classification performance in unbalanced datasets (2016)

[Oshio 12] Oshio, A., Abe, S., and Cutrone, P.: (in Japanese) Development, Reliability, and Validity of the Japanese Version of Ten Item Personality Inventory (TIPI-J), *The Japanese Journal of Personality*, Vol. 21, pp. 40–52 (2012)

[Rush 03] Rush, A. J., Madhukar, H. T., Ibrahim, H. M., Carmody, J. T., Arnow, B., Klein, N. D., Markowitz, J. C., Ninan, P. T., Kornstein, S., Manber, R., Thase, M. E., Kocsis, J. H., and Keller, M. B.: The 16-Item quick inventory of depressive symptomatology (QIDS), clinician rating (QIDS-C), and self-report (QIDS-SR): a psychometric evaluation in patients with chronic major depression, *Biological Psychiatry*, Vol. 54, pp. 573–583 (2003)

[Takahashi 01] Takahashi, K., Yoshimura, Y., Kaimoto, T., Kunii, D., Komatsu, T., and Yamamoto, S.: Validation of a food frequency questionnaire based on food groups for estimating individual nutrient intake., *The Japanese Society of Nutrition and Dietetics*, Vol. 59, pp. 221–232 (2001)

[Trivedi 04] Trivedi, H. M., J., R. A., Ibrahim, H. M., Carmody, T. J., Biggs, M. M., Suppes, T., Crismon, M. L., Shores-Wilson, K., Toprac, M. G., Dennehy, E. B., Witte, B., and Kashner, T. M.: The Inventory of Depressive Symptomatology, Clinician Rating (IDS-C) and Self-Report (IDS-SR), and the Quick Inventory of Depressive Symptomatology, Clinician Rating (QIDS-C) and Self-Report (QIDS-SR) in public sector patients with mood disorders: a psychometric evaluation, *Psychological Medicine*, Vol. 34, pp. 73–82 (2004)

[Wallace 11] Wallace, B. C., Small, K., Brodley, C. E., and Trikalinos, T. A.: Class, Imbalance, Redux, *IEEE 11th International conference on Data Mining*, pp. 754–763 (2011)

[Wang 16] Wang, L., Shen, X., Wu, Y., and Zhang, D.: Coffee and caffeine consumption and depression: A meta-analysis of observational studies., *The Australian and New Zealand Journal Of Psychiatry*, Vol. 50, pp. 228–242 (2016)

[WHO 17] WHO, : Depression and Other Common Mental Disorders Global Health Estimates (2017)

[Yamaguchi 18] Yamaguchi, S., Tanaka, H., Maki, H., Kanaya, S., Suzuki, N., and Nakamura, S.: Prediction of

depressive tendency from multidimensional health data collected through crowdsourcing (2018)

[Zhu 05] Zhu, Y.: Development of the Constitution in Chinese Medicine Questionnaire (CCMQ), *Japanese Journal of public health* (2005)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

血液検査データに対する包括的な分類分析のためのデータ変換法

Data Transformation for Comprehensive Classification in Blood Test Analysis

吉田 拓倫 *1　松井 藤五郎 *1 *2
Takumi Yoshida　Tohgoroh Matsui

*1 中部大学 工学部 情報工学科
Department of Computer Science, College of Engineering, Chubu University

*2中部大学 生命健康科学部 臨床工学科
Department of Clinical Engineering, College of Life and Health Sciences, Chubu University

This paper proposes a method to transform data to better fit a normal distribution in medical record analysis. We proposed a method to comprehensively analyze medical record using various machine learning method. Because some machine learning method assume that the data follow normal distribution, we need to transform the data to fit normal distribution. Ordinary method used Box-Cox transform that is a power transform, but it cannot apply negative values. In this paper, we propose to use Yeo-Johnson transform instead of Box-Cox transform, because it can apply negative values. We also propose one-class power transform that estimates the transform parameter only from one class. We confirmed that our proposed method can transform the data even if some values are negative and the transformed data fit normal distribution better than Yeo-Johnson transform using both classes.

1. はじめに

近年、電子カルテの普及が進みデータは電子データとして蓄積されている。電子データには血液検査の結果が記録されており、データを解析することで病気の原因を推測することが期待される。血液検査には膨大な項目があり、医師のみの判断では全ての検査項目を判断することは難しく見落としが発生し、医療ミスへと繋がることが問題となっている。機械学習で検査項目を網羅的に分析することで見逃しを防ぐことも期待される。

これまでに、我々は、複数の機械学習手法を用いて血液検査データを包括的に分析する方法 [1] を提案した。機械学習手法の中には、データが正規分布に従っていることを仮定しているものがあるため、従来手法では、べき乗変換の一種である Box-Cox 変換を用いてデータが正規分布に近づくように変換する。しかしながら、Box-Cox 変換は正の値しか変換できないため、負の値があると適用できないという問題が生じていた。

そこで本研究では、血液検査データに対する包括的な分類分析において、負の値でも変換可能なべき乗変換を用いることを提案する。また、従来手法と同様に、正常値を多く含むクラスだけからべき乗変換のパラメータを推定することを提案する。

2. 血液検査データ

名古屋市内にある救急救命センターにおいて、2016 年 1 月 1 日から 4 月 18 日までに死亡した 359 名の患者から、死亡日から 1 年前と死亡日までの間に実施された血液検査の結果を対象とした。検査結果を患者ごとに 1 日分をまとめ、4,408 件のデータがある。

血液検査データに対する包括的な分類分析 [] では、検査結果を死亡日直近に行われた結果とそれ以外の結果に分類・予測する。死亡日またはその前日に検査が行われた血液検査結果の値を 1（正例）、それ以外の血液検査結果の値を 0（負例）としている。4,408 件のデータのうち、死亡日直近（正例）は 273 件、それ以外（負例）は 4,135 件である。

連絡先: 吉田拓倫，中部大学 工学部 情報工学科, ep15146-1409@sti.chubu.ac.jp

3. 従来手法

従来手法は、血液検査データに対して複数の機械学習手法を用いて分類分析を行う。機械学習手法の中にはデータが正規分布に従っていることを仮定しているものがあるが、実際のデータは正規分布に従っているとは限らないため、従来手法ではデータの分布を正規分布に近づける 1 クラス Box-Cox 変換という手法を提案している。

Box-Cox 変換は Box と Cox により、1964 年に提案された [2] データ全体を正規分布に従うよう変換する手法である。

Box-Cox 変換は次式で表される。

$$x^{(\lambda)} = \begin{cases} \frac{x^{\lambda}-1}{\lambda} & \text{if } \lambda \neq 0 \\ \ln x & \text{Otherwise} \end{cases} \quad (1)$$

ここで、λ は変換パラメータであり、尤度法によって推定される。

Box-Cox 変換はデータ全体が正の値であることを前提としている為、0 以下の値が含まれる場合には、変換を行う前にバイアスとして定数を加えることでデータ全体を正の値へと変換してから適用する必要がある。

通常の Box-Cox 変換において、λ はデータ全体から推定される。血液検査データにおいては、臨床的に正常な値は正規分布に従うが、臨床的に異常な値は正規分布から大きく外れると考えられる。そこで、負例のみからべき乗変換のパラメータ λ を推定することで異常値が含まれる可能性を軽減し、推定された λ を用いてデータ全体を変換する。この手法を **1 クラス Box-Cox 変換**と呼ぶ。

3.1 従来手法の問題点

従来手法の 1 クラス Box-Cox 変換には問題点が 2 つある。

一つ目の問題点は、バイアスを加えてもには Box-Cox 変換では変換が行えないことがあることである。1 クラス Box-Cox 変換ではデータに 0 以下の値が含まれる場合、訓練データか

ら最小値を取り定数を加算することで正の値へと加工する必要がある。テストデータ（未知）の値に訓練データより小さな値が含まれる場合、訓練データから得られた値を加算してもテストデータは正の値に変換されない。また、正例にバイアスより小さな値が含まれる場合においても、正の値に変換されない。Box-Cox 変換は 0 以下の値が含まれる場合には変換ができない為、変換は不可能となる。

二つ目の問題点は、データを加工する際に含まれる定数ことである。定数が大きすぎる場合、データはある値を境に頭打ちになってしまい、最適な定数を定めなければデータは変換出来ない為、定数を定める手順が増えてしまう。

4. 提案手法

4.1 提案手法の概要

本論文では、テストデータに 0 以下の値が含まれている場合においても、正規分布に従っていないデータを正規分布に従わせる変換手法を提案する。提案手法では、Box-Cox 変換の問題を改善した手法である Yeo-Johnson 変換 [3] を用いて、1 クラス Box-Cox 変換と同様に負例のみから λ の推定を行うことで異常値が含まれる可能性を軽減する。本論文において、この手法を 1 クラス Yeo-Johnson 変換ではなく、2 つの手法の総称を用いて **1 クラス Power Trans**（べき乗変換）と呼ぶ。

4.2 Yeo-Johnson 変換

Yeo-Johnson 変換は 2000 年に Yeo と Johnson によって提案された手法で、Box-Cox 変換と同様に、データ全体を正規分布に従うよう変換する手法である。

Yeo-Johnson 変換は次式で表される。

$$x^{(\lambda)} = \begin{cases} \frac{((x+1)^{\lambda}-1)}{\lambda} & \text{if } \lambda \neq 0,\ x \geq 0 \\ \log(x+1) & \text{if } \lambda = 0,\ x \geq 0 \\ \frac{-\left[(-x+1)^{2-\lambda}-1\right]}{(2-\lambda)} & \text{if } \lambda \neq 2,\ x < 0 \\ -\log(-x+1) & \text{if } \lambda = 2,\ x < 0 \end{cases} \tag{2}$$

ここで、λ 変換パラメータであり、尤度法によって推定される。

Yeo-Johnson 変換は Box-Cox 変換を拡張させた手法である。Box-Cox 変換とは異なり、データ全体に 0 以下の値が含まれていた場合においても、データを加工せず変換を行うことができる。

4.3 1 クラス Power Trans

1 クラス Power Trans では、Box-Cox 変換の代わりに Yeo-Johnson 変換を使用する。1 クラス Box-Cox 変換同様に負例のみから λ の推定を行う。1 クラス Power Trans では、未知の値に 0 以下の値が含まれ、かつ、訓練データの最小値より小さい値が入った場合でも使用できる。また、1 クラス Box-Cox 変換とは異なり、定数を設定する必要がない為、データを加工する手順を省くことができる。

5. 評価実験

5.1 実験方法

提案手法の有効性を確認するため、実際の血液検査データに含まれる v52（メトヘモグロビン）を元にテストセットを作成した。v52 の値の平均値を基準に、それぞれの値から平均値を減算し、偏差となるように加工したものをテストセットとした。テストセットの値の分布を図 1 に示す。

テストセットに対して、通常の Power Trans と 1 クラス Power Trans を用いて変換し、正規分布に従っているか比較を行った。正規分布に従っているかの比較には、シャピロ-ウィルク検定 [5][6] を用いた。シャピロ-ウィルク検定は次式で表される。

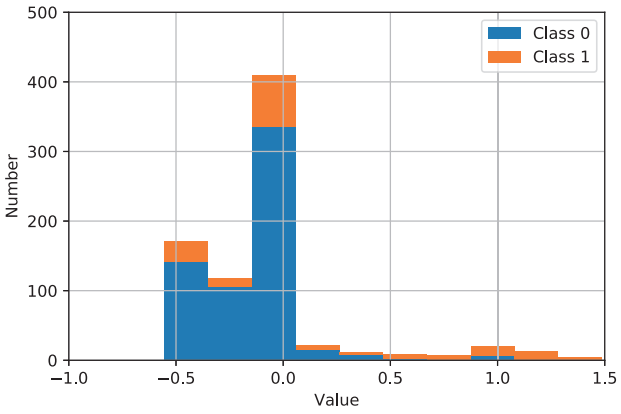


図 1　変換前のテストセット

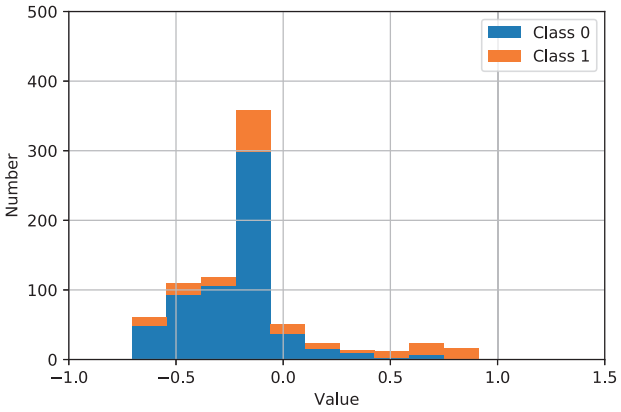


図 2　通常の Power Trans で変換後

$$W = \frac{(\sum_{i=1}^{n} a_i x_{(i)})^2}{\sum_{i=1}^{n}(x_i - \overline{x})^2} \tag{3}$$

$x_{(i)}$ は i 番目の順序統計量、x_i は i 番目の標本、a_i は有意水準であり平均から得られた定数を表す。

シャピロ-ウィルク検定で得られる W は $0 \leq W \leq 1$ で 1 に近いほど正規分布に近い。p-value が 0.05 未満の場合、5% 有意水準での統計的有意性を持つ。

5.2 実験結果

テストセットのヒストグラムを図 1、通常の Power Trans で変換したヒストグラムを図 2 に、1 クラス Power Trans で変換したヒストグラムを図 3 に示す。シャピロ-ウィルク検定による検定結果を表 1 に示す。

表 1 を見ると、通常の Power Trans と 1 クラス Power Trans の p-value は 0.05 より小さい為、統計的有意性がある。1 クラス Power Trans は $W = 0.87$ と、通常の Power Trans の $W = 0.85$ に比べて W が 0.02 大きく、正規分布に近い。

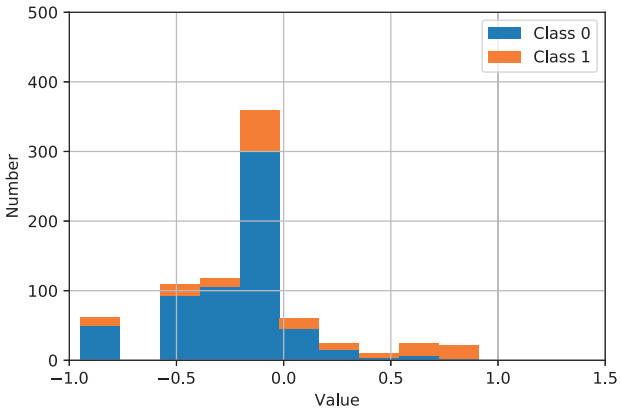


図 3　1 クラス Power Trans で変換後

表 1　シャピロ-ウィルク検定

	W	p-value
Origin Data	0.73	1.26391×10^{-33}
Normal PT	0.85	2.88913×10^{-37}
1-Class PT	0.87	5.26289×10^{-33}

5.3　考察

今回使用した血液検査データにおいて、0 以下の値を持つデータは v59（アニオンギャップ）と v60（ベースエクセス）のみであった。v59 は $W = 0.92$、p-value $= 1.96 \times 10^{-19}$ であり、v60 では $W = 0.96$、p-value $= 2.93 \times 10^{-14}$ と、いずれも正規分布に近いため、変換を行う必要はなかった。そのため、本論文では正規分布に従っていない変数を加工することによって 0 以下の値を含む他のテストセットを作成し、提案手法の有効性を確認した。しかし、一般的には 0 以下の値を含む正規分布に従わないデータが存在するため、Yeo-Johnson 変換を用いることは有効であると考えられる。

通常の Power Trans で変換した値は、最も頻度の高い範囲が 0 付近に移動しているが、全体的な分布の形は元データと変わっていない。そのため、シャピロ-ウィルク検定の W がほとんど変わっていない。これに対し、1 クラス Power Trans で変換した値は、山を低くしてその分を左に移動させており、より正規分布に近い形となっている。

1 クラス Box-Cox 変換では、図 4 のように、検証用データや予測対象のデータに元データの最小値より小さい負の値が含まれる場合、変換を行うことが出来ない。図 4 に示した例の場合、学習用データの最小値 −31.1 の絶対値に 1 を足した値をバイアスとして足しても、検証用データの最小値は正の値にならず、Box-Cox 変換が適用できない。提案手法では、Yeo-Johnson 変換を用いているため、このような場合でも変換でき、バイアスも必要ない。

6.　結論

従来の血液検査データに対する包括的な分類分析では、正規分布を前提とした機械学習手法を用いるために、Box-Cox 変換をベースとしたデータ変換法を用いていたが、Box-Cox 変換は負の値に対応していないため、データが変換できないことがあった。本論文では、Box-Cox 変換の代わりに Yeo-Johnson 変換を用いることによって、未知の値が既知の値より小さい値においても変換でき、広範囲のデータを変換できる手法を提案した。Box-Cox 変換ではバイアスを指定する必要があるが、提案手法はバイアスを指定する必要がないため、データを本手法に入力するのみで変換を行うことができる。

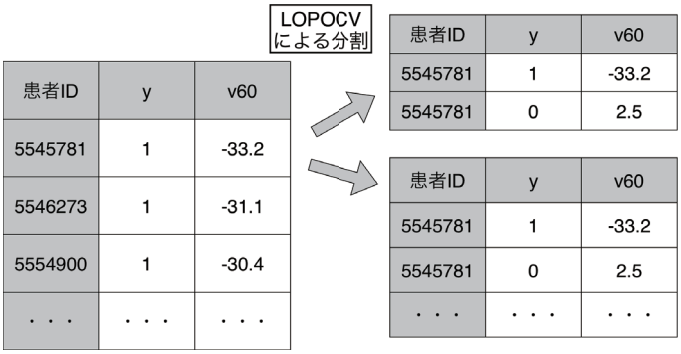


図 4　1 クラス Box-Cox 変換でエラーとなるデータ

正例の中の正常値や負例の中の異常値に関しては処理を施していない為、異常値検出と組み合わせることでより正規分布に近づける為の使用可能な値は残されていると考えられる。現在は、データ全体に対して 1 クラス Power Trans を施している為、シャピロ-ウィルク検定などを用いて正規分布に従っていない場合のみ変換を行った場合と比較したい。

今後は、提案手法を用いたデータ変換が機械学習の予測精度に与える影響について評価したい。

参考文献

[1] 松井, 永田, 吉田, 平手: 予測因子候補を抽出するための血液検査データに対する包括的な分類分析, 第 32 回人工知能学会全国大会, 4C1-OS-27a-04, 2018

[2] G. E. P. Box and D. R. Cox: An analysis of transformations, *Journal of the Royal Statistical Society*, B, 26(2):211–252, 1964

[3] In-Kwon Yeo and Richard A. Johnson: A new family of power transformations to improve normality or symmetry, *Journal of Biometrika*, 87:954–959, 2000

[4] F. Pedregosa, G. Varoquaux, A. Gramfort, et al.: Scikit-learn: Machine learning in Python, *Journal of Machine Learning Research*, 12:2825–2830, 2011

[5] S. S. Shapiro and M. B. Wilk: An analysis of variance test for normality (complete samples), *Biometrika*, 52():591–611, 1965

[6] S. S. Shapiro, M. B. Wilk, and H. J. Chen: A Comparative Study of Various Tests for Normality, *Journal of the American Statistical Association*, 63(324):1343–1372, 1968

ディープロジスティック GMDH-type ニューラルネットワークと CNN を用いた頭部 MRI 画像の医用画像認識

Medical image recognition of MRI brain images using deep logistic GMDH-type neural network and convolutional neural network

近藤 正[*1] Tadashi Kondo　高尾 正一郎[*2] Shoichiro Takao　近藤 明佳[*3] Sayaka Kondo　上野 淳二[*4] Junji Ueno

[*1] 徳島大学 Tokushima University　[*2] 徳島大学 Tokushima University　[*3] 徳島医用情報科学研究会 Tokushima medical informatics laboratory　[*4] 徳島大学 Tokushima University

In this study, hybrid deep neural network is organized using the deep logistic Group Method of Data Handling (GMDH)-type neural network and the Convolutional Neural Network (CNN) and, is applied to the medical image recognition problem. The deep GMDH-type neural network algorithms have abilities of self-selecting the number of hidden layers, the optimum neuron architectures and useful input variables, and they can automatically organize the deep neural network architectures to minimize prediction error criterion defined as Akaike's Information Criterion (AIC) or Prediction Sum of Squares (PSS) . This deep neural network algorithm is applied to medical image recognitions of brain regions, and the organs such as brain, the white matter and the lateral ventricle, are recognized and these regions are extracted accurately using the deep logistic GMDH-type neural networks.

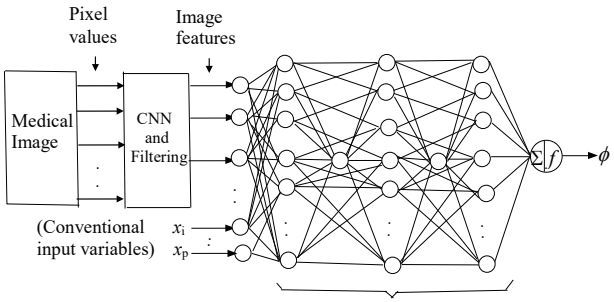
1. はじめに

本研究では、ディープロジスティック GMDH-type ニューラルネットワークとコンボリューショナルニューラルネットワーク(CNN)を用いたハイブリッド型ニューラルネットワーク[1]を用いて、頭部 MRI 画像の医用画像認識を行う。ディープ GMDH-type ニューラルネットワークのアルゴリズムは、著者らのグループにより、各種のアルゴリズムが提案されている[1-4]. ディープロジスティック GMDH-type ニューラルネットワーク[1]は、進化論的計算法の一種である改良形発見的自己組織化法[5]を用いて、多層構造をしたディープニューラルネットワークを自動的に構成することができる。中間層の個数、最適なニューロン構造、有益な入力変数の選択などのネットワークの構造パラメータを、予測誤差評価基準(情報量基準 AIC[6]や予測誤差平方和(PSS)[7])を最小にするように、自動的に決定している。本研究では、ディープロジスティック GMDH-type ニューラルネットワークス[1]を、文献[2, 3]と同じ頭部 MRI 画像の医用画像認識問題に応用して、その画像認識結果を比較検討する。

2. ディープロジスティック GMDH-type ニューラルネットワークスと CNN を用いたハイブリッド型ディープニューラルネットワーク[1]

ディープロジスティック GMDH-type ニューラルネットワークと CNN を用いたハイブリッド型ディープニューラルネットワークの構造[1]を、Fig.1 に示す。このニューラルネットワークでは、CNN とフィルタリングによって画像特徴量を発生させる。さらに、従来から医用画像に用いられている画像特徴量や位置情報などを加えてディープロジスティック GMDH-type ニューラルネットワークの入力変数にする。このディープニューラルネットワークでは、入力変数のすべての組み合わせを発生させて、有益な変数の組み合わせのみを自己選択し、選択した変数の組み合わせを用いてディープニューラルネットワーク構造を自己組織化する。

*連絡先:近藤正、徳島大学医学部保健学科
[*1]Email: kondomedsci@gmail.com



$g_i(x_1,x_2,\cdots,x_p)$: *Polynomial*
Σ : (*Nonlinear function*): $z_k = \sum w_i g_i(x_1,x_2,\cdots,x_p)$
f : (*Nonlinear function*): $\phi = 1/(1+exp(-z_k))$

Fig.1 Hybrid deep neural network architecture of deep logistic GMDH-type neural network and convolutional neural network (CNN)

2.1 CNN とフィルタリング

本研究では、学習に用いる大量の画像データを準備できなかったので、CNN での学習は行わずに、CNN のフィルタの値としてはあらかじめ既存のものを準備する。そして、フィルタとしてはガウシアンフィルタとラプラシアンフィルタを用いてコンボリューション層で計算を行い画像特徴量を発生させる。次に、プーリング層では、最大値、最小値、範囲などのフィルタリングを行い、画像特徴量の抽出を行う。

2.2 ディープロジスティック GMDH-type ニューラルネットワーク

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)や予測誤差平方和(PSS)を最小にするように自動的に決定する。

Fig.1 において、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。本研究では、予測誤差評価基準として、予測誤差平方和(PSS)を用いる。本アルゴリズムの概要を以下に示す。

[1] 第 1 層

$$u_j = x_j \qquad (j=1,2,\ldots,p) \quad (2)$$

ここで、x_j はシステムの入力変数を示す。

[2] 第 2 層

入力変数(u)を組み合わせて、2変数のすべての組み合わせ(u_i, u_j) 又は 3 変数すべての組み合わせ(u_i, u_j, u_k)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)

$$z_k=w_1u_i+w_2u_j+w_3u_iu_j+w_4u_i^2+w_5u_j^2 - w_0\theta_l \quad (3)$$

or

$$z_k=w_1u_i+w_2u_j+w_3u_k+w_4u_iu_j+w_5u_iu_k+w_6u_ju_k +w_7u_i^2+w_8u_j^2+w_9u_k^2-w_0\theta_l \quad (4)$$

f: (Linear function)

$$y_k= z_k \quad (5)$$

ここで、θ_l =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、主成分回帰分析を用いて推定する。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。

$$z_k^{**} = \log_e(\frac{\phi'}{1-\phi'}) \quad (6)$$

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。z_k^{**}を用いて、各々のニューロンに対して、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。

次に、発生した多項式型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 個の多項式型ニューロンを用いて総合特性変数ϕ^*を発生させる。

$$\phi^* = a_0 + \sum_{k=1}^{L} a_k y_k \quad (7)$$

ϕ^*と L 個のニューロンの出力値(y_k)を次層の入力変数(u_k)にセットして、次層の計算に移る。

[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。

$$\phi=1/(1+exp\,(-z_k)) \quad (8)$$

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。

〈シグモイド関数型ニューロン〉

∑: (Linear function)

$$z_k=\Sigma w_i g_i(x_1,x_2,\ldots,x_p) \quad (9)$$

f: (Nonlinear function)

$$\phi=1/(1+exp\,(-z_k)) \quad (10)$$

以上の手続きによりディープロジスティック GMDH-type ニューラルネットワーク[1]を構成できる。

3. 頭部臓器の医用画像認識への応用

本研究では、ディープロジスティック GMDH-type ニューラルネットワークスを用いて、頭部臓器の医用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 MRI 画像を用いた。なお、本研究では予測誤差の評価基準として PSS を用いた。

3.1 脳実質領域の医用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、CNN において、ガウシアンフイルタ、ラプラシアンフイルタ、最大値フイルタ、最小値フイルタ、レンジフイルタにより発生した 5 個の画像特徴量と、従来から用いられている統計学的特徴量である平均値、分散、標準偏差、及び位置情報(x と y 座標)の合計 10 個の入力変数を用いた。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、最大値の 6 個の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、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 5 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 GMDH-type ニューラルネットワークスの計算は第 19 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小さな値に収束した。

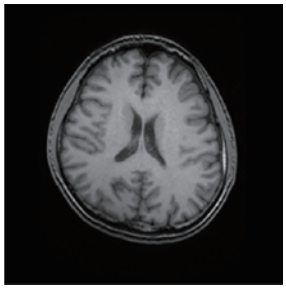


Fig.2 Original image

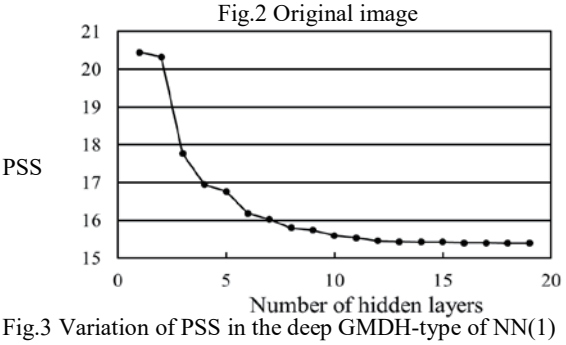


Fig.3 Variation of PSS in the deep GMDH-type of NN(1)

自己組織化されたディープロジスティック GMDH-type ニューラルネットワークスによって脳実質領域を出力する。Fig.4 に、ニューラルネットワークの出力画像を示す。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、画像の膨張処理と収縮処理を行い、脳実質領域の内部に孤立した部分がある場合や、脳実質領域の外部にある孤立点が除去された。そして、脳実質領域の輪郭を N/2 画素分だけ外側に拡張した。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。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脳実質領域は、原画像の脳実質領域によく一致していることがわかる。Fig.7 に差分画像(グレー画像)を示す。

誤差逆伝播法(BP 法)を用いて学習する従来形ニューラルネットワークを用いて脳実質領域の画像認識を行い、画像認識結果[2,3]との比較を行った。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。学習データは、ディープ GMDH-type ニューラルネットワークと同じものを用いた。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。これらのニューラルネットワークの出力画像には、孤立点や脳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。



Fig.4 Output image of the neural network(1)

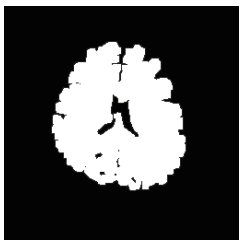


Fig.5 Output image after the post-processing(1)

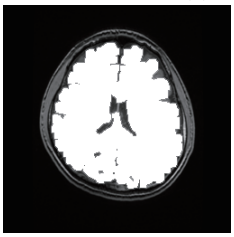


Fig.6 Overlapped image(1)

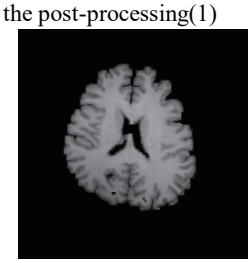
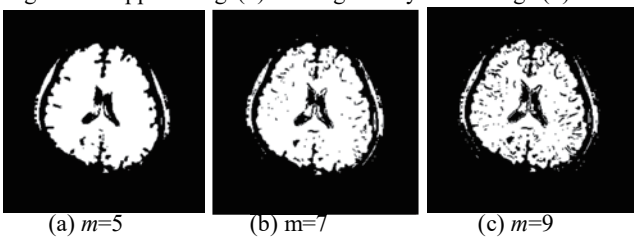


Fig.7 Gray scale image (1)



(a) *m*=5 (b) m=7 (c) *m*=9

Fig.8 Output images of the conventional neural network (1)[2,3]

3.2. 白質領域の医用画像認識と領域抽出

白質領域の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。そして、平均値、*x* 座標、*y* 座標、範囲、ガウシアンフイルタの出力値、ラプラシアンフィルタの出力値の6個の入力変数が自己選択された。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 3 の場合に、最も良い画像認識精度を得た。ディープロジスティック GMDH-type ニューラルネットワークスの計算は第 20 層で終了した。Fig.9 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小さな値に収束した。Fig.10 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。Fig.11 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。Fig. 12 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白質領域は、原画像の白質領域によく一致していることがわかる。Fig.13 に、白質領域のグレー画像を示す。Fig.14 に BP 法を用いて学習する 3 層構造の従来型ニューラルネットワークによって得られた画像認識結果[2,3]を示す。

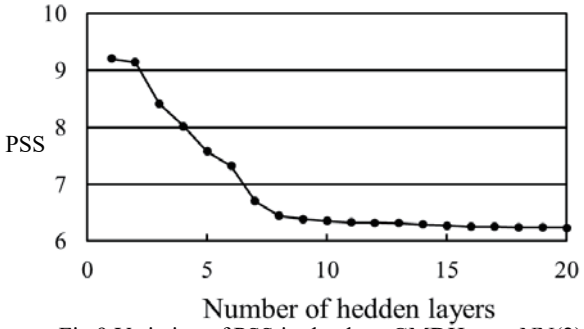


Fig.9 Variation of PSS in the deep GMDH-type NN(2)

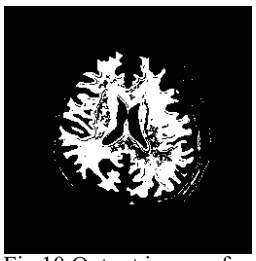


Fig.10 Output image of the neural network(2)

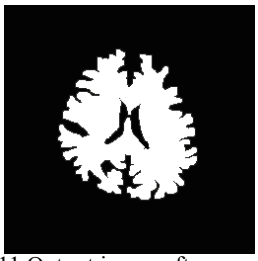


Fig. 11 Output image after the post processing (2)

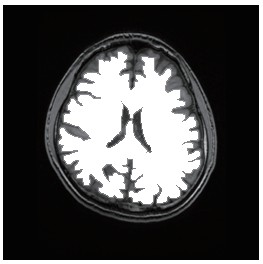


Fig. 12 Overlapped image(2)

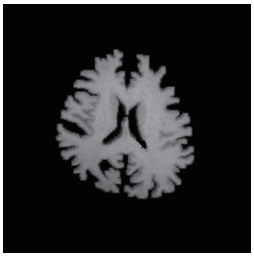


Fig.13 Gray scale image (2)



(a) *m*=5 (b) m=7 (c) *m*=9

Fig.14 Output images of the conventional neural network (2)[2,3]

3.3. 脳室領域の医用画像認識と領域抽出

脳室領域の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。そして、平均値、*x* 座標、*y* 座標、範囲、ガウシアンフイルタの出力値、最大値の6個の入力変数が自己選択された。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 4 の場合に、最も良い画像認識精度を得た。ディープロジスティック GMDH-type ニューラルネットワークスの計算は第 8 層で終了した。Fig.15 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.16 に最終層で得られた出力画像を示す。Fig.17 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。Fig. 18 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脳室領域は、原画像の脳室領域によく一致していることがわかる。Fig.19 に、脳室領域のグレー画像を示す。Fig.20 に、BP 法を用いて学習する 3 層構造の従来型ニューラルネットワークによって得られた画像認識結果[2,3]を示す。

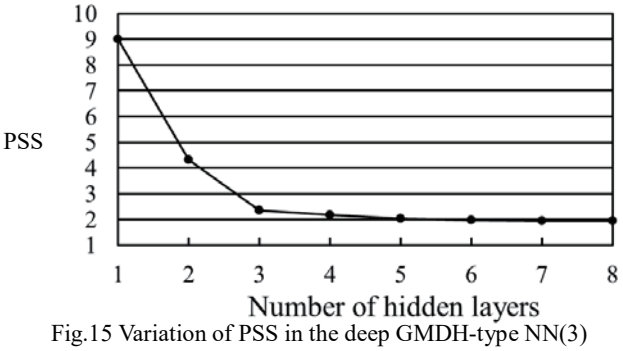


Fig.15 Variation of PSS in the deep GMDH-type NN(3)



Fig.16 Output image of the neural network (3)

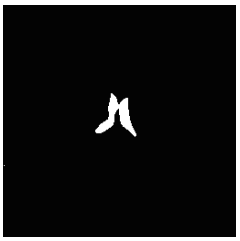


Fig. 17 Output image after the post processing (3)

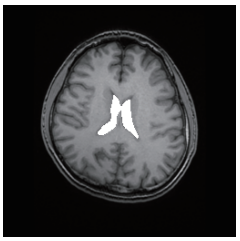
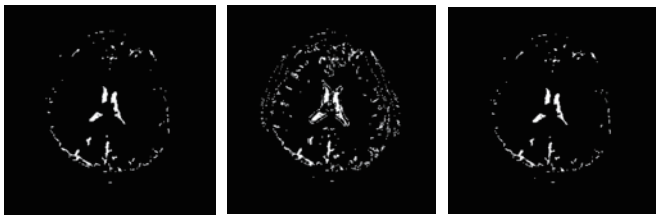


Fig. 18 Overlapped image(3)



Fig.19 Gray scale image (3)



(a) *m*=5 (b) m=7 (c) *m*=9

Fig.20 Output images of conventional neural network (3)[2,3]

Table 1 Number of hidden layers

Regions	Number of hidden layers
Brain	19
White matter	20
Lateral ventricle	8

3.4 考察

本研究では、脳実質、白質、脳室の各々の領域を画像認識して領域抽出する 3 つのディープニューラルネットワークスを自己組織化した。Table1 に、各々のディープニューラルネットワークの隠れ層の層数を示す。脳の実質では 19 層、白質では 20 層、脳室では 8 層のディープニューラルネットワークスが自己組織された。画像認識結果（Fig.3, Fig.9, Fig.15）から、予測誤差評価基準値（PSS）は、層を積み重ねるごとに徐々に減少していき、最終層では PSS 値が小さな値に収束した。次に、Table2 に有益な入力変数の自己選択結果を示す。従来のディープ GMDH-type ニューラルネットワークの研究では、平均値、分散、標準偏差、*x* 座標値、*y* 座標値の 5 つの入力変数が良く用いられていた。本研究では、3 つのニューラルネットワークで共通に自己選択された入力変数は、平均値、*x* 座標、*y* 座標の 3 変数であった。CNN やフイルタリングで発生された画像特徴量も自己選択されており、対象となる臓器の画像認識に最も適した画像特徴量が、各々のディープニューラルネットワークスにおいて自己選択されたことが分かる。

4. むすび

本研究では、ディープロジスティック GMDH-type ニューラルネットワークと CNN を用いたハイブリッド型ニューラルネットワークを用いて、頭部 MRI 画像の医用画像認識を行った。ディープロジスティック GMDH-type ニューラルネットワークスは、対象となる複雑な構造をした非線形システムの特徴によく適合するように、中間層の層数の自己選択、有益な入力変数の自己選択などの機能を備えており、予測誤差評価基準(AIC や PSS)を最小にするように、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している。このため、ニューラルネットワークの構造パラメーター（有益な入力変数の選択、層数の選択、各層のニューロン数の選択など）を変化させて、最適なディープニューラルネットワーク構造を見つけるための学習計算を繰り返す必要がないため、実際問題への応用が非常に容易である。本研究では、頭部 MRI 画像の医用画像認識問題へ応用し、画像認識結果を比較してその有効性を確認した。文献[2,3]の医用画像認識結果との比較については、発表時に示す。

謝 辞

本研究は、科学研究費補助金 JSPS KAKENHI Grant Number JP18K0420600 により補助を受けて実施された。

参 考 文 献

[1] S. Takao, S. Kondo, J. Ueno and T. Kondo: Medical image diagnosis of liver cancer by hybrid deep neural network of deep logistic GMDH-type neural network and convolutional neural network, *Proceedings of the Twenty-Third International Symposium on Artificial Life and Robotics* 2018 (*AROB* 23rd 2018), pp.89-93 (2018)

[2]近藤正、高尾正一郎、近藤明佳、上野淳二：ディープ GMDH-type ニューラルネットワークとコンボリューショナルニューラルネットワークを用いた臓器の自動医用画像認識、医療情報学会・人工知能学会 AIM 合同研究会資料 SIG-AIMED-006-05(2018)

[3] S. Takao, S. Kondo, J. Ueno and T. Kondo: Medical image recognition of brain regions using deep multi-layered GMDH-type neural network and convolutional neural network, *Proceedings of the Twenty-Fourth International Symposium on Artificial Life and Robotics* 2019 (*AROB* 24th 2019), pp.115-121 (2019)

[4] S. Takao, S. Kondo, J. Ueno and T. Kondo: Deep feedback GMDH-type neural network and its application to medical image analysis of MRI brain images, *Artificial Life and Robotics,* vol.23, No.2, pp.161-172 (2018)

[5] S. J. Farlow ed.: Self-organizing methods in modeling, GMDH-type algorithm, New York: Marcel Dekker Inc. (1984)

[6] H. Akaike: A new look at the statistical model identification, *IEEE Trans. Automatic Control,* vol.AC-19, no.6, pp.716-723 (1974)

[7] H. Tamura, 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)

Table2 Selection of useful input variables in the deep logistic GMDH-type neural networks

Input variables / Regions	Gaussian filter	Laplacian filter	Maximum filter	Minimum filter	Range filter	Mean	X	Y	Variance	Standard deviation
Brain			○			○	○	○	○	○
White matter	○	○			○	○	○	○		
Lateral ventricle	○		○		○	○	○	○		

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

深層状態空間モデルによるfMRI画像を用いた精神疾患診断

Mental Disorder Diagnosis using fMRI Images by Deep State-Space Model

草野航希 Koki Kusano　田代哲生 Tetsuo Tashiro　松原崇 Takashi Matsubara　上原邦昭 Kuniaki Uehara

神戸大学 大学院システム情報学研究科
Graduate School of System Informatics, Kobe university

Machine learning-based accurate diagnosis of mental disorders is expected to support finding their biomarkers and understanding their underlying mechanism. Recent studies employed dynamic and generative models due to the time-varying nature of the brain activities. Though it is difficult to extract complex features due to the simpleness of the model. In this paper, we model fMRI data using dynamic and deep generative model. The proposed deep state-space model is flexible, dynamic and generative(interpretable). Hence it can extract complex feature, capture time-varying nature of the brain activities and identifies brain regions related to the disorders.

1. はじめに

早期の正確な神経疾患の診断は，適切な治療や新たな治療法の評価に役立つ．そのためには，なるべく診断手順において，疾患のバイオマーカーを特定し，内部メカニズムを解明するべきで，言い換えれば説明可能であるべきである (表 1)．また，疾患は，脳活動や機能的接続 (functional connectivities; FC) と呼ばれる脳活動の相互作用を変化させるが，FC はそもそも経時的に変化するものである [Liu 13, Li 15]．それゆえ，時間変化する信号を捉えるためには，診断手順は動的であるべきである (表 1)．

そういった理由で，fMRI (functional magnetic resonance imaging) は多くの脳画像技術において注目を集めている [Atkinson 01]．fMRI は脳領域ごとの活動を視覚化し，統合失調症 [Castro 16, Plis 14] などの精神疾患の分析に使用され，また，多くの機械学習手法により分析されてきた (表 1)．脳領域ごとの活動間のピアソン相関係数 (PCC) に基づいた特徴抽出は，疾患によって変化した静的な FCs を検出している [Shen 10, Yahata 16]．隠れマルコフモデル (hidden Markov model; HMM) は確率的グラフィカルモデルで，脳活動の根底にあるダイナミクスを推測することができる [Suk 16]．機械学習の中でも，有力な手法として深層ニューラルネットワーク (DNN) が注目を集めている [Bengio 12, Schmidhuber 15]．DNN は，高度な特徴を自動で学習することで様々なタスクで成果を挙げてきた．DNN を再帰的に接続した，LSTM と呼ばれるモデルが，fMRI データの分析に有効であった [Dvornek 17]．LSTM は DNN の柔軟性を享受し (表 1)，fMRI データを効果的に扱う事ができる．だがしかし，複雑な識別機であるため，PCC や HMM とは異なり，疾患の内部メカニズムを抽出するのは難しい．つまりは，説明可能ではない．DNN の柔軟性と確率的グラフィカルモデルの分析的性質を活用するために，deep generative model (DGM) が提案され [Kingma 14]，静的な FC に限定した DGM を fMRI データに適用された [Tashiro 17].

ここで fMRI データ分析に提案する深層状態空間モデル (*deep state-space model*; DSSM) は，比較手法らの全ての利点を備えている (表 1)．DSSM は，DNN を使った連続的な fMRI データの状態空間モデルで，deep Kalman filter [Krishnan 17] のように DGM を動的に拡張したものとみなせる．deep Kalman filter と異なり，DSSM は患者ごとに診断結果を持っている．DSSM は患者の状態を仮定し，fMRI 画像に尤度を割り当てることで，ベイズ則を用いることで診断する．

表 1: Conceptual Comparison Between Our Proposed Model and Comparative Models

Model	説明可能性	動的	柔軟性
PCC	✓		
HMM	✓	✓	
LSTM		✓	✓
DGM	✓		✓
DSSM (proposed)	✓	✓	✓

本研究では，統合失調症と双極性障害の fMRI データを用いて実験を行い，DSSM を評価した．この実験では，提案した DSSM が，従来手法 [Shen 10, Yahata 16, Suk 16, Dvornek 17, Tashiro 17] よりも良い精度の診断を達成することを示す．

2. Deep State-Space Model

いくつかの先行研究では，確率的グラフィカルモデルに基づく診断手順を共通している [Suk 16, Tashiro 17, Matsubara 17]．確率的グラフィカルモデルは，可視変数 $\boldsymbol{x}$, y, と潜在変数 $\boldsymbol{z}$ の同時確率 $p_\theta(\boldsymbol{x}, y, \boldsymbol{z})$ で定義される．ここでは，可視変数 $\boldsymbol{x} = (x_1, x_2, x_3 \ldots, x_T)$ は，連続的な fMRI 画像を，x_t は，時刻 t でのスキャンをそれぞれ表す．y は 2 値データで，患者の状態 ($y = 1$ は陽性，$y = 0$ は陰性) を表す．潜在変数 $\boldsymbol{z} = (z_1, z_2, z_3, \ldots, z_T)$ は，状態 y が与えられたときに fMRI 画像 $\boldsymbol{x}$ を生成する内部メカニズムとなるような内部状態を表す．内部状態 $\boldsymbol{z}$ は，感情や思考などの，患者の時間的状態を表しているとみなされる．内部状態 $\boldsymbol{z}$ は，不可観測なので以下のように周辺化して扱う．

$$p_\theta(\boldsymbol{x}, y) = \int_z p_\theta(\boldsymbol{x}, y, \boldsymbol{z})$$

確率的グラフィカルモデルは，サンプル $(\boldsymbol{x}, y)$ が与えられ

連絡先: 神戸大学 大学院システム情報学研究科 計算科学専攻
E-mail: kusano@ai.cs.kobe-u.ac.jp

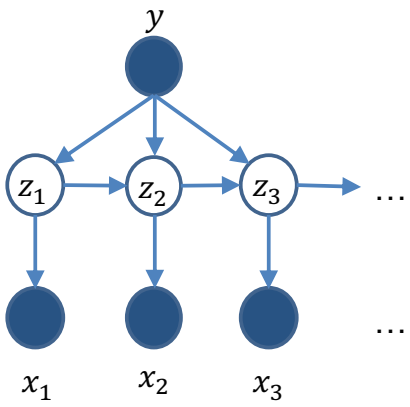


図 1: 提案した DSSM p_θ のグラフィカルモデル．$\boldsymbol{x} = (x_1, x_2, x_3, \dots)$ は連続した fMRI 画像を，y は状態を，$\boldsymbol{z} = (z_1, z_2, z_3, \dots)$ は内部状態を，それぞれ表す．

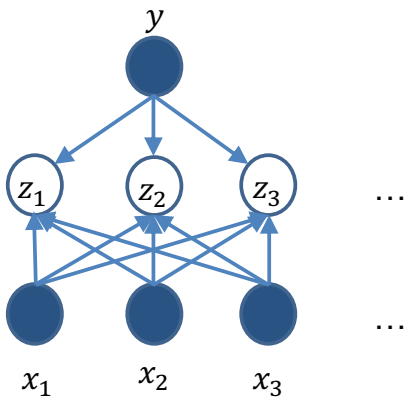


図 2: 推論 q_ϕ のグラフィカルモデル．$\boldsymbol{x} = (x_1, x_2, x_3, \dots)$ は連続した fMRI 画像を，y は状態を，$\boldsymbol{z} = (z_1, z_2, z_3, \dots)$ は内部状態を，それぞれ表す．

たときにモデル p_θ から生成される対数尤度 $\log p_\theta(\boldsymbol{x}, y)$ を最大化するように訓練される．まだ y を与えられてない患者 $\boldsymbol{x}$ について考えてみると，ベイズ則を使用して，患者の状態 y の事後確率を取得できる．

$$p_\theta(y|\boldsymbol{x}) = \frac{p_\theta(\boldsymbol{x}, y)}{\sum_{y' \in \{0,1\}} p_\theta(\boldsymbol{x}, y')} \propto p_\theta(\boldsymbol{x}, y)$$

患者の fMRI 画像 $\boldsymbol{x}$ について，状態を仮定して $(y = 0, 1)$ 尤度を比較することで診断する．患者の fMRI 画像 $\boldsymbol{x}$ について，$p_\theta(\boldsymbol{x}, y = 1) > p_\theta(\boldsymbol{x}, y = 0)$ なら $y = 1$，$p_\theta(\boldsymbol{x}, y = 0) > p_\theta(\boldsymbol{x}, y = 1)$ なら $y = 0$ と診断する．

DSSM は連続した fMRI 画像のあらゆるフォーマットに対して適用可能である．そのため，各画像 x_t は，3D，2D，k-space 画像，ボクセルのベクトル，関心領域 (region of interest; ROI) の特徴ベクトルや他の抽出した特徴でもよい．

計算リソースの制限や，過学習の回避のため，多くの先行研究が ROI の特徴ベクトルを扱ってきた [Shen 10, Suk 16, Plis 14, Yahata 16, Castro 16, Dvornek 17, Tashiro 17, Matsubara 17]．疾患に関係する ROI を特定することは，fMRI データに関する研究の主目的の一つである．そのため，これ以降は fMRI 画像 $\boldsymbol{x}$ として，連続した ROI の特徴ベクトルを使用する．

図 1, 2 において，黒丸は可視変数，白丸が潜在変数を表す．時刻 t における内部状態を z_t と表す．状態 y が与えられたときに，内部状態 z_{t-1} が次の内部状態 z_t に推移する (transition model $p_\theta(z_t|z_{t-1}, y)$)．内部状態 z_t が与えられたとき，fMRI 画像 x_t を生成する (emission model $p_\theta(x_t|z_t)$)．これは AutoEncoder における decoder に一致する．同時確率 $p_\theta(\boldsymbol{x}, y, \boldsymbol{z})$ は以下のように表される．

$$p_\theta(\boldsymbol{x}, y, \boldsymbol{z}) = p_\theta(y) p_\theta(z_1|y) \prod_{t=2}^{T} p_\theta(z_t|z_{t-1}, y) p_\theta(x_t|z_t) \quad (1)$$

transition model $p_\theta(z_t|z_{t-1}, y)$ と emission model $p_\theta(x_t|z_t)$ は DNN を使って実装することで，高い柔軟性をもたせた．変分推論 [Kingma 14, Tashiro 17, Matsubara 17, Krishnan 17] を用いるため，[Krishnan 17] のような推論モデル q_ϕ を設計し，図 2 に示すように以下の平均場近似を採用した．

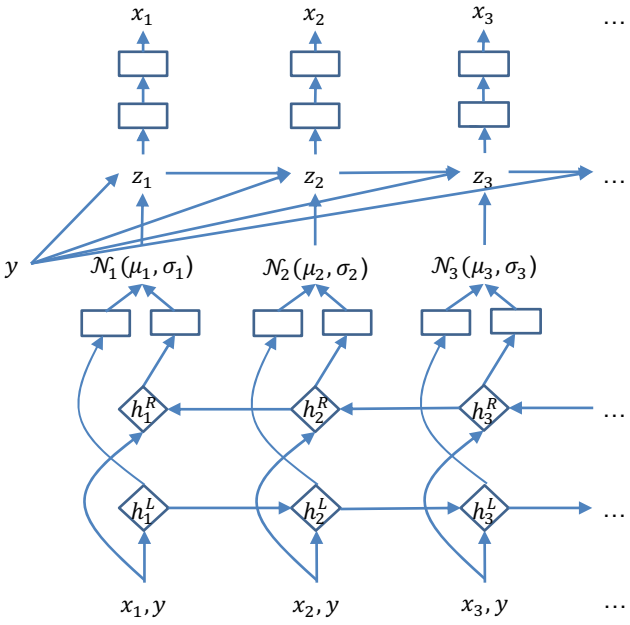


図 3: DSSM の実装イメージ図．

$$q_\phi(\boldsymbol{z}|\boldsymbol{x}, y) = \prod_{t=1}^{T} q_\phi(z_t|\boldsymbol{x}, y) \quad (2)$$

これらのモデルを使うことで，モデルエビデンスと呼ばれる可視変数 $\boldsymbol{x}, y$ の対数尤度 $\log p_\theta(\boldsymbol{x}, y)$ は以下のように表される．

$$\begin{aligned}
&\log p_\theta(\boldsymbol{x}, y) \geq \mathbb{E}_{q_\phi(\boldsymbol{z}|\boldsymbol{x}, y)} \left[\log \frac{p_\theta(\boldsymbol{x}, y, \boldsymbol{z})}{q_\phi(\boldsymbol{z}|\boldsymbol{x}, y)} \right] \\
&= \textstyle\sum_{t=1}^{T} \mathbb{E}_{q_\phi(z_t|\boldsymbol{x}, y)} \left[\log p_\theta(x_t|z_t) \right] \\
&\quad - \textstyle\sum_{t=2}^{T} \mathbb{E}_{q_\phi(z_{t-1}|\boldsymbol{x}, y)} \left[D_{KL}(q_\phi(z_t|\boldsymbol{x}, y) || p_\theta(z_t|z_{t-1}, y)) \right] \\
&\quad - D_{KL}(q_\phi(z_1|\boldsymbol{x}, y) || p_\theta(z_1|y)) + \log p_\theta(y) \\
&=: \mathcal{L}_g(\boldsymbol{x}, y).
\end{aligned} \quad (3)$$

モデルエビデンスの下界 $\mathcal{L}_g(\boldsymbol{x}, y)$ を，目的関数とし，最大化する．$\mathcal{L}_g(\boldsymbol{x}, y)$ は，$\log p_\theta(\boldsymbol{x}, y)$ に収束すると考えられている [Blei

表 2: Diagnosis Accuracies

	Schizophrenia		Bipolar	
Model	**BACC**	**F1**	**BACC**	**F1**
PCC+SCCA+SLR [Yahata 16]	0.646	0.462	0.519	0.378
PCC+Kendall+LLE+c-means [Shen 10]	0.670	0.544	0.626	0.480
LSTM [Dvornek 17]	0.673	0.522	0.577	0.345
AE+HMM [Suk 16]	0.579	0.429	0.589	0.417
DGM [Tashiro 17]	0.707	0.571	**0.633**	0.445
DSSM (proposed)	**0.728**	**0.601**	**0.633**	**0.481**

表 3: Regions with Top 3 and Bottom 3 Contribution Weights for Diagnosis.

Schizophrenia		Bipolar	
ROI	weight ($\times 10^{-4}$)	ROI	weight ($\times 10^{-4}$)
Postcentral_R	3.08	Temporal_Inf_R	1.49
Precentral_R	3.00	Cingulum_Post_R	1.14
Postcentral_L	2.81	Postcentral_R	1.01
⋮	⋮	⋮	⋮
Putamen_L	0.04	Cerebelum_7b_L	-0.26
Temporal_Pole_Sup_R	0.02	Cerebelum_Crus1_L	-0.28
Vermis_1_2	-0.02	Cingulum_Ant_R	-0.32

17, Bishop 06] ので，$\log p_\theta(\boldsymbol{x}, y)$ の代わりに使用される．患者の状態 y の事後分布 $p_\theta(y|\boldsymbol{x})$ は以下のように近似される．

$$\begin{aligned} p_\theta(y|\boldsymbol{x}) &= \frac{p_\theta(\boldsymbol{x}, y)}{\sum_{y' \in \{0,1\}} p_\theta(\boldsymbol{x}, y')} \\ &\approx \frac{\exp \mathcal{L}_g(\boldsymbol{x}, y)}{\sum_{y' \in \{0,1\}} \exp \mathcal{L}_g(\boldsymbol{x}, y')} \\ &= \exp \mathcal{L}_d(\boldsymbol{x}, y) \end{aligned} \tag{4}$$

加えて，$\mathcal{L}_d(\boldsymbol{x}, y)$ は，状態 y の対数尤度 $\log p_\theta(y|\boldsymbol{x})$ の近似であり，クラス分類を進めるような代わりの目的関数になる [Lasserre 06]．以下のように定数 $\omega \in [0, 1]$ を使って，目的関数のバランスをとる．

$$\mathcal{L}(\boldsymbol{x}, y) = (1 - \omega)\mathcal{L}_g(\boldsymbol{x}, y) + \omega \mathcal{L}_d(\boldsymbol{x}, y) \tag{5}$$

実装イメージは，図 3 に示す．

[Tashiro 17] のように，emission model $p_\theta(x_t|z_t)$ は，隠れ層が 2 層のニューラルネットワークを採用した．基本的に各隠れ層には，layer normalization を行い [Ba 16]，活性化関数には ReLU を用いた [Nair 10]．emission model $p_\theta(x_t|z_t)$ は，*reparameterization trick* [Kingma 14] を使って，x_t の事後分布 $\mathcal{N}(\mu_{z_t}, \mathrm{diag}(\sigma^2_{z_t}))$ を出力する．

transition model $p_\theta(z_t|z_{t-1}, y)$ には， [Krishnan 17] の提案した DNN ベースの gated transition を用いた．これにより，gated recurrent unit(GRU) と同様に， 各次元とステップに対して線形，非線形な遷移を調整できる柔軟性をもたせている．ここでは [Krishnan 17] とは異なり，状態 y と前内部状態 z_{t-1} の組を扱う実装にし，事後分布 $p_\theta(z_t|z_{t-1}, y)$ のパラメータを出力した．

推論モデル $q_\phi(\boldsymbol{z}|\boldsymbol{x}, y)$ は，bidirectional LSTM [Hochreiter 97, Schuster 97] で実装した．bidirectional LSTM は，順方向と逆方向の出力をもち，出力された順方向と逆方向の分布 $q^{(f)}_\phi(z_t|\boldsymbol{x}, y)$，$q^{(b)}_\phi(z_t|\boldsymbol{x}, y)$ から計算し，事後分布 $q_\phi(z_t|\boldsymbol{x}, y) \propto q^{(f)}_\phi(z_t|\boldsymbol{x}, y) \times q^{(b)}_\phi(z_t|\boldsymbol{x}, y)$ を得る．これにより，Eq. (3) の Kullback-Leibler 距離 $D_{KL}(q_\phi(z_t|\boldsymbol{x}, y)||p_\theta(z_t|z_{t-1}, y)$ が計算できる，

3. 実験

本実験で用いたデータセットは，OpenfMRI データベースの ds000030 (`https://openfmri.org/dataset/ds000030/`) から得た，前処理済み [Esteban 18](`https://github.com/poldracklab/fmriprep`) データである．このデータに scrubbing を行った後に，automated anatomical labeling (AAL) [Tzourio-Mazoyer 02] を使用し，各 ROI 領域におけるボクセル強度を平均化することで，fMRI 画像を 116 の ROI に分割し，ROI の特徴ベクトルを得た．最後に各時間の ROI 強度を．0.01Hz から 0.1Hz の周波数帯になるようにバンドパスフィルタを通して，それを平均 0，分散 1 になるように正規化を施した．それにより，最終的に健常者 117 人，統合失調症患者 48 人，双極性障害患者 46 人を使用した．

DSSM の各隠れ層は n_h 個の隠れユニットを持ち，内部状態 z_t は，n_z 次元である．各重みは $\mathcal{N}(0, 0.02^2)$ からのサンプル，各バイアスは 0 で初期化した．入力層には，dropout 率 p で dropout を行った．3 つのモデル全ての学習には，学習率は 10^{-4} その他は初期パラメータの Adam アルゴリズム [Kingma 15] を使用した．$n_h \in \{100, 200, 400\}$, $n_z \in \{5, 10, 20, 50, 100\}$, $p \in \{0.0, 0.5\}$，$\omega \in \{0.0, 0.9, 0.95, 0.99\}$ の範囲でハイパーパラメータを探索した．また，データのクラスの偏りを調整する

ために oversampling を行って学習した．比較手法と，その探索パラメータは [Tashiro 17] と同様である．

4. 結果

実験結果を，表 2 に示す．なお，10-fold cross-validation を 5 回行った平均値を用いて精度を評価している．また，データセットに偏りがあることを考慮して，accuracy ではなく balanced accuracy(BACC) で評価する．この結果は，表 1 に示した 3 つの特性によるものだと考えられる．更に詳しい解析は今後明らかにしていきたい．

クラスラベルを変えたときの再構成誤差の変化の大きさを計算することで，診断に特に寄与した ROI を調べることができる．具体的な計算方法は [Matsubara 17] と同様である．各 ROI の寄与度を求め，上位 3 位と下位 3 位の ROI を表 3 に示す．統合失調症の場合，上位 3 位の ROI の寄与度は大きな値で関係があることを，下位 3 位においてはほぼ 0 で関係がないことをそれぞれ示唆している．統合失調症に対する post-central と pre-central の関係は，いくつかの研究で言及されてきた [Tanskanen 10] が，統合失調症の研究の中ではそれほど一般的ではない [Glahn 08]．双極性障害の場合，上位 3 位の ROI の寄与度はそれほど大きくなく，偶然程度のレベルとはいえ下位 3 位は 0 もしくはわずかに負となった．この結果は，識別がまだ信頼に足りない可能性を示唆している．生成モデルを使って ROI の特徴の再構成誤差 (負の対数尤度 $-\mathbb{E}_{q_\phi(z_t|\boldsymbol{x},y)}[\log p_\theta(x_t|z_t)]$) に基づいて診断したが，これは，推論された内部状態と生成された内部状態 $\boldsymbol{z}$ の間の誤差である Kullback-Leibler 距離 $D_{KL}(q_\phi(z_t|\boldsymbol{x},y)||p_\theta(z_t|z_{t-1},y)$ にも依存する．DSSM の transition や推論モデルが豊かなために，内部状態が ROI 方向の特徴に対して優位をもつことが考えられる．内部状態 $\boldsymbol{z}$ に関する詳しい分析は今後明らかにしていきたい．

5. 結論

本研究では，精神疾患の診断のために構成した fMRI 画像の深層状態空間モデル (deep state-space model; DSSM) を提案した．DSSM は，動的な機能的接続を考慮して，fMRI 画像と疾患と時間変化する内部状態の同時確率をモデル化したものである．内部状態の動的モデルにより，DSSM は従来手法及び，比較手法よりも高い診断精度を示した．DSSM は疾患に関係のある脳状態を示唆し，潜在的な治療法の開発に役立つ可能性を示している．

本研究は総務省 SCOPE(受付番号 172107101) の委託を受けて行われた．

参考文献

[Atkinson 01] Atkinson, A. J. ,*et al.*:*Clinical Pharmacology and Therapeutics*, vol. 69, no. 3, pp. 89–95, (2001)

[Ba 16] Ba, J. L. *et al.*: Layer Normalization (2016)

[Bengio 12] Bengio, Y. *et al.*: *IEEE Transactions on Pattern Analysis and Machine Intelligence*, No. 1993, pp. 1–30 (2012)

[Bishop 06] Bishop, C. C. M. C.: Pattern recognition and machine learning, in *Springer*, Vol. 4, p. 738 (2006)

[Blei 17] Blei, D. M.*et al.*: *Journal of the American Statistical Association*, Vol. 112, No. 518, pp. 859–877 (2017)

[Castro 16] Castro, E. *et al.*: *IEEE Transaction on Medical Imaging*, Vol. 35, No. 7, pp. 1729–1740 (2016)

[Dvornek 17] Dvornek, N. C. *et al.*: *International Workshop on Machine Learning in Medical Imaging*, Vol. 10541, pp. 362–370 (2017)

[Esteban 18] Esteban, O. *et al.*: *bioRxiv*, pp. 1–20 (2018)

[Glahn 08] Glahn, D. C. *et al.*: *Biological Psychiatry*, Vol. 64, No. 9, pp. 774–781 (2008)

[Hochreiter 97] Hochreiter, S. *et al.*:*Neural Computation*, Vol. 9, No. 8, pp. 1735–1780 (1997)

[Kingma 14] Kingma, D. P. *et al.*: *International Conference on Learning Representations* (2014)

[Kingma 15] Kingma, D. P. *et al.*: *International Conference on Learning Representations* , pp. 1–15 (2015)

[Krishnan 17] Krishnan, R. G. *et al.*: in *AAAI Conference on Artificial Intelligence* , pp. 1–13 (2017)

[Lasserre 06] Lasserre, J. A. *et al.*: in *IEEE Computer Society Conference on Computer Vision and Pattern Recognition* , Vol. 1, pp. 87–94, IEEE (2006)

[Li 15] Li, X. *et al.*: *BioMed Research International*, Vol. 2015, (2015)

[Liu 13] Liu, X. *et al.*:*Proceedings of the National Academy of Sciences*, Vol. 110, No. 11, pp. 4392–4397 (2013)

[Matsubara 17] Matsubara, T. *et al.*: *arXiv* (2017)

[Nair 10] Nair, V. *et al.*: in *International Conference on Machine Learning*, pp. 807–814 (2010)

[Plis 14] Plis, S. M. *et al.*: *Frontiers in Neuroscience*, Vol. 8, No. Aug., pp. 1–11 (2014)

[Schmidhuber 15] Schmidhuber, J.: *Neural Networks*, Vol. 61, pp. 85–117 (2015)

[Schuster 97] Schuster, M. *et al.*: *IEEE Transactions on Signal Processing*, Vol. 45, No. 11, pp. 2673–2681 (1997)

[Shen 10] Shen, H. *et al.*: *NeuroImage*, Vol. 49, No. 4, pp. 3110–3121 (2010)

[Suk 16] Suk, H. I. *et al.*: *NeuroImage*, Vol. 129, pp. 292–307 (2016)

[Tanskanen 10] Tanskanen, P. *et al.*: *Schizophrenia Bulletin*, Vol. 36, No. 4, pp. 766–777 (2010)

[Tashiro 17] Tashiro, T. *et al.*: *NOLTA*, pp. 700–703 (2017)

[Tzourio-Mazoyer 02] Tzourio-Mazoyer, N. *et al.*: *NeuroImage*, Vol. 15, No. 1, pp. 273–289 (2002)

[Yahata 16] Yahata, N. *et al.*: *Nature Communications*, Vol. 7, No. 7, p. 11254 (2016)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

半教師あり学習を用いた医療データにおける標的遺伝子の探索

Semi-supervised learning based target gene selection for medical data

関 爽人 *1 Akito Seki　秋田 大空 *1 Hirotaka Akita　鹿島 久嗣 *1*2 Hisashi Kashima　山田 誠 *1*2 Makoto Yamada

*1京都大学 Kyoto University　*2RIKEN AIP

A therapeutic method that controls disease progression by administering a drug which inhibits the function of a particular molecule is called molecularly targeted therapy. Since the number of genes which can be targeted in this method is quite large, it is impossible to verify all of them by human hands. Therefore, in this study, we see the task of finding new target genes as a problem of machine learning and propose a framework in order to solve this problem. In the experiment, we used three datasets and examined the proposed method. As a result, the method outperformed the baseline even when we used any dataset.

1. はじめに

ある特定の分子の働きを阻害することにより病気の進行を抑制する治療法は分子標的治療と呼ばれ、主にがん治療の分野で用いられている。医療データを用いて分子標的治療における新たな標的遺伝子を発見することは、その病気に対する新薬の開発に必要となる、極めて重要なタスクである。ただし、標的となり得る遺伝子の候補を人間の手で網羅的に検証するには、多くのコストと時間を要する。そのため新たな標的を発見するためにはまず、遺伝子の発現量に関するデータを用いて、治療において重要だと考えられる遺伝子を特定する必要がある。このような課題は、機械学習やデータマイニングの分野で長年研究されてきた、特徴選択の問題であると考えることができる。しかし、一般的に特徴選択を用いた手法は人間の知識を利用できないため、治療に重要な標的遺伝子を発見できない恐れがある。そこで、特徴選択で選んだ少数の遺伝子をケミカルスクリーニングなどによって人手で評価し、得られたデータを解析することで新たな標的遺伝子を発見することを考える。

本研究が提案するフレームワークについて以下に述べる。はじめに、遺伝子の発現量に関するデータセットに対して Hilbert-Schmidt Independence Criterion (以下、HSIC) Lasso [Yamada 14] を用いて特徴選択を行い、疾患の有無と強い関係を持っている遺伝子を選択する。この手法は医療データのような複雑なデータに対しても適用できる点、冗長な特徴量を排除できる点において優れている。次に、特徴選択の結果選ばれた遺伝子を、専門家がケミカルスクリーニングなどを用いて分析する。このステップにより、遺伝子の発現量データと、各遺伝子に対応するラベルから構成されるデータセットを得ることができる。最後に、このデータセットを用いて半教師あり学習を行う。本研究では、Virtual Adversarial Training (以下、VAT)[Miyato 18] という手法を用いる。これは、独自の正則化項を導入することによりネットワークの汎化性能を向上させる手法であり、半教師あり学習において優れた結果を示すことが知られている。学習を行ったのち、新たな標的遺伝子の予測を行う。具体的には、ラベル付けされていない各遺伝子に対して重要度を表すスコアを算出し、そのスコアが特に大きいものを新たな標的遺伝子の候補として扱うものとする。この予測の精度を評価するためには、候補となった遺伝子に対して再び専門家による評価を行い、各遺伝子が実際に標的遺伝子となるか否かを検証する必要がある。

本研究の主な貢献としては、専門家による評価を用いた、新たな標的遺伝子発見のためのフレームワークの構築を行ったこと、また、上記のフレームワークに基づいた半教師あり学習を提案し、実験によってその有効性について検証したことが挙げられる。また、VAT などの手法による半教師あり学習は一般的に分類問題に適用されており、我々の知る限りでは、半教師あり学習を用いて新たな標的遺伝子を探索する取り組みは初めてである。

本研究における実験では、ウェブ上に公開されている 3 つのデータセットを用いて、新たな標的遺伝子の予測精度について検証を行った。この実験においては、特徴選択によって得られた特徴量がすべて真の標的遺伝子であることを仮定し、これらの特徴量を半教師あり学習を用いて識別できるかを評価した。その結果、いずれのデータセットを用いた場合も、訓練データの数の大小に関わらず、提案手法がベースラインの性能を上回ることが示された。

2. 関連研究

Least absolute shrinkage and selection operator (以下、Lasso)[Tibshirani 96] は、L1 正則化を用いた回帰の代表的な手法である。L1 正則化は、モデルのパラメータを推定する際に使用されることで過学習を防ぎ、モデルの汎化性能を向上させる効果が期待できる。Lasso はスパース推定を行うため、特徴選択のアルゴリズムとしても一般的に使用されている。ただしこの手法には、特徴量の数を d、データ数を n で表すとき、$d > n$ ならば、高々n 個の特徴量しか選択できないという欠点があることが知られている。さらに、Lasso は線形手法であり、医療データのような複雑なデータでは重要な特徴量を選択できないという問題がある。

HSIC Lasso [Yamada 14] は、冗長性を排除した特徴選択を行える上に、大域的最適解を得ることができる手法である。また、この手法は非線形な特徴選択を行うため、複雑なデータを用いた際も重要な特徴量を選択できると考えられる。一方、HSIC Lasso によって特徴選択を行うだけでは人間の知識を利用できないため、専門家による評価も併用して行うことが必要となる。

半教師あり学習は、一般に少数の教師ありデータと多数の

教師なしデータから構成されるデータセットを用いて行われる学習を指す。このようなデータセットが多く存在する画像処理や情報検索、生命情報科学の分野において、半教師あり学習は広く適用されている [Chapelle 09]。

半教師あり学習において優れた結果を示す手法として、Miyato らによって考案された VAT [Miyato 18] がある。この手法は、教師ありデータと教師なしデータの両方を用いて計算される独自の正則化項を目的関数に導入することにより、ネットワークの汎化能力を向上させている。

3. 問題設定

まず、問題設定における表記法について述べる。本研究においては医療データ、特に遺伝子の発現量に関するデータを取り扱うことを想定している。この時、$\boldsymbol{x} = [x^{(1)}, x^{(2)}, \ldots, x^{(d)}]^{\mathrm{T}} \in \mathbb{R}^d$ を一人の被験者における各遺伝子の発現量を表すベクトル、$y \in \mathbb{R}$ を疾患の有無など被験者の状態を表すラベルであると考える。任意の行列 $\boldsymbol{A}$ に対して、$\boldsymbol{A}^{\mathrm{T}}$ は $\boldsymbol{A}$ の転置行列を表しているものとする。いま、互いに独立で同一の分布に従う n 組のデータが与えられていると仮定し、これを $\{(\boldsymbol{x}_i, y_i) | \boldsymbol{x}_i \in \mathcal{X}, y_i \in \mathcal{Y}, i = 1, \ldots, n\}$ と表す。上記の $\boldsymbol{x}$ を用いて、遺伝子データ全体を $\boldsymbol{X} = [\boldsymbol{x}_1, \boldsymbol{x}_2, \ldots, \boldsymbol{x}_n] \in \mathbb{R}^{d \times n}$ と表す。また、上記の y を用いて、被験者のラベル全体を $\boldsymbol{y} = [y_1, y_2, \ldots, y_n]^{\mathrm{T}} \in \mathbb{R}^n$ と表す。

本研究では、このような遺伝子データと被験者のラベルに加え、各特徴量に付与されたラベルについても情報を得ることができると仮定する。各ラベルを $t_i \in \{-1, 0, 1\}$ として定義し、t_i は専門家が行った分析の結果得られるラベルであるとする。値が 1 の場合はその特徴量が有効であることを表し、-1 の場合は有効でないことを表し、0 は有効であるかが不明であることを表している。また、$\boldsymbol{u} = [u^{(1)}, u^{(2)}, \ldots, u^{(n)}]^{\mathrm{T}} \in \mathbb{R}^n$ を各特徴量データとして定義すると、特徴量データとその特徴量に付与されたラベルの組 $\{(\boldsymbol{u}_j, t_j) | \boldsymbol{u}_j \in \mathcal{U}, t_j \in \mathcal{T}, i = 1, \ldots, d\}$ を得ることができる。具体的には、$\boldsymbol{u}$ は一つの遺伝子の各被験者における発現量を表すベクトルであり、t は遺伝子が標的であるか否かを表すラベルである。ただしラベル t については、専門家による分析を行った後にのみ利用することができるものとする。上記の t を用いて、各特徴量に対応するラベル全体を $\boldsymbol{t} = [t_1, t_2, \ldots, t_d]^{\mathrm{T}} \in \mathbb{R}^d$ と表す。また、上記の $\boldsymbol{u}$ を用いて、特徴量データ全体を $\boldsymbol{U} = [\boldsymbol{u}_1, \boldsymbol{u}_2, \ldots, \boldsymbol{u}_d] \in \mathbb{R}^{n \times d}$ と表すと、$\boldsymbol{X}^{\mathrm{T}} = \boldsymbol{U}$ が成立する。

本研究における入出力を以下に示す。

- 入力 : 遺伝子データ $\boldsymbol{X}$, 被験者のラベル $\boldsymbol{y}$, 特徴量データ $\boldsymbol{U}$, 特徴量のラベル $\boldsymbol{t}$
- 出力 : 有効であるか不明な遺伝子 $\boldsymbol{u}_j$ に対する、重要度を表すスコア $\hat{t}_j \in [0, 1]$

出力のスコアについては、その値が 1 に近いほど、その特徴量がより重要であると予測したことを表している。

4. 提案手法

本研究では、医療データにおける新たな標的遺伝子の発見を目的とした新たなフレームワークを提案する。これは大きく分けて、遺伝子データを用いた特徴選択、選択された特徴量に対する専門家による評価、半教師あり学習による新たな標的遺伝子の予測という 3 つのステップから構成される。これらについて、以下に詳細を述べる。

4.1 遺伝子データを用いた特徴選択

このステップにおける入力は、各被験者の遺伝子の発現量を記録したデータと、疾患の有無など各被験者の状態を表すラベルであり、それらの組を $\{(\boldsymbol{x}_i, y_i) | \boldsymbol{x}_i \in \mathcal{X}, y_i \in \mathcal{Y}, i = 1, \ldots, n\}$ と表す。このような入力を用いて、その疾患と強い関係がある特徴量を選択することをタスクとする。ここで、第 2 ステップの専門家による評価においては、検査できる遺伝子の数が限られているため、不要で冗長な特徴量を可能な限り排除した選択を行うことが求められる。また、遺伝子の発現量データは複雑であるという特徴がある。これらの条件を考慮し、非線形な特徴選択を行う最先端のアルゴリズムとして知られる HSIC Lasso [Yamada 14] を用いる。

まず、HSIC Lasso における最適化問題を以下に示す。

$$\min_{\boldsymbol{\alpha} \in \mathbb{R}^d} ||\widetilde{\boldsymbol{L}} - \sum_{k=1}^{d} \alpha_k \widetilde{\boldsymbol{K}}^{(k)}||_F^2 + \lambda ||\boldsymbol{\alpha}||_1, \quad s.t. \quad \alpha_1, \ldots, \alpha_d \geq 0 \quad (1)$$

$\lambda \geq 0$ は正則化項の係数を表すパラメータである。$||\cdot||_1$ は L1 ノルム、$||\cdot||_F$ はフロベニウスノルム ($||\boldsymbol{A}||_F = \sqrt{\mathrm{tr}(\boldsymbol{A}\boldsymbol{A}^{\mathrm{T}})}$) を表し、$\widetilde{\boldsymbol{K}}$ と $\widetilde{\boldsymbol{L}}$ はそれぞれ、以下の式で与えられる行列を表している。

$$\widetilde{\boldsymbol{K}} = \frac{\boldsymbol{HKH}}{||\boldsymbol{HKH}||_F}, \quad \widetilde{\boldsymbol{L}} = \frac{\boldsymbol{HLH}}{||\boldsymbol{HLH}||_F} \quad (2)$$

$\boldsymbol{K}$ と $\boldsymbol{L}$ はそれぞれ、遺伝子データとラベルに関するグラム行列を表し、$\boldsymbol{H} = \boldsymbol{I} - \frac{1}{n}\boldsymbol{1}\boldsymbol{1}^{\mathrm{T}}$ は中心化行列である。$\boldsymbol{I}$ は単位行列であり、$\boldsymbol{1}$ は全ての要素が 1 である正方行列を表している。式 (2) 及び $\boldsymbol{H}$ の性質より、$\widetilde{\boldsymbol{K}}$ と $\widetilde{\boldsymbol{L}}$ は以下のような性質を持つ。

$$\boldsymbol{1}_n^{\mathrm{T}} \widetilde{\boldsymbol{K}} \boldsymbol{1}_n = \boldsymbol{1}_n^{\mathrm{T}} \widetilde{\boldsymbol{L}} \boldsymbol{1}_n = 0 \quad (3)$$

$$||\widetilde{\boldsymbol{K}}||_F^2 = ||\widetilde{\boldsymbol{L}}||_F^2 = 1 \quad (4)$$

4.2 選択された特徴量に対する専門家の評価

まず、第 1 ステップで選択された特徴量に対する評価を専門家に依頼する。具体的には、各遺伝子に対して、それが標的として有効であると判明すればラベルの値を 1 に設定し、逆に有効ではないと判明すればラベルを -1 に設定する。このような検査には多くのコストと時間を要するため、検査できる遺伝子の数が限られているという制約がある。

4.3 半教師あり学習による新たな標的遺伝子の予測

第 2 ステップの結果得られたデータ $\{(\boldsymbol{u}_j, t_j)_{j=1}^d\}$ を入力とする。$\boldsymbol{u}_j$ は遺伝子の各被験者における発現量を表す。$t_j \in \{-1, 0, 1\}$ は各遺伝子に対応するラベルであり、評価を行わなかった遺伝子には 0 が付与されている。このステップでは、半教師あり学習において優れた結果を示す VAT [Miyato 18] を用いる。VAT は、独自の正則化項を導入することによりネットワークの汎化性能が向上させる手法であり、パラメータの更新を繰り返して学習を行う。この手法について以下に述べる。

まず、Local Distributional Smoothness (以下、LDS) という関数を、入力データ $\boldsymbol{u}$ とパラメータ $\boldsymbol{\theta}$ について、以下のように定義する。

$$LDS(\boldsymbol{u}, \boldsymbol{\theta}) := D[p(t|\boldsymbol{u}, \hat{\boldsymbol{\theta}}), p(t|\boldsymbol{u} + r_{vadv}, \boldsymbol{\theta})] \quad (5)$$

t は出力ラベル、$\hat{\boldsymbol{\theta}}$ は現在のパラメータの値を表し、$p(t|\boldsymbol{u}, \boldsymbol{\theta})$ は事後分布を表す。$D[p, p']$ は、2 つの分布 p と p' の差異を計る尺度を表しているが、本研究では D としてクロスエントロ

ピーを用いる。また、式 (5) で用いられている r_{vadv} は、以下の形で定義される。

$$r_{vadv} := \arg\max_{r;||r||_2 \leq \epsilon} D[p(t|\boldsymbol{u}, \hat{\boldsymbol{\theta}}), p(t|\boldsymbol{u}+r, \hat{\boldsymbol{\theta}})] \tag{6}$$

ϵ はハイパーパラメータであり、$||\cdot||_2$ は L2 ノルムを表している。この設定のもとで、r_{vadv} は、2 つの分布 $p(t|\boldsymbol{u}, \hat{\boldsymbol{\theta}})$ と $p(t|\boldsymbol{u}+r, \hat{\boldsymbol{\theta}})$ の差異がもっとも大きくなる時の摂動 r を表し、LDS は、入力データ $\boldsymbol{u}$ 周辺での事後分布の滑らかさを表している。

次に、式 (5) で定義された LDS を用いて正則化項 R_{vadv} を定義する。

$$R_{vadv}(\boldsymbol{\theta}) := \frac{1}{N_l + N_{ul}} \sum_{\boldsymbol{u} \in \mathcal{U}_l, \mathcal{U}_{ul}} LDS(\boldsymbol{u}, \boldsymbol{\theta}) \tag{7}$$

ここで N_l は、専門家による評価の結果ラベル付けされたデータ、つまり、ラベルの値が 1 もしくは -1 であるデータの数を表している。一方 N_{ul} は、専門家による評価を行わなかったデータ、つまり、ラベルの値が 0 であるデータの数を表している。最後に、式 (7) で定義された R_{vadv} を用いて、目的関数全体を以下のように表す。

$$\frac{1}{N_l} \sum_{(t,\boldsymbol{u}) \in \mathcal{T} \times \mathcal{U}_l} \ell(t, f(\boldsymbol{u}, \boldsymbol{\theta})) + \alpha R_{vadv}(\boldsymbol{\theta}) \tag{8}$$

$f(\boldsymbol{u}, \boldsymbol{\theta})$ は、θ をパラメータとして用いるモデルを表しており、α はハイパーパラメータである。$\ell(t, f(\boldsymbol{u}, \boldsymbol{\theta}))$ は、ラベルありデータについての負の対数尤度を表す。ここで、式 (8) を最小化するように学習を行うことを考えると、この問題は誤差逆伝播 [Rumelhart 86] によって効率的に最適化を行うことができる。学習が終了したのち、モデル $f(\boldsymbol{u}, \boldsymbol{\theta})$ を用いて新たな標的遺伝子の予測を行う。この際、専門家による評価を行わなかった各遺伝子に対して、重要度を表すスコアを算出する。スコアの値は 0 以上 1 以下であるとし、その値が 1 に近いほどその遺伝子がより重要であると予測したことを表している。最後に、これらの遺伝子のうち、スコアが特に大きいものを新たな標的遺伝子として考える。

5. 評価実験

5.1 実験概要

本研究が提案するフレームワークでは、遺伝子の発現量に関するデータを用いて特徴選択を行い、選択された遺伝子に対する専門家の評価によって、それらの遺伝子にラベル付けを行っている。しかし本研究の実験では、専門家による評価を実際に行うことはできなかったため、以下のような方法を用いている。

まず、特徴選択の結果選ばれたすべての遺伝子に対してラベルの値を 1 に設定する。そして、特徴選択の際選ばれなかった遺伝子に対してはラベルの値を -1 に設定する。したがって、各遺伝子に対して与えられるラベルは疑似ラベルとなる。このように、すべての遺伝子に対するラベル付けを行った上で、ラベルの値が 1 であるデータとラベルの値が -1 であるデータをそれぞれ同数選択し、これらを訓練データとして用いる。一方、訓練データとして選択されなかったデータは全て、テストデータとして用いる。ただしモデルの訓練の際、テストデータのラベル情報は利用できないが、これらを教師なしデータとして利用することはできるものとする。

5.1.1 実験設定

はじめに、入力として与えられるデータセットに対して特徴選択を行うが、第 3 章で述べたように HSIC Lasso [Yamada 14] を用いる。その後、先に述べた方法で各遺伝子にラベルを付与し、訓練データとテストデータに分割する。次に、訓練データとラベル情報を取り除いたテストデータを用いてモデルの学習を行う。最後に、テストデータを用いてモデルの性能を測定する。訓練データとテストデータの分割については偏りが生じる恐れがあるため、データの分割を変えながらテストを 10 回行うものとする。

半教師あり学習におけるモデルとして、4 層のニューラルネットワークを用いる。提案手法とベースラインにおいては共通したネットワークを用いるものとする。ニューラルネットワークの入力層のユニット数は、各実験における被験者の数と等しいものとし、2 つある隠れ層のユニット数は 100、出力層のユニット数は 2 とする。出力層における活性化関数としては softmax 関数を用い、その他の層における活性化関数としては ReLU [Glorot 11] を用いた。また、ネットワークの最適化手法として確率的勾配降下法を使用した.

5.1.2 ベースライン

本項では、ベースラインとして用いる手法について述べる。入力として与えられるデータセットに対する特徴選択や、各遺伝子へのラベル付けの方法などはすべて、提案手法と同様に行われるものとする。前節でも述べたように、新たな標的遺伝子を予測するための学習の際に、モデルとして用いるニューラルネットワークについても同様である。提案手法と異なるのは、学習を行う際に用いられる目的関数である。その関数は以下の形で与えられる。

$$\frac{1}{N_l} \sum_{(t,\boldsymbol{u}) \in \mathcal{T} \times \mathcal{U}_l} \ell(t, f(\boldsymbol{u}, \boldsymbol{\theta})) \tag{9}$$

5.1.3 評価指標

本実験では正例と負例の数に偏りがあるデータが使用されるため、評価指標は ROC 曲線の AUC を用いる。

5.2 データセット

本研究が提案するフレームワークの有効性を検証するため、3 つのデータセットを用いて実験を行う。実験において用いる 3 つのデータセットは全て、FEATURE SELECTION DATASETS[*1] に公開されているものである。これらについて簡単に述べる。leukemia データセットは、各被験者の遺伝子の発現量を 3 値化したデータと、各被験者が患者であるか否かを表す二値のラベルからなる。発現量は $-2, 0, 2$ のいずれかとして与えられている。72 人の被験者のうち、患者である 25 人を正例として扱い、残りの 47 人を負例として扱う。発現量のデータが存在する遺伝子の数は 7,070 個である。Prostate_GE データセットは、各被験者の遺伝子の発現量を表したデータと、各被験者が患者であるか否かを表す二値のラベルからなる。102 人の被験者のうち、患者である 50 人を正例として扱い、残りの 52 人を負例として扱う。発現量のデータが存在する遺伝子の数は 5,966 個である。TOX_171 データセットは、各被験者の遺伝子の発現量を表したデータと、各被験者の状態を表す 4 値のラベルからなる。各クラスを構成する被験者の数はそれぞれ、39 人、42 人、45 人、45 人であり、その総数は 171 人である。発現量のデータが存在する遺伝子の数は 5,748 個である。

*1 http://featureselection.asu.edu/datasets.php#

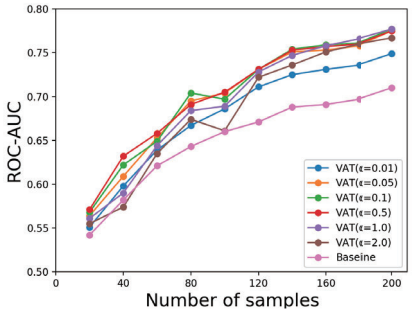


図 1: leukemia データを用いた実験の結果

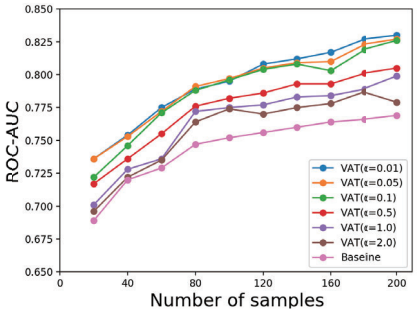


図 2: Prostate_GE を用いた実験の結果

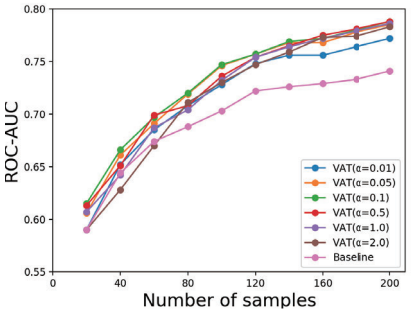


図 3: TOX_171 を用いた実験の結果

5.3 実験結果

まず、leukemia データセットを用いた実験の結果について述べる。特徴選択を行った結果、7,070 個の特徴量のうち 604 個が選択され、それらのラベルの値は 1 に設定された。このデータを用いて提案手法とベースラインの性能を評価したものを図 1 に示す。次に、Prostate_GE データセットを用いた実験の結果について述べる。特徴選択を行った結果、5,966 個の特徴量のうち 398 個が選択され、それらのラベルの値は 1 に設定された。このデータを用いて提案手法とベースラインの性能を評価したものを図 2 に示す。最後に、TOX_171 データセットを用いた実験の結果について述べる。特徴選択を行った結果、5,748 個の特徴量のうち 564 個が選択され、それらのラベルの値は 1 に設定された。このデータを用いて提案手法とベースラインの性能を評価したものを図 3 に示す。

以上のように、いずれのデータセットを用いた場合も、提案手法はベースラインを上回る結果を示した。特に Prostate_GE データセットを用いた実験においては、提案手法がベースラインを下回ることが一度もない点、また、他のデータセットを用いた場合と比較して提案手法の ROC 曲線の AUC が一貫して高い値を取る点において、提案手法の有効性が示された。一方で、用いたデータセットによって提案手法が高い性能を示す時のパラメータ α の値が異なったため、各データセットに適した値をチューニングによって検証する必要があると感じた。

6. むすび

本研究では、ある疾患における新たな標的遺伝子を発見することを目的とした新たなフレームワークを提案した。実験においては、3 つの遺伝子の発現量に関するデータセットを用いて提案手法の性能をベースラインと比較し、提案手法の有効性について検証した。

一方、本研究の課題としては、実験において専門家による評価を行えなかったこと、またこれに関連して、実際に専門家による評価を運用した際の提案手法の有効性を示せなかったことが挙げられる。今後は、専門家による協力のもと提案手法を用いた実験を行い、新たな標的遺伝子を発見することを目標としたい。また今回の実験では、ハイパーパラメータのチューニングをせず、目的関数における正則化項の係数 α のみ値を変えながら実験を行った。本来は教師ありデータを訓練データ、検証データ、テストデータの 3 つに分割して実験を行うべきであるが、そのためには、少数の教師ありデータを有効に活用するための工夫が必要となるため、これを今後の課題としたい。

また、本研究が提案したフレームワークを拡張として、フレームワークの第 2 ステップと第 3 ステップを交互に繰り返し、新たな標的遺伝子の探索を何度も行うというものが考えられる。このような拡張を行うと、半教師あり学習によって重要度が高いと考えられる遺伝子を得たのち、再度専門家による評価を行えるので、これらの遺伝子を新たな教師ありデータとして用いることができる。したがって、標的遺伝子の探索の精度を向上させることができると考えられる。一方で、専門家による評価を繰り返すことで実験にかかる費用が増大するため、反復回数をできる限り少なく抑えることが重要となる。

参考文献

[Chapelle 09] Chapelle, O., Scholkopf, B., and Zien, A.: Semi-supervised learning (chapelle, o. et al., eds.; 2006)[book reviews], *IEEE Transactions on Neural Networks*, Vol. 20, No. 3, pp. 542–542 (2009)

[Glorot 11] Glorot, X., Bordes, A., and Bengio, Y.: Deep sparse rectifier neural networks, *Proceedings of the fourteenth international conference on artificial intelligence and statistics*, pp. 315–323 (2011)

[Miyato 18] Miyato, T., Maeda, S., Ishii, S., and Koyama, M.: Virtual adversarial training: a regularization method for supervised and semi-supervised learning, *IEEE transactions on pattern analysis and machine intelligence* (2018)

[Rumelhart 86] Rumelhart, D. E., Hinton, G. E., and Williams, R. J.: Learning representations by back-propagating errors, *nature*, Vol. 323, No. 6088, p. 533 (1986)

[Tibshirani 96] Tibshirani, R.: Regression shrinkage and selection via the lasso, *Journal of the Royal Statistical Society. Series B (Methodological)*, pp. 267–288 (1996)

[Yamada 14] Yamada, M., Jitkrittum, W., Sigal, L., Xing, E. P., and Sugiyama, M.: High-dimensional feature selection by feature-wise kernelized lasso, *Neural computation*, Vol. 26, No. 1, pp. 185–207 (2014)

General Session | General Session | [GS] J-2 Machine learning

[2Q1-J-2] Machine learning: models for prediction

Chair:Koh Takeuchi Reviewer:Hikaru Kajino

Wed. Jun 5, 2019 9:00 AM - 10:40 AM Room Q (6F Meeting room, Bandaijima bldg.)

[2Q1-J-2-01] The Cox hazard model using Factorization Machines

○Kanata Satake[1], Makoto Yamada[1,2], Kota Matsui[2], Shigeyuki Matsui[2,3], Hisashi Kashima[1,2]
（1. Kyoto University, 2. RIKEN Center, 3. Nagoya University）

9:00 AM - 9:20 AM

[2Q1-J-2-02] LTV Prediction Based on RFM and Customer Characteristics

○Yusaku Imai[1], Yuki Tajima[1] （1. Dentsu Digital Inc.）

9:20 AM - 9:40 AM

[2Q1-J-2-03] Study on the relationship between data non-linearity and dam inflow discharge prediction accuracy

○Masazumi Amakata[1], Takuto Yasuno[1], Junichiro Fujii[1], Yuri Shimamoto[1], Junichi Okubo[1]
（1. Yachiyo Engineering Co.,Ltd.）

9:40 AM - 10:00 AM

[2Q1-J-2-04] Comparison of Deep Time Series Prediction Models Utilizing Linear Regression Model

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

10:00 AM - 10:20 AM

[2Q1-J-2-05] The Effects of Element and Input Length on Accuracy in Aquaculture Seawater Temperature Prediction Model

○Masahito Okuno[1], Takanobu Otsuka[1] （1. Nagoya Institute of Technology）

10:20 AM - 10:40 AM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

Factorization Machinesを用いたCoxハザードモデル

The Cox hazard model using Factorization Machines

佐竹 哉太 *1 Kanata Satake　山田 誠 *1*2 Makoto Yamada　松井 孝太 *2 Kota Matsui　松井 茂之 *2*3 Shigeyuki Matsui　鹿島 久嗣 *1*2 Hisashi Kashima

*1京都大学 Kyoto University　*2理化学研究所 RIKEN Center　*3名古屋大学 Nagoya University

Survival analysis is an approach to analyze the time until the occurrence of an event of interest. In many cases, the Cox proportional hazard model is the most popular regression method without specifying the underlying time-to-event distribution. However, it can only use linear information of features. In this research, we introduce the factorization machines (FM) to the Cox hazard model. In contrast to the previous models, The proposed model can use the interaction between covariates and retain interpretability. The experiments using a medical dataset show that our model yields better performance than baseline models.

1. はじめに

ある出来事が起こるまでの時間を分析する問題は、多くの分野で共通する重要な問題である。このイベントが起こるまでの時間である生存時間を推定する手法として、生存時間解析がある。一般に生存時間解析では、ある瞬間にイベントが生じる可能性をハザード関数 $h(t)$ として定義し、それをもとに時刻 t 以上生存する確率である生存関数 $S(t)$、時刻 t までに死亡する確率である死亡関数 $F(t)$ を求める。イベントの振る舞いが詳細に分かっていない場合には、モデルの一部のみを定義するセミパラメトリックな手法が用いられることが多い。例えば医療分野では個別の病気に関するデータが十分ではない場合が多いため、セミパラメトリックな手法がよく用いられる。

生存時間解析のセミパラメトリックなモデルのうち、最もよく用いられるものに Cox 比例ハザードモデル [Cox 72] がある。Cox 比例ハザードモデルは、2 つのサンプルのハザード関数の比であるハザード比が時間に依存しないという重要な性質をもつ。またモデルに対して対数をとると線形になるという対数線形性を仮定したモデルで、時間 t による変化は定義しない。Cox 比例ハザードモデルは対数線形性を持つため、各特徴量のモデルに対する貢献を解釈することができる。しかし一方で非線形の情報を利用することはできない。後述するカーネル法を用いたモデルでは特徴間の非線形な情報を利用できるよう工夫されている [Li 02] が、それらのモデルでは解釈性が失われるという問題がある。そこで本論文では、非線形性を利用でき解釈も可能なモデルについて考察した。

本研究の貢献は以下の通りである。

- Cox 比例ハザードモデルに FM を導入し、解釈性を保ったまま特徴間の相互作用を利用できるモデルを提案した。
- FM による提案手法が実際の医療データに対し既存手法よりも良い精度を示すことを確認した。

2. 関連研究

Cox 比例ハザードモデルにおいて非線形な情報を利用した例としては、Li と Luan が Cox モデルにカーネル法を適用した研究がある [Li 02]。この論文では高次元データから p 値をもとに特徴を選択し、モデルを構築している。このモデルではカーネル法により変数間の非線形な関係性を利用できるが、解釈ができないという問題がある。

また最近の研究として、ニューラルネットワークを用いる DeepSurv と呼ばれる手法を Katzman らが提案している [Katzman 16]。DeepSurv では生存期間をただニューラルネットワークで推定するのではなく、ハザード関数自体はニューラルネットワークを用いて出力し、観測打ち切りデータに対応するためにハザード関数の推定法を用いることで精度の高い推定に成功している。この手法では特徴間の非線形な相関を利用できる。ただし解釈性は高くなく、またこの論文中の実験では人力で数十程度の特徴を選択して実験するなど高次元小サンプルの問題への適応は難しい。

連絡先: 佐竹 哉太, k-satake@ml.ist.i.kyoto-u.ac.jp

3. 問題設定

本研究では Cox モデルをセミパラメトリックなまま評価するため、遺伝子情報、イベント・打ち切りの有無、生存期間のデータから、ハザード関数の大きさを求め、それによりイベントの順序を予測する問題を扱う。ただしそのまま生存期間を予測すると打ち切りデータを評価に用いることができないため、ある時点で死亡しているかどうかをラベルとして評価を行う。

今回の実験設定では観測済みデータとして特徴量 $\boldsymbol{x}_i \in \mathbb{R}^d$、生存期間 $t_i \in \mathbb{R}$、そして生存期間の終わりに死亡したかどうか $c_i \in \{0, 1\}$ を扱う。ここで $c_i = 1$ であれば死亡、$c_i = 0$ であれば観測打ち切りを意味する。本論文では、訓練データ $\{(\boldsymbol{x}_i, c_i, t_i)\}_{i=1}^N$ を用いてモデルを学習し、未知の入力データ $\boldsymbol{x}$ に対する死亡リスクの大きさ $f(\boldsymbol{x})$ を出力する問題を扱う。

4. 提案手法

まず基本となる Cox ハザードモデルについて述べ、次にそれを改善した提案手法について述べる。

4.1 Cox 比例ハザードモデル

Cox 比例ハザードモデルはセミパラメトリックなハザードモデルの代表的なもので、以下の式で定義される [Cox 72]。

$$h(\boldsymbol{x}, t) = h_0(t) \exp(\boldsymbol{\beta}^T \boldsymbol{x})$$

ここで $h_0(t)$ はベースラインハザードと呼ばれ、各 $\boldsymbol{x}$ に依存しない形で定義する。一般にベースラインハザードは陽に定義

しないことが多い。

Cox 比例ハザードモデルは、ハザード比が時間 t に依存しないという重要な性質がある。これは以下のように確かめられる。

$$\frac{h(\boldsymbol{x}_i,t)}{h(\boldsymbol{x}_j,t)} = \exp(\boldsymbol{\beta}^T(\boldsymbol{x}_i - \boldsymbol{x}_j))$$

この性質により、ベースラインハザードが分からない場合でもリスク比 $\frac{h(\boldsymbol{x}_i,t)}{h(\boldsymbol{x}_j,t)}$ を求めることができる。

Cox 比例ハザードモデルではベースラインハザードを定めないため、尤度を直接最適化することができない。そこで部分尤度関数 $L(\boldsymbol{\beta})$ を定義し、パラメータの推定を行う。

$$\hat{\boldsymbol{\beta}} = \underset{\boldsymbol{\beta}}{\operatorname{argmax}}\ L(\boldsymbol{\beta})$$

$L(\boldsymbol{\beta})$ は以下のようになる。

$$\begin{aligned} L(\boldsymbol{\beta}) &= \prod_{i=1}^{n}\left[\frac{h(\boldsymbol{x}_i,t_i)}{\sum_{j\in R_i} h(\boldsymbol{x}_j,t_i)}\right]^{c_i} \\ &= \prod_{i=1}^{n}\left[\frac{\exp(\boldsymbol{\beta}^T\boldsymbol{x}_i)}{\sum_{j\in R_i}\exp(\boldsymbol{\beta}^T\boldsymbol{x}_j)}\right]^{c_i} \end{aligned}$$

ここでデータは $\boldsymbol{t}$ の昇順に並び替えたものとする。また R_i はリスク集合で、その時点でイベントが生じる可能性がある集合を表す。これには $c_i = 0$ のサンプルも含まれる。部分尤度の最適化は、$\boldsymbol{x}_i$ によるハザード関数の大きさを次にそのデータのイベントが選択される確率とみなしたときの条件付き確率に相当する。

この対数尤度 $l(\boldsymbol{\beta})$ は以下のようになる。

$$l(\boldsymbol{\beta}) = \sum_{i=1}^{n}\left(c_i\boldsymbol{\beta}^T\boldsymbol{x}_i - c_i\log\sum_{j\in R_i}\exp(\boldsymbol{\beta}^T\boldsymbol{x}_j)\right)$$

Cox 比例ハザードモデルのパラメータ推定では、一般に上の対数尤度関数 $l(\boldsymbol{\beta})$ が用いられる。

4.2 FM の導入

4.2.1 Factorization Machines (FM)

Factorization Machines (FM) は各特徴間の相互作用をモデル化するための手法の一つである [Rendle 10]。FM では各特徴量間の相互作用を直接パラメータとして保持するのではなく、特徴ごとに持たせた k 次元のパラメータの内積で表現する。2 次元までの特徴の相互作用を考える場合、FM を用いた回帰モデルは以下のように表される。

$$y(\boldsymbol{x}) = w_0 + \sum_{i=1}^{d} w_i x_i + \sum_{i=1}^{d}\sum_{j=i+1}^{d}\langle\boldsymbol{v}_i,\boldsymbol{v}_j\rangle x_i x_j$$

ここで $w_0 \in \mathbb{R}$、$\boldsymbol{w} = (w_1,\ldots,w_d)^T \in \mathbb{R}^d$、$\boldsymbol{V} = [\boldsymbol{v}_1,\ldots,\boldsymbol{v}_d] \in \mathbb{R}^{d\times k}$ であり、

$$\langle\boldsymbol{v}_i,\boldsymbol{v}_j\rangle = \sum_{l=1}^{k} v_{i,l}v_{j,l}$$

である。ただし $v_{i,l}$ は $\boldsymbol{v}_i$ の l 番目のパラメータを表す。ハイパーパラメータ k は自由度である。k が十分大きければ任意の交互作用をモデリングできるが、一方でスパースなデータの場合オーバーフィッティングにつながる。k が大きすぎなければ、相互作用をパラメータ化する場合に比べてパラメータ量を削減できる

4.2.2 FM による Cox モデル

Cox 比例ハザードモデルの線形和の部分に FM を導入する形で拡張する。ここでは 2 次の交互作用を考慮したモデルを用いる。

$$h(\boldsymbol{x},t) = h_0(t)\exp(\sum_{i=1}^{d} w_i x_i + \sum_{i=1}^{d}\sum_{j=i+1}^{d}\langle\boldsymbol{v}_i,\boldsymbol{v}_j\rangle x_i x_j)$$

このモデルは特徴間の相互作用の情報をパラメータ k の自由度の分だけ利用できる。また比例ハザード性を満たすため、特徴の重要度を解釈することができる。ただし他のモデルに比べモデル自体の計算量は大きくなる。

4.3 カーネル法による線形なモデル

FM は特徴間の相互作用を利用できるが、提案したモデルでは 2 次の関係までしか利用できない。そこで特徴間の高次の関係性を利用するために、ガウスカーネルによる情報を用いる拡張も考える。ここでは解釈性を残すため、線形な拡張を考える。モデルは以下のようになる。

$$h(\boldsymbol{x},t) = h_0(t)\exp((\boldsymbol{D}\boldsymbol{\alpha})^T\boldsymbol{x})$$

ただし $\boldsymbol{D}$ はグラム行列で、以下で求められる。

$$\boldsymbol{D}_{ij} = \exp(-\gamma|\boldsymbol{f}_i - \boldsymbol{f}_j|^2)$$

γ はパラメータであり、$\boldsymbol{f}_i$ は訓練データの i 番目の特徴量を並べたベクトルである。このモデルは各特徴間の非線形な情報を利用することができ、各特徴の係数により解釈性を持つ。

5. 評価実験

5.1 データセット

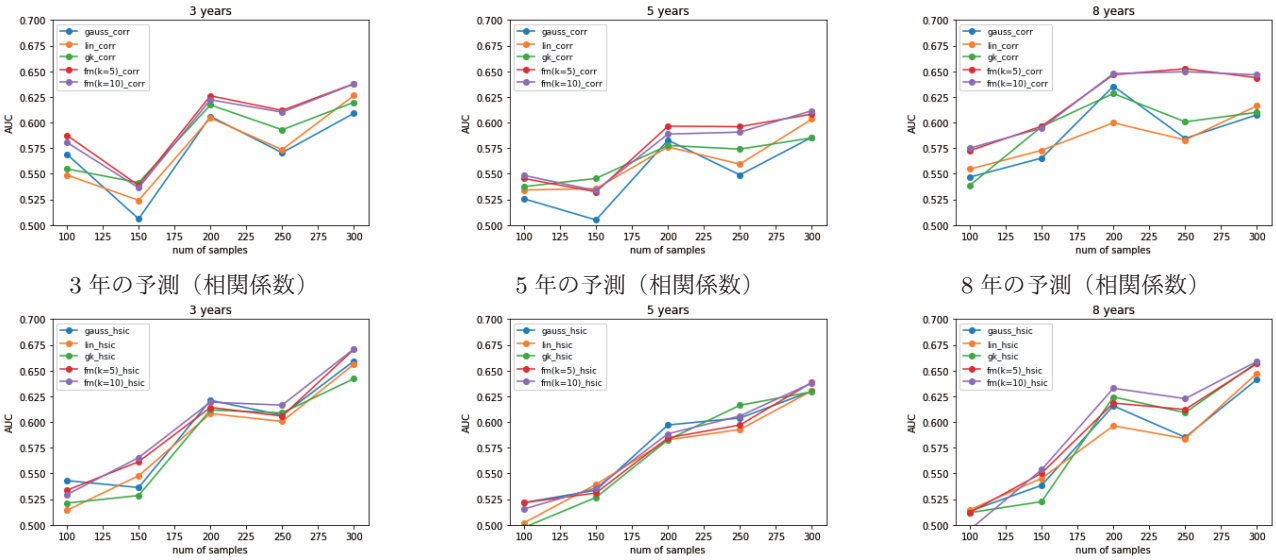
データセットは病気と生存期間に関する実データを用いる。用いたデータセットについて、サンプル数が 351、特徴の次元数が 54675 であり、打ち切りデータは 196 である。

5.2 評価手順

本研究では特徴数やサンプル数を変化させ精度を検証する。なお本研究では Cox モデルの最適化が煩雑になることを防ぐため、t_i が同一であるタイデータは用いない。今回扱うデータセットではタイデータが存在するので、まずランダムに一方を選択したのち実験を行う。

実験では、10 分割のクロスバリデーションを異なるサンプリングで 3 回行い、精度を検証する。サンプリングを行いデータを分割したのち、訓練データによって決められた特徴数だけ特徴選択を行う。この特徴選択は生存期間 t と特徴 x によって計算される。特徴選択については打ち切りデータも用いた方が良い精度を示したので、全ての訓練データで行う。特徴が選択されると訓練データからモデルを学習し、テストデータに対して予測を行い、精度を得る。なお全てのモデルで L2 正則化を用いる。

精度の計算では、まず 3 年、5 年、8 年で生存しているかどうかでテストデータをラベル付けする。このとき指定の期間未満の打ち切りデータはラベルが分からないため利用しない。次にラベル付けされた各データに関して、ベースラインハザードを除くハザード関数の大きさを求める。第 4.1 項よりハザード比は時間 t に依存せず一定であるため、このハザード関数の大きさが大きいほど死亡する確率が高いとみなすことができる。そこでハザード関数の大きさを死亡する確率と考え、ラベルに対して AUC を求めてこれを精度とする。



3 年の予測（相関係数）　5 年の予測（相関係数）　8 年の予測（相関係数）

3 年の予測（HSIC Lasso）　5 年の予測（HSIC Lasso）　8 年の予測（HSIC Lasso）

図 1: サンプル数に対する実験

5.3　比較手法

5.3.1　Cox 比例ハザードモデル

本研究で提案しているモデルの原型である Cox 比例ハザードモデルをベースラインとして用いる。定義等は第 4.1 項で述べた通りで以下のようになる。

$$h(\boldsymbol{x}, t) = h_0(t)\exp(\boldsymbol{\beta}^T\boldsymbol{x})$$

5.3.2　カーネル Cox モデル

Cox モデルの非線形な拡張として、ガウスカーネル法による手法 [Li 02] をベースラインとする。ハザードモデルは以下のようになる。

$$h(\boldsymbol{x}, t) = h_0(t)\exp(\boldsymbol{K}\boldsymbol{\alpha})$$

$\boldsymbol{K}$ はグラム行列で、以下で求められる。

$$\boldsymbol{K}_{ij} = \exp(-\gamma|\boldsymbol{x}_i - \boldsymbol{x}_j|^2)$$

γ はパラメータであり、$\boldsymbol{x}$ は各サンプルのベクトルである。ここでモデルの訓練時には $\boldsymbol{x}_i$、$\boldsymbol{x}_j$ がともに訓練データのサンプルのベクトルで、テストデータの予測時には $\boldsymbol{x}_i$ がテストデータ、$\boldsymbol{x}_j$ が訓練データのサンプルのベクトルとなる。このモデルは非線形の特徴間の情報をカーネルによって利用できるが、一方各特徴の貢献を解釈することは難しい。

5.4　特徴選択

5.4.1　相関係数による特徴選択

Cox 比例ハザードモデルでは、2. で述べたように線形の特徴選択が用いられることが多い。そこで線形な特徴選択として、目的である生存時間 t と各特徴との相関係数による特徴選択を用いる。具体的には生存時間 $\boldsymbol{t}$ と全ての特徴ベクトル $\boldsymbol{f}$ でそれぞれ相関係数を求め、その絶対値をスコアとする。その後スコアの高いものから特徴を抽出する。

5.4.2　HSIC Lasso による特徴選択

特徴間の非線形な相関を利用するため、非線形性を利用した特徴選択が可能な HSIC Lasso による特徴選択も用いる [Yamada 14]。具体的には生存時間 $\boldsymbol{t}$ と全ての特徴ベクトル $\boldsymbol{f}$ を用いて HSIC Lasso によるスコアを求め、スコアの高いものから特徴を抽出する。

6.　実験結果

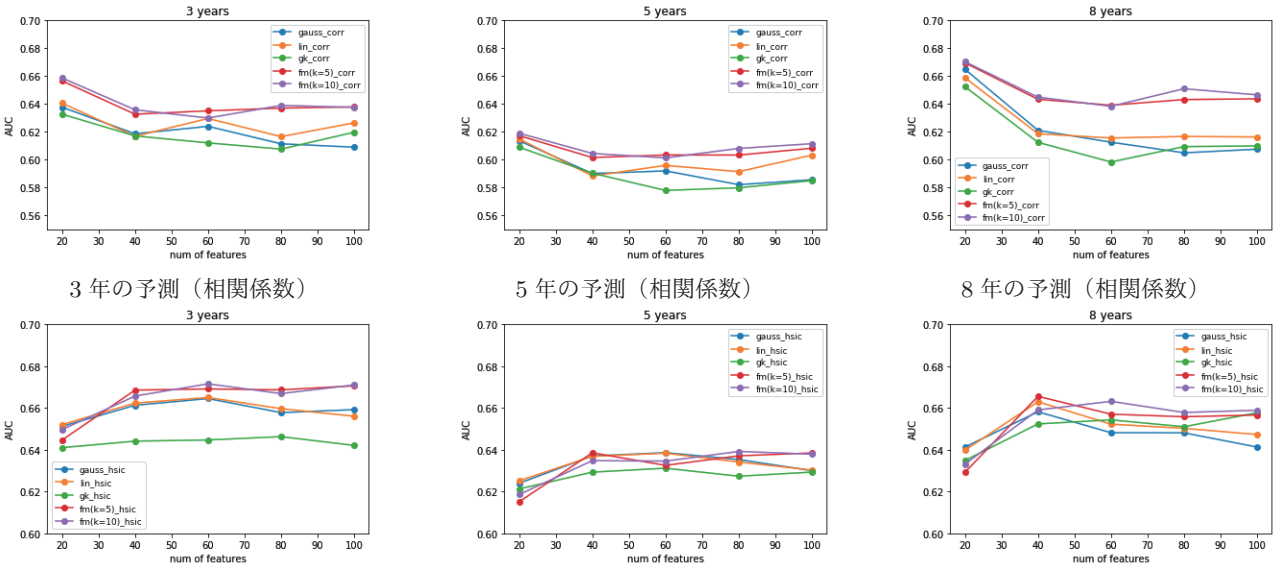
各ラベルは lin が通常の Cox モデル、gk がカーネル Cox モデルによる比較手法を表し、gauss が 4.3 で述べたカーネル法による線形な提案手法、fm が 4.2 で述べた FM による提案手法を表す。

6.1　サンプル数に対する実験

まずはじめに選択する特徴の数を 100 で固定し、サンプル数を 100 から 300 まで変化させた実験について述べる。相関係数を用いて特徴選択を行った場合の結果を図 1 の上側に示す。この結果を見ると、ほとんど全ての場合で FM による提案手法が最も良い精度を示している。これは特にサンプル数が多い場合と予測する期間が長い場合に顕著である。一方カーネル法による提案手法では精度が良くないが、これはガウスカーネルに有用な特徴を選択できていないからだと考えられる。

次に HSIC Lasso による特徴選択で同様の実験を行った結果を図 1 の下側に示す。この結果を見ると、こちらも多くの場合で FM による提案手法が最も良い精度を示している。ただし特に 5 年の予測などでは比較手法の方が良い精度を示しており、その他の場合でも相関係数による特徴選択の場合ほど比較手法と差があまりない。比較手法で精度が良いものを見ると、ガウスカーネルを用いた線形手法（gauss）や非線形手法（gk）である。HSIC Lasso による特徴選択は出力と各特徴の非線形な相関で行われるので、その情報を利用できるグラム行列を用いるこれらの手法の精度が良いと考えられる。

最後に両方の特徴選択手法で良い精度を示した FM による提案手法について比較を行った。1 による結果から、どの期間の予測でもサンプル数が少ない場合には相関係数による特徴選択が良い結果を示し、サンプル数が多い場合には HSIC Lasso による特徴選択が良い結果を示している。特にサンプル数が少ない場合にはその差が大きく、線形な特徴選択が非線形な特徴選択に比べて有用だと言える。これはサンプル数が少ない場合に複雑な特徴選択は過学習を起こしているからだと考えられる。また予測する期間が短いと HSIC Lasso が、予測する期間が長いと相関係数がそれぞれ優位な結果となっている。今回の特徴選択では出力に生存期間 t をそのまま利用しているので、



3 年の予測（相関係数）　5 年の予測（相関係数）　8 年の予測（相関係数）

3 年の予測（HSIC Lasso）　5 年の予測（HSIC Lasso）　8 年の予測（HSIC Lasso）

図 2: 特徴数に対する実験

相関係数では長期の生存に関わる特徴を選ぶことができていると考えられ、また HSIC Lasso では短い期間でも頑健である特徴を選ぶことができていると考えることができる。

6.2 特徴数に対する実験

次にサンプル数を 300 に固定し、特徴数を 10 から 100 まで変化させた実験について述べる。相関係数による特徴選択の結果を図 2 の上側に示す。この結果をから、どの年数・どのモデルの予測でも特徴数が最も少ない 10 のときに特に精度が高く、次の特徴量数 20 で精度が大幅に下がっている。これは予測に十分に寄与する特徴量が少数であるためと考えられる。また特徴量が少ない場合ではどのモデルでも差異は小さいが、特徴数が大きくなるとどの年数でも FM による提案手法と比較手法の差が大きくなっている。このことから、FM による提案手法では特に重要でない特徴も比較的うまく扱えると考えられる。

HSIC Lasso による特徴選択で同様の実験を行った結果を図 2 の下側に示す。こちらの場合は相関係数による特徴選択の場合と異なり、特徴数が少ない場合では精度が低く、その数が増えるに従って精度が向上している。このことから、HSIC Lasso による特徴選択では重要な特徴を少数で確保することはできないが、一方で満遍なく意味のある特徴を選択できていると考えられる。モデルの精度を見ると FM による提案手法がほとんどの場合で最も良い精度を示しているが、サンプル数が少ない場合には比較手法に比べて良いとは言えない。これは特徴数が少ない場合にはパラメータ数が大きすぎて過学習が起こっていると考えられる。

7. 終わりに

本研究では Cox ハザードモデルに FM による拡張を取り入れたモデル、さらに HSIC Lasso による特徴選択を提案した。実験の結果、FM によるモデルの有効性を示すことができた。また HSIC Lasso による特徴選択を Cox モデルに適用し、従来の線形な相関係数に対して不利な条件・有利な条件を示した。さらに生存期間に対する特徴選択の性質と、提案手法が特徴数の大きい場合にとくに良い精度を示すことを確認した。

今後の研究としては、まず FM で 3 次以上の交互作用を用いたモデルを適用することが考えられる。その場合パラメータを抑えても計算量は大きくなるが、特徴の数を増やすとさらに精度が良くなる可能性がある。また今回の実験は提案したモデルの精度を確かめることが目的であったため、議論が複雑になるタイデータの処理は考えていない。そのため実運用するためには実際の条件に近いタイデータを含むデータセットでも精度を確かめる必要がある。さらに実運用を考える上では特徴の数を増やしたり、別のデータセットでも提案手法の優位性が保たれるかを確認することが必要である。

参考文献

[Cox 72] Cox, D. R.: Regression models and life-tables, Journal of the Royal Sta- tistical Society: Series B (Methodological), Vol. 34, No. 2, pp. 187202 (1972).

[Li 02] Li, H. and Luan, Y.: Kernel Cox regression models for linking gene expres- sion profiles to censored survival data, Biocomputing 2003, World Scien- tific, pp. 6576 (2002).

[Katzman 16] Katzman, J. L., Shaham, U., Cloninger, A., Bates, J., Jiang, T. and Kluger, Y.: Deep survival: A deep cox proportional hazards network, stat, Vol. 1050, p. 2 (2016).

[Rendle 10] Rendle, S.: Factorization machines, Data Mining (ICDM), 2010 IEEE 10th International Conference on, IEEE, pp. 9951000 (2010).

[Yamada 14] Yamada, M., Jitkrittum, W., Sigal, L., Xing, E. P. and Sugiyama, M.: High-dimensional feature selection by feature-wise kernelized lasso, Neural computation, Vol. 26, No. 1, pp. 185207 (2014).

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

RFM 指標と顧客特性に基づく LTV 予測モデル

LTV Prediction Based on RFM and Customer Characteristics

今井 優作　　田嶋 優樹
Yusaku Imai　　Yuki Tajima

株式会社電通デジタル
Dentsu Digital Inc.

Lifetime Value (LTV) as we know it, is an important indicator of customer evaluation. To build long-term relationships with the right customer, it is important to predict LTV with increasingly higher accuracy levels. Once we attain that, we would be able to communicate with them through appropriate marketing actions. While predicting LTV in a non-contractual setting, three indicators, namely; Recency, Frequency and Monetary Value (RFM) are widely used. RFM is used as an indicator of customers' buying behaviour on the whole, however normally dimensions like demographics are not considered. In this paper, we propose a model for predicting LTV based not just on RFM, but also other customer characteristics. To support our proposal and its effectiveness we have also provided the details of the experiments, their outputs and our inference using a real dataset.

1. はじめに

マーケティングにおける顧客評価のための重要な指標として顧客生涯価値 (LTV; Lifetime Value) がある．非契約型サービスにおいて，LTV は顧客の生存期間, 購買頻度, 1 回あたりの購買金額の掛け合わせで表される [Schmittlein 94]．LTV を高精度に予測できるようになると，適切なマーケティング活動を通して優良顧客との長期的な関係構築が可能となる．

LTV 予測において，Recency(直近の購買からの経過日数), Frequency(観測期間中の購買回数), Monetary(平均購買金額) の 3 指標が広く使われている．RFM 指標は顧客の購買特性を集約した指標として有用であるが，性別や年代といった顧客自体の特性は考慮していない．本稿では，RFM 指標に加えて顧客特性も加味した予測モデルを提案し，RFM 指標のみを用いた従来法よりも高い精度で LTV 予測が可能なことを示す．

2. LTV 予測

RFM 指標を用いた LTV 予測モデルの代表的な手法として BTYD(Buy Till You Die) モデルがある [Schmittlein 87]．観測終了時刻を T とすると，$(T, T+t]$ での予測 LTV は，T での顧客生存確率 $\times$ $(T, T+t]$ での期待購買回数 $\times$ 1 回あたりの期待購買金額となり，第一項, 第二項の購買回数は BG/NBD モデル [Fader 05b]，第三項の購買金額は GG モデル [Fader 05a] を用いて求められる．

BG/NBD モデルでは，購買回数にパラメータ λ のポアソン分布，顧客の離脱確率にパラメータ ρ の幾何分布を仮定する．また，λ はパラメータ r, β のガンマ分布，ρ はパラメータ a, b のベータ分布を事前分布とする．$(0, T]$ での購買回数が x，最終購買時刻が t_x のとき，T での顧客生存確率は

$$P(\text{active}|x, t_x, T; r, \beta, a, b) = \frac{1}{1 + \delta_{x>0} \frac{a}{b+x-1} \left(\frac{\beta+T}{\beta+t_x}\right)^{r+x}}, \tag{1}$$

連絡先: 今井優作, 株式会社電通デジタル, imai.yu@dentsudigital.co.jp

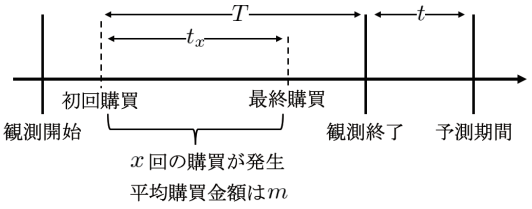


図 1: RFM 指標の概要図

$(T, T+t]$ での期待購買回数は

$$E(X(t)|x, t_x, T; r, \beta, a, b) = \frac{a+b+x-1}{a-1}\left[1 - \left(\frac{\beta+T}{\beta+T+t}\right)^{r+x} \cdot {}_2F_1\left(r+x, b+x; a+b+x-1; \frac{t}{\beta+T+t}\right)\right] \tag{2}$$

となる．ここで，δ はデルタ関数, ${}_2F_1$ はガウスの超幾何関数を表す．

GG モデルでは，購買金額にパラメータ τ, ν のガンマ分布を仮定し，ν はパラメータ q, ξ のガンマ分布を事前分布とする．$(0, T]$ での購買回数が x，平均購買金額が m のとき，期待購買金額は

$$E(M|m; \tau, q, \xi) = \frac{\tau(\xi + mx)}{\tau x + q - 1} \tag{3}$$

となる．

式 (1)(2)(3) の導出過程については巻末付録に示す．

3. 提案法

本稿では，2. で示した BG/NBD モデルと GG モデルを基に，RFM 指標に加えて顧客特性も加味した LTV 予測モデルを提案する．

顧客特性を $\boldsymbol{d} = \{d_k\}$ とする．BG/NBD モデルのパラメータ r, β, a, b および GG モデルのパラメータ τ, q, ξ はいずれも

> 0 となるため，モデルパラメータは $\vartheta = \exp(\langle \boldsymbol{w}_\vartheta, \boldsymbol{d} \rangle), \vartheta \in \{r, \beta, a, b, \tau, q, \xi\}$ とする．ここで，$\langle \cdot, \cdot \rangle$ は 2 つのベクトルの内積を表す．

従来法ではパラメータ $r, \beta, a, b, \tau, q, \xi$ を推定するが，提案法では以下の最適化問題を解いて重みパラメータ $\boldsymbol{w}_\vartheta$ を求める．

$$\arg\min_{\boldsymbol{w}_\vartheta} L + \frac{\mu}{2}\left(\sum_\vartheta \|\boldsymbol{w}_\vartheta\|_2^2\right) \tag{4}$$

ここで，μ は正則化パラメータ，$\|\boldsymbol{w}\|_2^2$ は L2 ノルム，L は negative log-likelihood を表す．

$\boldsymbol{w}_\vartheta$ の勾配は連鎖律により

$$\frac{\partial L}{\partial w_{\vartheta,k}} = \frac{\partial L}{\partial \vartheta} \cdot \frac{\partial \vartheta}{\partial w_{\vartheta,k}} = \frac{\partial L}{\partial \vartheta} \cdot \vartheta d_k \tag{5}$$

となる．ここで，BG/NBD モデルの尤度

$$\ell_{\mathrm{BG/NBD}} = \frac{B(a, b+x)}{B(a,b)} \frac{\Gamma(r+x)\beta^r}{\Gamma(r)(\beta+T)^{r+x}} + \delta_{x>0} \frac{B(a+1, b+x-1)}{B(a,b)} \frac{\Gamma(r+x)\beta^r}{\Gamma(r)(\beta+t_x)^{r+x}} \tag{6}$$

より

$$\frac{\partial L_{\mathrm{BG/NBD}}}{\partial r} = \Psi(r) - \Psi(r+x) - \log\left(\frac{\beta}{\beta+T}\right) - \frac{\delta_{x>0}\left(\frac{a}{b+x-1}\right)\left(\frac{\beta+T}{\beta+t_x}\right)^{r+x}\log\left(\frac{\beta+T}{\beta+t_x}\right)}{1+\delta_{x>0}\left(\frac{a}{b+x-1}\right)\left(\frac{\beta+T}{\beta+t_x}\right)^{r+x}}, \tag{7}$$

$$\frac{\partial L_{\mathrm{BG/NBD}}}{\partial \beta} = -\frac{r}{\beta} + \frac{r+x}{\beta+T} - \frac{\delta_{x>0}\left(\frac{a}{b+x-1}\right)\left(\frac{\beta+T}{\beta+t_x}\right)^{r+x}\left(\frac{r+x}{\beta+T}\right)\left(1-\frac{\beta+T}{\beta+t_x}\right)}{1+\delta_{x>0}\left(\frac{a}{b+x-1}\right)\left(\frac{\beta+T}{\beta+t_x}\right)^{r+x}}, \tag{8}$$

$$\frac{\partial L_{\mathrm{BG/NBD}}}{\partial a} = -\Psi(a+b) + \Psi(a+b+x) - \delta_{x>0}\frac{\left(\frac{\beta+T}{\beta+t_x}\right)^{r+x}}{\left(1+\left(\frac{a}{b+x-1}\right)\left(\frac{\beta+T}{\beta+t_x}\right)^{r+x}\right)(b+x-1)}, \tag{9}$$

$$\frac{\partial L_{\mathrm{BG/NBD}}}{\partial b} = -\Psi(a+b) + \Psi(a+b+x) + \Psi(b) - \Psi(b+x) + \delta_{x>0}\frac{\left(\frac{\beta+T}{\beta+t_x}\right)^{r+x}\left(\frac{a}{b+x-1}\right)}{\left(1+\left(\frac{a}{b+x-1}\right)\left(\frac{\beta+T}{\beta+t_x}\right)^{r+x}\right)(b+x-1)}, \tag{10}$$

GG モデルの尤度

$$\ell_{\mathrm{GG}} = \frac{\Gamma(\tau x+q)}{\Gamma(\tau x)\Gamma(q)} \frac{m^{\tau x-1} x^{\tau x} \xi^q}{(\xi+mx)^{\tau x+q}} \tag{11}$$

より

$$\frac{\partial L_{\mathrm{GG}}}{\partial \tau} = \left[-\Psi(\tau x+q) + \Psi(\tau x) - \log\left(\frac{mx}{\xi+mx}\right)\right] x, \tag{12}$$

$$\frac{\partial L_{\mathrm{GG}}}{\partial q} = -\Psi(\tau x+q) + \Psi(q) - \log\left(\frac{\xi}{\xi+mx}\right), \tag{13}$$

$$\frac{\partial L_{\mathrm{GG}}}{\partial \xi} = -\frac{q}{\xi} + \frac{\tau x+q}{\xi+mx} \tag{14}$$

となる．ここで，B はベータ関数，Γ はガンマ関数，Ψ はディガンマ関数を表す．

表 1: MAE の比較

	従来法	提案法
期待購買回数	2.852	2.722
期待購買金額 ($\times 10^3$)	4.082	4.046
予測 LTV ($\times 10^3$)	15.180	14.457

表 2: RMSLE の比較

	従来法	提案法
期待購買回数	0.884	0.845
期待購買金額	1.045	1.035
予測 LTV	6.134	6.023

4. 実験

提案法の有効性を評価するための実験を行った．実験には，セブン&アイ・ホールディングスの通販サイト omni7[*1] における，2016 年 10 月 1 日から 2018 年 9 月 30 日までの購買データを用いた．購買データには，4,930,238 の顧客 ID と 22,500,570 の購買情報が含まれる．また，提案法における顧客特性として，性別, 年代, 地域の 3 変数を用いた．

2017 年 9 月 30 日までの RFM 指標を用いてモデルの学習を行い，2017 年 10 月 1 日から 1 年後までの期待購買回数 (式 (1)×(2)), 期待購買金額 (式 (3)), および予測 LTV(式 (1)×(2)×(3)) を求めた．評価尺度には平均絶対誤差 (MAE) と対数平方平均二乗誤差 (RMSLE) を用いた．実験結果を表 1, 2 に示す．表より，いずれの評価指標においても提案法の予測精度が向上していることがわかる．また，予測 LTV の改善幅が期待購買回数, 期待購買金額よりも大きいことから，顧客特性を加味することで BG/NBD モデルと GG モデルの予測精度が同時的に向上したと考えられる．

5. おわりに

本稿では，非契約型サービスにおける LTV 予測モデルを提案した．提案法では，顧客の購買特性を示す RFM 指標に加えて顧客特性を加味することで，RFM 指標のみを用いた従来法よりも高い精度で LTV 予測が可能であることを確認した．

先行研究 [阿部 11] において，顧客の離脱確率/購買回数に Pareto/NBD モデル [Schmittlein 87]，購買金額に対数正規分布を仮定し，それらのパラメータの事前分布を多変量対数正規分布とすることで，顧客生存確率, 購買回数, および購買金額の相関構造をモデル化している．そこで，提案法に対しても相関構造を考慮する機構を加え，提案法の有効性に対するさらなる検証，および改善を行う．

*1 https://www.omni7.jp

A BG/NBD モデル

$(0,t]$ での購買回数を x とすると，x は負の二項分布に従う．

$$f(X(t)=x;r,\beta)=\int f(X(t)=x;\lambda)\cdot f(\lambda;r,\beta)d\lambda = \frac{\Gamma(r+x)}{\Gamma(r)x!}\left(\frac{\beta}{\beta+t}\right)^r\left(\frac{t}{\beta+t}\right)^x \quad (15)$$

with

$$f(X(t)=x;\lambda)=\frac{(\lambda t)^x\exp(-\lambda t)}{x!}, \quad (16)$$

$$f(\lambda;r,\beta)=\frac{\beta^r\lambda^{r-1}\exp(-\lambda\beta)}{\Gamma(r)} \quad (17)$$

顧客の離脱確率を ρ とすると，j 回目の購買後に離脱する確率はベータ-幾何分布に従う．

$$f(\text{inactive};a,b)=\int f(\text{inactive};\rho)\cdot f(\rho;a,b)d\rho = \frac{B(a+1,b+j-1)}{B(a,b)} \quad (18)$$

with

$$f(\text{inactive};\rho)=\rho(1-\rho)^{j-1}, \quad (19)$$

$$f(\rho;a,b)=\frac{\rho^{a-1}(1-\rho)^{b-1}}{B(a,b)} \quad (20)$$

$(0,t]$ での購買回数が x の確率は

$$\begin{aligned}&P(X(t)=x;r,\beta,a,b)\\ &=\int P(X(t)=x;\lambda,\rho)\cdot f(\lambda;r,\beta)\cdot f(\rho;a,b)d\lambda d\rho\\ &=\frac{B(a,b+x)}{B(a,b)}\frac{\Gamma(r+x)}{\Gamma(r)x!}\left(\frac{\beta}{\beta+t}\right)^r\left(\frac{t}{\beta+t}\right)^x\\ &\quad+\ \delta_{x>0}\frac{B(a+1,b+x-1)}{B(a,b)}\\ &\quad\cdot\left[1-\left(\frac{\beta}{\beta+t}\right)^r\left\{\sum_{j=0}^{x-1}\frac{\Gamma(r+j)}{\Gamma(r)j!}\left(\frac{t}{\beta+t}\right)^j\right\}\right]\end{aligned} \quad (21)$$

with

$$\begin{aligned}&P(X(t)=x;\lambda,\rho)\\ &=P(\text{active after } x\text{th purchase})\cdot P(t_x\le t<t_{x+1})\\ &\quad+\ \delta_{x>0}P(\text{inactive after } x\text{th purchase})\cdot P(t_x\le t)\\ &=(1-\rho)^x\frac{(\lambda t)^x\exp(-\lambda t)}{x!}\\ &\quad+\ \delta_{x>0}\rho(1-\rho)^{x-1}\left[1-\exp(-\lambda t)\sum_{j=0}^{x-1}\frac{(\lambda t)^j}{j!}\right]\end{aligned} \quad (22)$$

であり，期待購買回数は

$$\begin{aligned}&E(X(t);r,\beta,a,b)\\ &=\int E(X(t);\lambda,\rho)\cdot f(\lambda;r,\beta)\cdot f(\rho;a,b)d\lambda d\rho\\ &=\frac{a+b-1}{a-1}\left[1-\left(\frac{\beta}{\beta+t}\right)^r\ {}_2F_1\left(r,b;a+b-1;\frac{t}{\beta+t}\right)\right]\end{aligned} \quad (23)$$

with

$$E(X(t);\lambda,\rho)=\frac{1}{\rho}\left(1-\exp(-\lambda\rho t)\right) \quad (24)$$

となる．

$(0,T]$ での購買回数が x，最終購買時刻が t_x のとき，$(T,T+t]$ での期待購買回数は

$$\begin{aligned}&E(\gamma(t)|x,t_x,T;r,\beta,a,b)\\ &=P(\text{active}|x,t_x,T;r,\beta,a,b)\cdot E(X(t)|x,t_x,T;r,\beta,a,b)\end{aligned} \quad (25)$$

となる．ここで，第一項は

$$\begin{aligned}&P(\text{active}|x,t_x,T;r,\beta,a,b)\\ &=\int P(\text{active}|x,t_x,T;\lambda,\rho)\cdot f(\lambda,\rho|x,t_x,T;r,\beta,a,b)d\lambda d\rho\\ &=\frac{1}{1+\delta_{x>0}\frac{a}{b+x-1}\left(\frac{\beta+T}{\beta+t_x}\right)^{r+x}}\end{aligned} \quad (26)$$

with

$$P(\text{active}|x,t_x,T;\lambda,\rho)=\frac{(1-\rho)\exp(-\lambda(T-t_x))}{\rho+(1-\rho)\exp(-\lambda(T-t_x))}, \quad (27)$$

$$\begin{aligned}&f(\lambda,\rho|x,t_x,T)\\ &=(1-\rho)^x\lambda^x\exp(-\lambda T)+\delta_{x>0}\ \rho(1-\rho)^{x-1}\lambda^x\exp(-\lambda t_x),\end{aligned} \quad (28)$$

$$\begin{aligned}&f(\lambda,\rho|x,t_x,T;r,\beta,a,b)\\ &=\frac{f(\lambda,\rho|x,t_x,T)\cdot f(\lambda;r,\beta)\cdot f(\rho;a,b)}{\int f(\lambda,\rho|x,t_x,T)\cdot f(\lambda;r,\beta)\cdot f(\rho;a,b)d\lambda d\rho}\end{aligned} \quad (29)$$

第二項は

$$\begin{aligned}&E(X(t)|x,t_x,T;r,\beta,a,b)\\ &=\int E(X(t);\lambda,\rho)\cdot f(\lambda,\rho|X=x,t_x,T;r,\beta,a,b)d\lambda d\rho\\ &=\frac{a+b+x-1}{a-1}\left[1-\left(\frac{\beta+T}{\beta+T+t}\right)^{r+x}\right.\\ &\quad\left.\cdot\ {}_2F_1\left(r+x,b+x;a+b+x-1;\frac{t}{\beta+T+t}\right)\right]\end{aligned} \quad (30)$$

である．

B GG モデル

購買金額 m はガンマ-ガンマ分布に従う．

$$f(M(x)=m;\tau,q,\xi)=\int f(M(x)=m;\tau,\nu)\cdot f(\nu;q,\xi)d\nu = \frac{\Gamma(\tau x+q)}{\Gamma(\tau x)\Gamma(q)}\frac{m^{\tau x-1}x^{\tau x}\xi^q}{(\xi+mx)^{\tau x+q}} \quad (31)$$

with

$$f(M(x)=m;\tau,\nu)=\frac{(\nu x)^{\tau x}m^{\tau x-1}\exp(-\nu x m)}{\Gamma(\tau x)}, \quad (32)$$

$$f(\nu;q,\xi)=\frac{\xi^q\nu^{q-1}\exp(-\nu\xi)}{\Gamma(q)} \quad (33)$$

期待購買金額ζはガンマ分布より$\zeta = \frac{\tau}{\nu}$であり，$\zeta = h(\nu;\tau)$とすると

$$f(\zeta;\tau,q,\xi) = \left|\frac{d}{d\zeta}h^{-1}(\zeta;\tau)\right| f(h^{-1}(\zeta;\tau);q,\xi) = \frac{(\tau\xi)^q\zeta^{-q-1}\exp(-\frac{\tau\xi}{\zeta})}{\Gamma(q)} \tag{34}$$

のように逆ガンマ分布となるため，期待値は

$$E(M;\tau,q,\xi) = \frac{\tau\xi}{q-1} \tag{35}$$

となる．

$(0,T]$での購買回数がx，平均購買金額がmのとき

$$f(\nu|m;\tau,q,\xi) = \frac{f(m;\tau,\nu)\cdot f(\nu;q,\xi)}{\int f(m;\tau,\nu)\cdot f(\nu;q,\xi)d\nu} \tag{36}$$

より

$$f(\zeta|m;\tau,q,\xi) = \left|\frac{d}{d\zeta}h^{-1}(\zeta;\tau)\right| f(h^{-1}(\zeta;\tau)|m;\tau,q,\xi) = \frac{(\tau(\xi+mx))^{\tau x+q}\zeta^{-\tau x-q-1}\exp(-\frac{\tau(\xi+mx)}{\zeta})}{\Gamma(\tau x+q)} \tag{37}$$

となるため, 期待購買金額は

$$E(M|m;\tau,q,\xi) = \frac{\tau(\xi+mx)}{\tau x+q-1} \tag{38}$$

である．

参考文献

[Fader 05a] Fader, P. S., Hardie, B. G., and Lee, K. L.: RFM and CLV: Using Iso-Value Curves for Customer Base Analysis, *Journal of Marketing Research*, Vol. 42, No. 4, pp. 415–430 (2005)

[Fader 05b] Fader, P., G. S. Hardie, B., and Lok Lee, K.: “Counting Your Customers” the Easy Way: An Alternative to the Pareto/NBD Model, *Marketing Science*, Vol. 24, pp. 275–284 (2005)

[Schmittlein 87] Schmittlein, D. C., Morrison, D. G., and Colombo, R.: Counting Your Customers: Who Are They and What Will They Do Next?, *Manage. Sci.*, Vol. 33, No. 1, pp. 1–24 (1987)

[Schmittlein 94] Schmittlein, D. and Peterson, R.: Customer Base Analysis: An Industrial Purchase Process Application, *Marketing Science*, Vol. 13, pp. 41–67 (1994)

[阿部 11] 阿部 誠 : RFM 指標と顧客生涯価値 : 階層ベイズモデルを使った非契約型顧客関係管理における消費者行動の分析, 日本統計学会誌. シリーズ J, Vol. 41, No. 1, pp. 51–81 (2011)

データ非線形性とダム流入量予測精度に関する研究

Study on the relationship between data non-linearity and dam inflow discharge prediction accuracy

天方匡純[*1] 安野貴人[*1] 藤井純一郎[*1] 嶋本ゆり[*1] 大久保順一[*1]
Masazumi Amakata Takuto Yasuno Junichiro Fujii Yuri Shimamoto Junichi Okubo

[*1] 八千代エンジニヤリング株式会社
Yachiyo Engineering Co., Ltd.

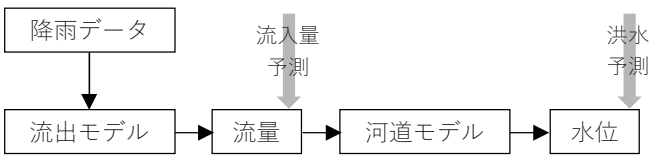
Abstract: We aim at improving the predictive precision of the dam inflow discharge using the correlation between the upper stream data and the lower stream data. When we handle the correlation between the upper and lower stream data, we focus on the non-linearity the data have and we have to change the way of modeling according to the degree of the non-linearity. In this paper, we gave the sequential data generated by the distributed flow analysis model the deviation in order to express the non-linearity of the data. After that, we selected LSTM which is a kind of deep learning network and made the predictive model of the dam inflow discharge learning the non-linearity data. As the result, we knew that the deviation which the normal observation values have doesn't influence the complexity of deep learning model.

1. はじめに

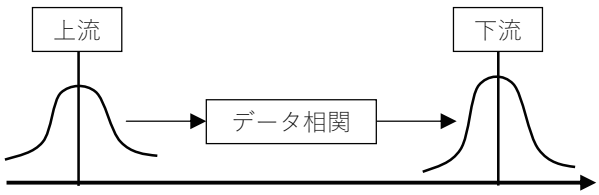
気候変動による地球温暖化の影響を受け，各地方でこれまで経験もしたことが無い外力や事象に起因する水・土砂災害に苦しんでいる．これまでの河川整備の水準を超える外力規模・頻度の増大により，従来の治水対策の在り方を抜本的に見直さざるを得ない状況も想定され，まずは人命を救うための可能な限り迅速で正確な情報提供が求められる．洪水時のダム管理に当たっても，下流側の資産集積地の被害軽減やダム自体の安全性確保の観点から，洪水関連情報の早期取得・利用は死活問題であり，その一つのツールであるダム流入量予測の精度向上は喫緊の課題である．

2. ダム流入量予測の原理

ダム流入量予測には，図 1 の通り，主に2つの方法があり，雨量から流入量への流出過程を疑似的に再現する方法と，上流側の雨量や水位から下流側の流入量を予測する方法である．前者はモデルの説明責任を果たせる伝統的手法であるがデータ同化等の技術を駆使しても，入力データやモデル構造等のバイアスを低減することが難しい．一方，後者は上流側と下流側のデータ相関を活用する手法であり，確保できるリードタイムが短く，また，説明責任を果たせない手法と考えられているが，洪水到達時間内予測精度は前者よりも高い．本稿では，後者の原理に基づくダム流入量予測モデルの留意点の一つであるデータ間の非線形性への対応をとりまとめる．



【物理モデルの流量・水位変換】



【相関モデルの流量・水位変換】

図 1　水位・流量予測手法の概要

連絡先：天方匡純，技術創発研究所（RIIPS），〒111-8648 東京都台東区浅草橋 5-20-8，amakata@yachiyo-eng.co.jp

3. 観測データの特徴

ダム流入量と相関性が高い一般的な上流側データは，水位データと雨量データである．水位データは雨量が地面に到達した後の水文過程の結果であるため，よりダム流入量との関係が濃厚である．このため，本稿では検討の簡便化のため上流側データとして水位データのみを扱う．

3.1 水位データの特徴

洪水時の河川は，河道全体に水量が充満し，河道形状等の影響で水面形状は複雑な起伏を持つ（図 2 参照）．ところが，水位データは通常，一点を捉えた時系列データとなり，洪水時には非常に不確定性の高い振幅を有するデータとなる．

3.2 ダム流入量データの特徴

ダム流入量は，ダム貯水池への接続河道からだけでなく，貯水池総縁辺からの流れ込みにより形成されるため，観測は事実上不可能である．そこで，観測可能な放流量と貯水位から間接的にダム流入量を推定する．ただし，洪水時には大量の水が流れ込むことによる衝撃波等が発生し，貯水池は大きく振動し，貯水位も大きく振動する．この結果，貯水位から間接的に変換したダム流入量も大きく振動する（図 3 参照）時系列データとなる．



図 2　洪水時の水面形状



図 3　ダム流入量データ

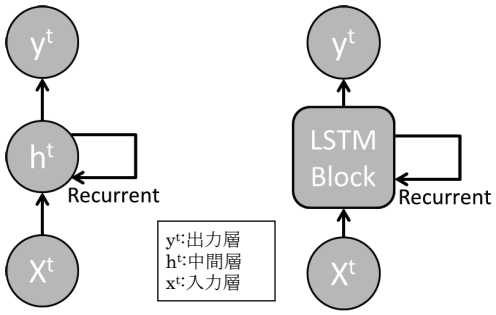


図 4　RNN と LSTM の基本構造

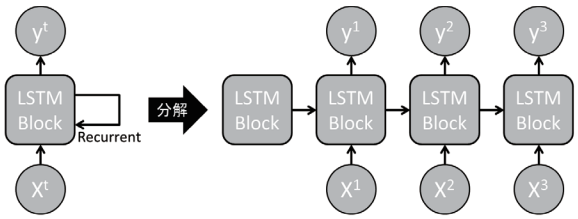


図 5　LSTM 構造の分解

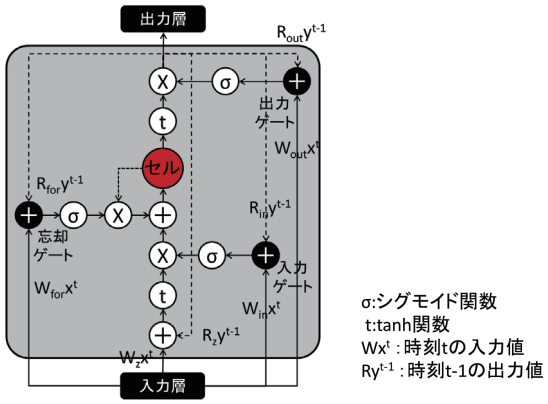


図 6　LSTM ブロックの詳細図

4.　アーキテクチャーの検討

現時刻以前の情報を保持し，次のステップの予測に役立てることができる DNN（Deep Neural Network）である RNN 系の LSTM（Long Short-Term Memory）を活用し，ダム流入量の予測精度を高めるアーキテクチャーを検討する．なお，扱うデータは前章で記した振幅を有するデータとなるため，それらの雑音を排した汎化性のある出力データを求めることとなる．

4.1 LSTM の概要

DNN のモデル構造は，これまでも洪水予測やダム流入量予測に利用されてきたニューラルネットワークのものと類似している．DNN は，中間層の数を大幅に増やすことができ，非線形性に代表されるより複雑なデータ間の関係を読み解くことが可能である．特に LSTM は，前後関係が重要となる時系列データの特徴量抽出に威力を発揮する．そこで，本稿では LSTM を用いて時系列のハイドログラフの特徴量抽出に適用する．

これまで，我々が洪水予測等に利用してきたニューラルネットワーク[竹村　2013]は，中間層を 1 層（1 層当たりニューロン 7 個）とし，活性化関数にシグモイド関数を用いてきた．しかし，このネットワークは入力データの前後関係を保持する機構を持たず，時系列データを扱う場合は，時刻 t のデータと時刻 t+⊿t のデータの関係を学習することにより，時刻 t のデータから時刻 t+⊿t のデータを予測する．また，入力データに時刻 t，時刻 t+1，時刻 t+2，…，時刻 t+⊿t のデータを別々に揃えることで時系列の関係を保持しながら出力データとの関係を構築することも可能であるが，数日先のように予測スパンが長くなると入力データセットが煩雑となる，また，Xrain に代表されるメッシュ雨量等の巨大入力データを利用する際は類似データセットの冗長性は避けたい等を想定すると入力データ構造として限界がある．

RNN 系ネットワークは，入力データの前後関係を保持する機能が整備され，入力データを必要最小限としてデータの前後関係の特徴量を捉え，出力データとの関係を構築することができる．RNN は図 4 のように時刻 t-1 以前の中間層を時刻 t の中間層に紐づけ，入力データの前後関係を保持している．更に，LSTM は，図 4，図 5 のように基本的構造は RNN と同様であるが，中間層をニューロンではなく LSTM ブロックと呼ばれるメモリセルと 3 つのゲートを持つブロックに置き換え，データの前後関係の長期依存性能（long-term dependencies）[Bengio 1994]を高めている．LSTM ブロックの詳細は図 6 の通りであり，DNN の勾配消失問題をネットワーク構造（図 6 のメモリセルと 3 つのゲートによるデータ制御）により解決している．3 つのゲートは，忘却ゲート，入力ゲート，出力ゲートに分けられ，それぞれシグモイド層によりデータを通す・通さないを判定する．

4.2 取り扱うデータ内容

降った雨が 60～90 分後にダム貯水池に流れ込む流域を想定し，土研モデル[吉野　1990]を活用して分布型流出解析モデル（図 7 参照）を構築した．そのモデルの出力結果である計算流量に人工ノイズを与え，振幅付き観測値を疑似的に再現する（図 8 参照）．ダム上流域に 3 地点の観測所を想定し，3 地点の疑似観測値を活用して LSTM モデルを作成し，ダム流入量を予測する試みとした．図 9 の通り，全 55 出水を扱い，そのうち 52 出水で学習し，3 出水で精度検証した．

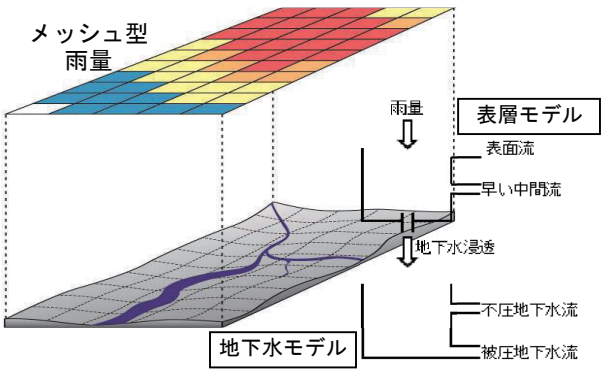


図 7　分布型流出解析モデルの概念図

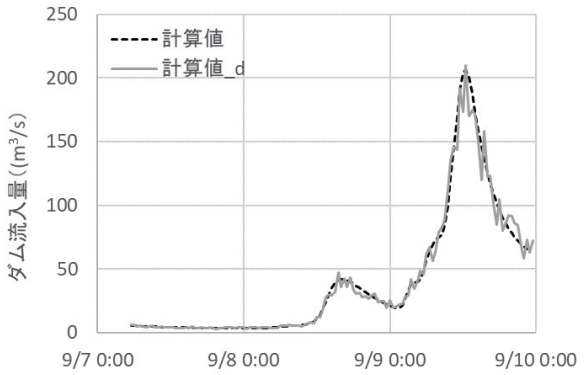


図 8　人工ノイズを与えた計算流量（観測値に見立てる）

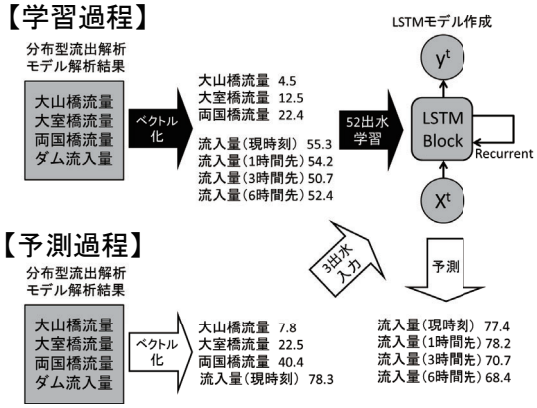


図 9　LSTM の学習と予測の過程

表 1　LSTM のモデル条件

モデル名	層	ブロック数	出力関数	評価関数	最適手法
LSTM1	1	7	恒等関数	MSE	SGD
LSTM2	1	56	恒等関数	MSE	SGD
LSTM3	2	7×7	恒等関数	MSE	SGD

4.3 アーキテクチャーの設定

学習・予測で用いた LSTM モデルは表 1 の通り. LSTM1 層（7 ブロック）でも他モデルと同精度を確保できることが分かる.

5. おわりに

計算結果にノイズを含めなければ，1 層（7 ブロック）の LSTM モデルの計算精度が最良結果となることは別途確認済みである. 本稿では，表 2～表 4 の結果から観測時に想定されるノイズを含めても LSTM モデルの複雑さが求められるわけではないことを確認した. この結果，ノイズを有する実観測データに対しては，非線形対応として表現力の高い，層の深いモデルを選択するよりも平滑化等のノイズ除去の前処理が重要であると考えられる. 一方，大流域ではノイズとは異なる観測データ間の非線形性が高まると考えられるため，今後はその非線形性のダム流入量予測精度への影響を確認していく予定である.

参考文献

[竹村　2013]竹村仁志，眞間修一，吉田武司，石上尚:中流域に洪水調節ダムを有する河川における洪水予測システムの精度検証，河川技術論文集，土木学会，2013.

[吉野　1990]吉野文雄，吉谷純一，堀内輝亮:分布型流出モデルの開発と実流域への適用，土木技術資料，土木研究センター，1990.

[Bengio　1994]　Yoshua Bengio, Patrice Simoard, and Paolo Frasconi: Learning Long-Term Dependencies with Gradient Descent is Difficult, TRANSACTIONS ON NEURAL NETWORKS, IEEE, 1994.

表 2　各 LSTM モデルの計算結果（H27. 7. 3 洪水）

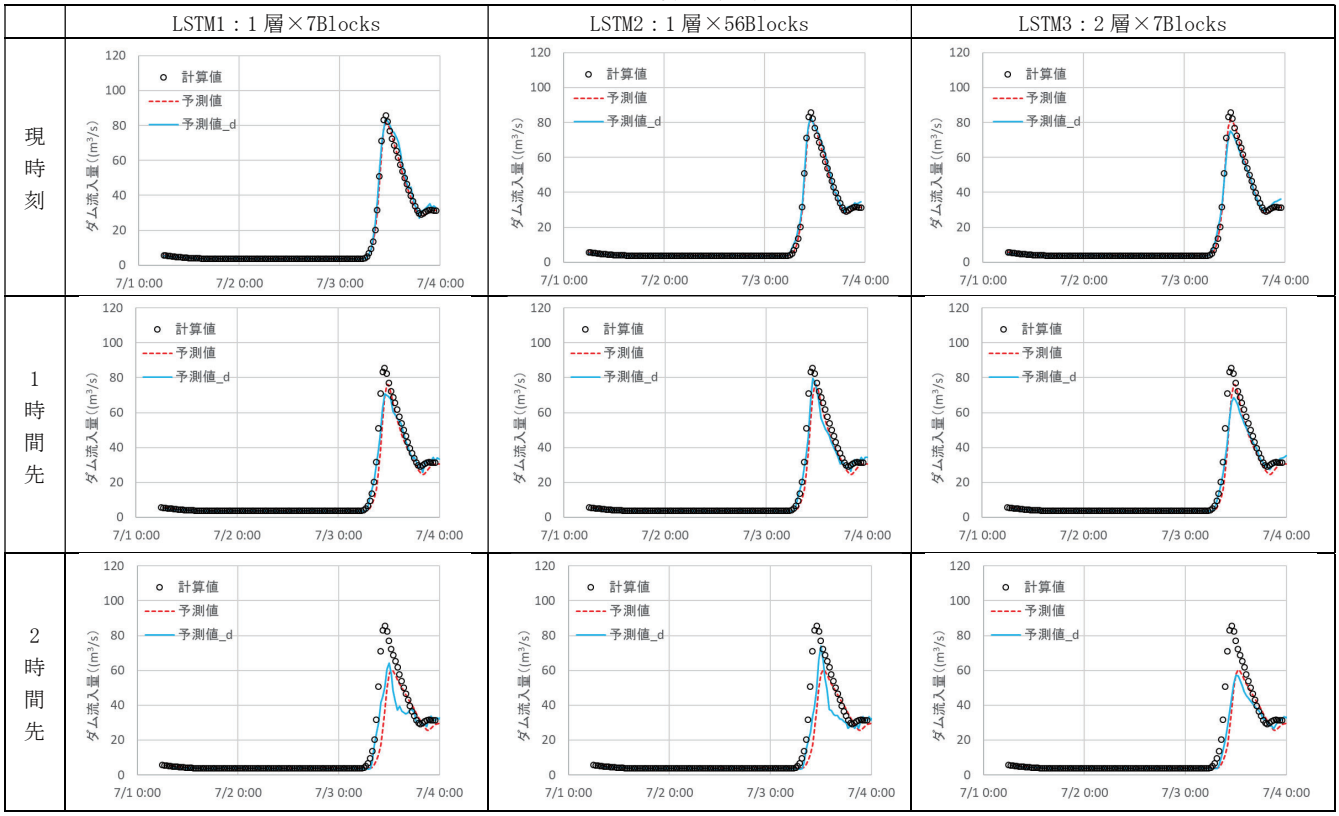


表 3　各 LSTM モデルの計算結果（H27. 7. 16 洪水）

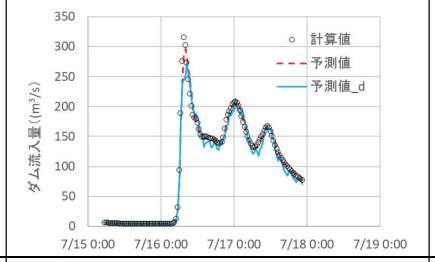
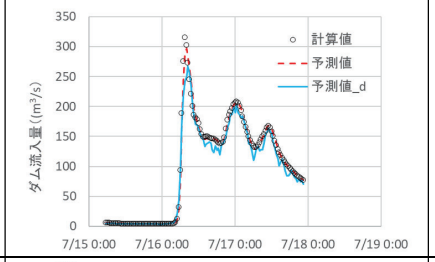
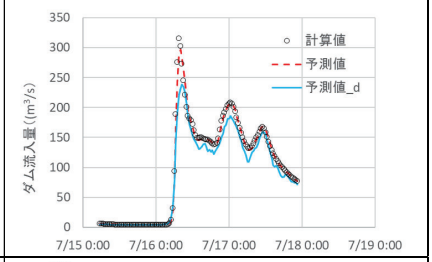
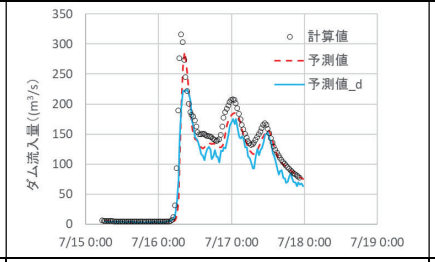
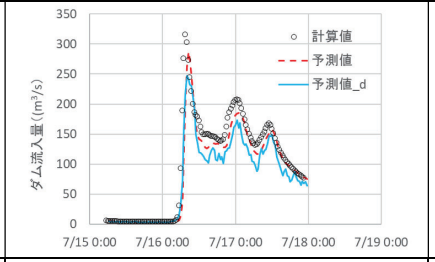
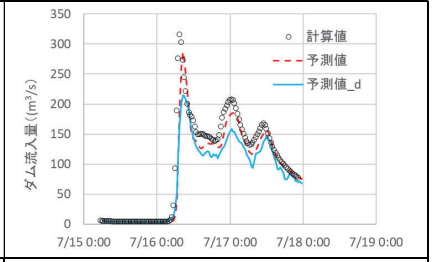
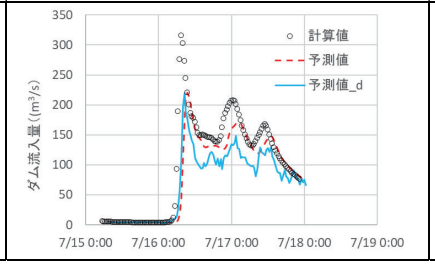
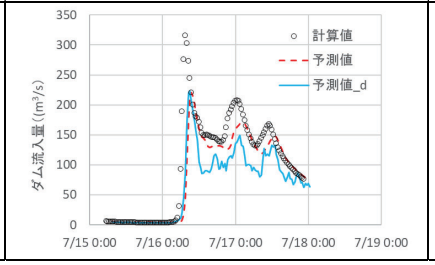
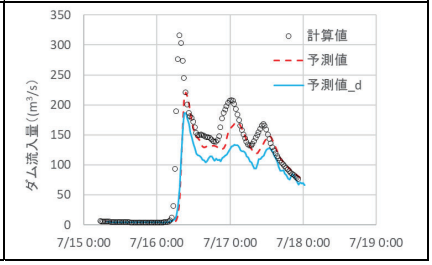
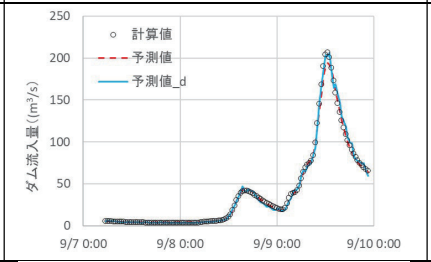
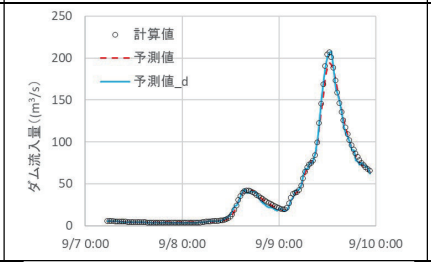
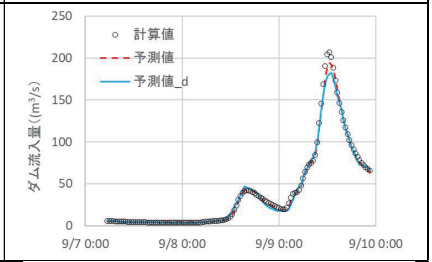
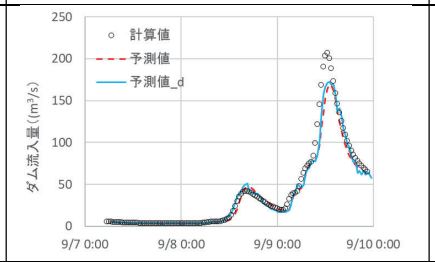
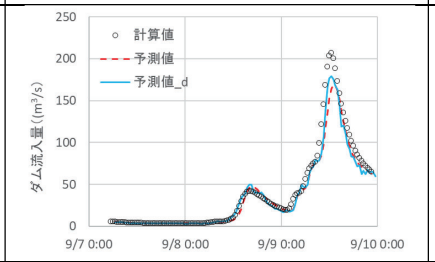
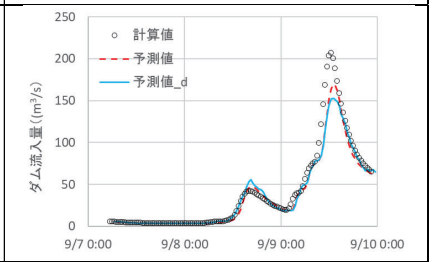
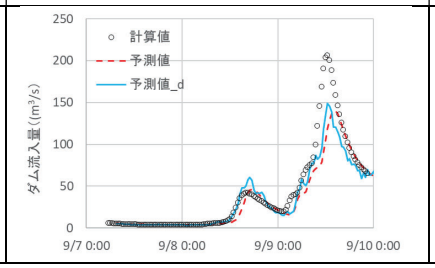
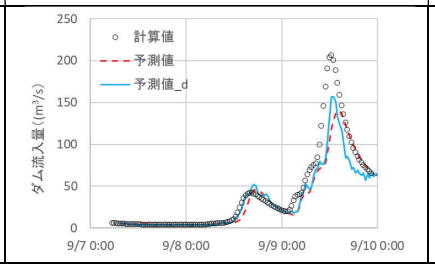
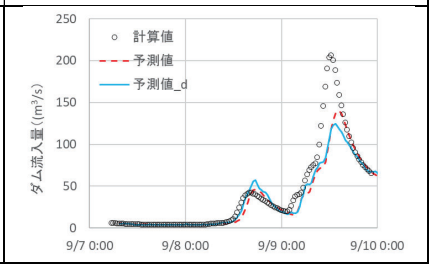
	LSTM1：1 層×7Blocks	LSTM2：1 層×56Blocks	LSTM3：2 層×7Blocks
現時刻			
1 時間先			
2 時間先			

表 4　各 LSTM モデルの計算結果（H27. 9. 9 洪水）

	LSTM1：1 層×7Blocks	LSTM2：1 層×56Blocks	LSTM3：2 層×7Blocks
現時刻			
1 時間先			
2 時間先			

注)表 2, 表 3, 表 4 の凡例説明

計算値(○印)：分布型流出解析モデルの出力値である真値

予測値(赤点線)：真値を基に学習したモデルの出力値(予測値)[どのグラフも 1 層×7Blocks モデルの計算結果を統一して記載]

予測値_d(青線)：真値にノイズを含めたデータを基に学習したモデルの出力値(予測値)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

線形回帰モデルを活用した深層時系列予測モデルの比較検討

Comparison of Deep Time Series Prediction Models Utilizing Linear Regression Model

保住 純 *1　　松尾 豊 *1
Jun Hozumi　　Yutaka Matsuo

*1東京大学
The University of Tokyo

Time series prediction is important for the industry and various prediction models have been proposed. Recently some reports showed that deep learning models have higher accuracy than traditional models. However, it is known that these models take longer time to learn and are difficult to maintain long-term periodicity. To deal with these problems, some researches on deep models with the concepts of autoregressive models have been proposed. However, since these models have not been compared with the same data and same settings, it is unclear which models are effective for diffrent tasks and different data. In this research, we apply these models to different types of time series data under different settings and examine the learning processes and results to capture the features of each model. The results confirmed the claimed merit of the model and suggested that simpler deep models are effective under complicated problems.

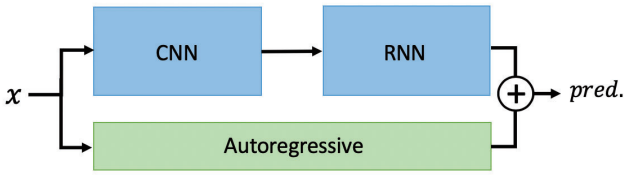


図 1: LSTNet の概念図

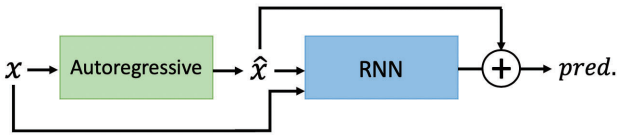


図 2: R2N2 の概念図

1. はじめに

時系列データの将来予測は産業上非常に重要であるため，これまでに様々な予測モデルが提案されてきた．また，機械学習分野における予測モデルの研究では，深層学習によるモデルが従来のモデルに比べて高い精度が出る事例も報告されている．しかし，深層学習を用いた予測モデルは，データ量が多くなると学習に要する時間が増大することや，長期にわたる周期性を保持し続けることが難しいことから，そのような性質を持つ時系列の予測には不向きであることも知られている [Goel 17]．そして，株価や商品売上など人間活動の記録によって発生する時系列データは，一週間や一年間といった複数種類の周期による影響を受けることが考えられる．

以上の問題を踏まえ，深層学習を用いたモデルの研究では，これまでに自己回帰モデル (Autoregressive Model; AR) の発想を取り入れることで周期性の保持や計算量の削減を実現した複数種類の手法 [Bińkowski 17, Goel 17, Lai 18] が提案されてきた．しかし，これらのモデルは同じデータや設定での比較した研究はなされていないため，データごとの各タスクに対しどのモデルが有効であるかは不明な点も残されている．

そこで，本研究ではこれらの手法を複数種の時系列データに対し異なる設定下で適用し，結果を比較検討することで各モデルの特徴を捉えることを目的とする．この成果は実業務における時系列予測において有用な示唆を示すとともに，今後の時系列予測手法の研究にも活かせるものであると考えられる．

連絡先: 保住 純，東京大学，hozumi@weblab.t.u-tokyo.ac.jp

2. 前提知識

本研究における予測の対象は一定の時間間隔でサンプリングされた時系列を想定し，以降時刻 t において観測された変数 x を $x(t)$ と記す．

2.1 線形自己回帰モデル

オーダーが N である線形自己回帰モデル $AR(N)$ は以下の式で示される．

$$x(t) = \sum_{k=t-(N-1)}^{t-1} a_k x_k + c + \epsilon(t) \quad (1)$$

式 1 中の c は定数項，ϵ はノイズを表す．

また，深層ネットワークにおいて AR モデルはベクトル $\mathbf{x}_{[t-k:t-1]}$ の単純な全結合層によって，ノイズ部分以外を計算することができる．

2.2 線形回帰モデルを活用した深層モデル

本節では前述した深層モデルの構造の概要および線形回帰モデルとの関連を紹介する．詳細については各論文を参照されたい．

2.2.1 LSTNet

LSTNet(Long- and Short- term Time-series Network)[Lai 18] は，図 1 で表されるように，深層ネットワークによる予測と線形自己回帰モデルによる予測を並行して実行し，最後に両方の出力の和をとって最終出力とするモデルである．深層ネットワーク側は CNN 層，RNN

層，全結合層の順で構成される．[Lai 18] ではタスクに応じて Skip-connetction や Attention Layer を導入することで精度を高める試みもなされている．

2.2.2 R2N2

R2N2(Residual RNN)[Goel 17] は，図 2.2 で表されるように，$x(t-1)$ までを入力として $x(t)$ を線形自己回帰モデルで予測を行い，その後，真の $x(t)$ の値との差分を RNN によって予測し，最後にそれらの和を予測値とするモデルである．言い換えるなら，R2N2 は線形自己回帰モデルを用いて大部分の予測を実行し，その結果生じた残差 $\epsilon(t)$ に相当する部分のみを RNN で学習させることで精度を高めるモデルであると言える．

2.2.3 SOCNN

SOCNN(Significance-Offset Convolutional Neural Network)[Bińkowski 17] は，時間方向の畳込み (Significiant-Network) によって式 1 における a の学習，データ間の畳込み (OffSet-Network) によって x の補正を行い，最終的にそれらを式 1 に当てはめて出力を算出するモデルである．OffSet-Network は入力が多変量である時系列に対して同時刻 t における特徴量の畳み込みを行うため，より強い補正効果が期待される．

3. 実験

3.1 設定

本研究では，前章で紹介した LSTNet, R2N2, SOCNN の他に，比較対象として線形回帰 (Linear)，3 層の多層パーセプトロン (MLP)，2 層 CNN，2 層 LSTM による時系列予測実験を行った．これらのはモデルは容量に大きな差が出ないよう層の数やノードの数を調整している．活性化関数は LeakyRelu，最適化関数は Adam，損失関数及び評価指標は平均二乗誤差 (MSE) として，それぞれ 5000epoch 学習させた．また，いずれのモデルも勾配が最大 1.0 になるよう Graident Clipping がなされている．

また，各予測モデルの特長を捉えるために，2 種類の時系列データで実験を実施した．1 つ目は人工データとして，以下の式 2 で表される周期性を持った時系列データを $t = 0$〜1825 の区間で作成した．

$$x(t) = \sin(\frac{\pi}{7}t) + 2\sin(\frac{\pi}{30}t) + 4\sin(\frac{\pi}{365}t) + 0.005t + \epsilon(t) \quad (2)$$

この時系列は複数の周期と振幅を持つ波形と，時刻とともに上昇するトレンドを足し合わせた波形となっており，$\epsilon(t)$ は平均 0，分散 1 の正規分布からなるノイズ項である．2 つ目は実世界のデータとして，日毎のドル円為替データ 5 年分 [*1] を使用した．

どの実験においても入力データ長は 90 とし，訓練データとテストデータはレコード数が 4:1 になるよう時間方向で分割し，双方に共通の変数が含まれないようにしてある．また，予測対象を入力データの直後 (0 日後) および 60 日のスキップ期間後という，複数の設定下で実験を行った．

3.2 結果

実験結果を表 1 に記す．括弧内の数字は入力データから予測対象までの日数を示す．

表 1: 各モデルの予測最高スコア (MSE)

モデル	人工 (0)	人工 (60)	為替 (0)	為替 (60)
Linear	10.69	10.62	8.66	10.64
MLP	11.03	10.83	8.24	17.39
LSTM	10.35	11.21	121.32	126.12
CNN	11.69	10.89	12.75	**6.21**
LSTNet	10.57	10.44	8.43	10.59
R2N2	10.62	**10.39**	8.47	10.58
SOCNN	**10.00**	10.52	**4.54**	6.44

まず，周期性を持たせた人工データの予測では，線形回帰モデルを併用したモデルはより高い精度を示しているものの，他の単純なモデルにおいてもそれに近い誤差を記録している．また，人工データの直後予測実験における，Epoch 数ごとのテスト誤差の推移を図 3 に示す．Epoch ごとの誤差の変化に注目すると，LSTNet, R2N2, SOCNN といった線形回帰を活用したモデルが DNN や LSTM など他の深層モデルに比べて早期に収束していることが確認される．このことから，時系列予測における深層モデルは，これらの論文で主張されている通り，線形モデルの併用が学習に要する時間を減らす効果があることが示唆される．また，この傾向は後述するドル円為替の時系列予測においても確認されている．

次に実データとしてのドル円為替の予測の結果を見ると，線形モデルを併用した深層モデルが全体的に良い精度を示している．また，直後については SOCNN，60 日後においては CNN が最も良い精度を示している．CNN を活用したモデルが高い精度を示している理由としては，畳込みによって時系列に含まれていたノイズの影響が軽減されていることにあると考えることができる．また，時間間隔を開けた場合には単純な CNN が精度を上回る結果となっていることや，LSTM ではどちらの実験においても良い精度が出ずに人工データの直後予測以外では他のモデルに比べて精度が悪くなっていることを踏まえると，予測対象までのスキップ期間が空いてしまう時系列予測タスクにおいては，線形モデルの併用や RNN の採用が予測に悪影響を及ぼしている可能性が示唆される．

以上の考察を踏まえると，そもそも自己回帰モデルが有効であると考えられる時系列予測タスクについては，線形モデルを活用した深層モデルが高い精度を示すものの，周期性が不明確であったり予測対象にスキップ期間が挟まるような複雑なタスクでは，単純な深層モデルや，線形モデルや RNN を採用せずに CNN を重視するモデルを用いるほうが，より高い性能を発揮されると考えられる．

4. まとめ

複数のモデルで実験を行った結果，線形自己回帰モデルが有効であると考えられる時系列予測タスクには，線形回帰モデルを活用した深層モデルがより有効であると言えるが，そう言えない時系列予測タスクはより単純な深層モデルや CNN を活用したモデル有効であることが示唆された．この結果は株価や消費電力量といった異なる実データや，スキップ期間の幅を変更する等さらなる検証実験が必要であると考えられる．

また，本研究では入力をスカラー列として実験したが，今回参考としたモデルは入力がベクトル列である多変量時系列回帰問題を想定しているため，その設定下では結果が変わることも大いに想定される．その場合における検証も今後の課題とする．

*1 https://www.federalreserve.gov/releases/h10/Hist/

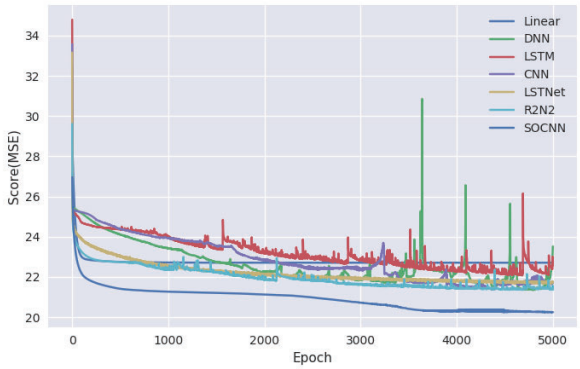


図 3: 人工 (0) における各 Epoch ごとのモデルのテスト誤差

参考文献

[Bińkowski 17] Bińkowski, Mikołaj, Gautier Marti, and Philippe Donnat. "Autoregressive convolutional neural networks for asynchronous time series." arXiv preprint arXiv:1703.04122 (2017).

[Goel 17] Goel, Hardik, Igor Melnyk, and Arindam Banerjee. "R2N2: Residual recurrent neural networks for multivariate time series forecasting." arXiv preprint arXiv:1709.03159 (2017).

[Lai 18] Lai, Guokun, et al. "Modeling long-and short-term temporal patterns with deep neural networks." The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval. ACM, 2018.

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

養殖場内の海水温予測モデルにおける要素と入力長の精度に及ぼす影響

The Effects of Element and Input Length on Accuracy in Aquaculture Seawater Temperature Prediction Model

奥野 聖人 *1　大塚 孝信 *2
Masahito Okuno　Takanobu Otsuka

*1名古屋工業大学
Nagoya Institute of Technology

*2名古屋工業大学大学院情報工学専攻
Department of Computer Science, Nagoya Institute of Technology

Aquaculture is globally important now, and because of the increase of worldwide demand, it will be more essential in the future. To supply stably, appropriate management of farm environment is necessary, and prediction of seawater temperature is important too. Therefore, to improve accuracy of seawater temperature prediction model is strongly needed. In this paper, we experiment prediction models that element and input length are different for the improvement of accuracy. From the experiment results, effective element and input length are revealed, and more improvement of prediction accuracy is expected in future.

1. はじめに

養殖業は現在, 世界的に重要である. 国内では海面漁業生産の約 24%を養殖業が占めており [1], 世界でも魚介類消費量の増加や漁業生産の頭打ちなどにより養殖業需要は急激に増加している [2]. 養殖を行う際, 養殖場内の環境管理が重要となる. 養殖では貝は筏に吊るされた籠の中など一定の位置で育成されるため自らの意思で移動することができず, 赤潮や海水温の変動が発生した場合にはへい死など大きな被害が発生する. 例として, 1996 年に代表的な真珠養殖場である三重県英虞湾にて感染症による日本産アコヤ貝の大量死が発生している. そのため, 安定した供給を行うためには養殖場内の環境管理が正確に行われる必要があり, 養殖場内の海水温変化を正確に予測することが重要となる. 本研究では養殖場内の海水温予測の更なる精度向上を目的とし, 予測モデル構築時の要素と入力長が精度に及ぼす影響を実験により明らかにする.

本論文の構成を示す. まず, 2 章で養殖の例として, 真珠養殖における水温管理の重要性と現状の課題について述べる. 次に, 3 章で養殖場内の海水温予測手法について述べる. 次に, 4 章で予測モデル構築時におけるデータの要素と入力長が精度に及ぼす影響について述べる. 最後に, 5 章で本稿のまとめと今後の課題を示す.

2. 真珠養殖と水温管理

2.1 真珠養殖の歴史と現状

真珠は貝から採取される宝石の 1 種であり, その希少性から世界各地で珍重されてきた. 養殖が行われる以前, 天然の真珠は 1 万個の貝から数粒程度しか産出されず, 大粒や真円の真珠は非常に価値のあるものであった. そのため古くから世界各地で真珠養殖に関する研究が行われており, 13 世紀の中国の仏像真珠などが例に挙げられる [3]. 1893 年 (明治 26 年) に御木本幸吉により世界で初めて半円真珠の養殖に成功し, その後 1904 年には見瀬辰平・西川藤吉による真円真珠の養殖の成功, 1920 年代には養殖技術が確立され, 養殖真珠が世界に供給されるようになった. その後, 1950 年代には世界の 9 割のシェアを日本が持つようになり, 三重 県, 和歌山県, 長崎県をはじめとして日本の輸出産業の一端を担った. しかし, 近年では世界各地で真珠養殖が行われるようになり, 日本のシェアは年々減少している. 日本の真珠養殖復興について, 2017 年 6 月 7 日に真珠振興法 [4] が施行され, 日本国として真珠養殖を補助する動向にある. また, 日本国内において真珠養殖生産高の最も高い三重県では, 1996 年に発生した感染症をきっかけに, 環境変化に強い品種改良を目的として, 日本原産アコヤ貝と日本産以外のアコヤ貝を交配させた貝を養殖に用いており, 現在養殖されているアコヤ貝はほぼ交配種となっている [5]. しかし, 交配種には日本産アコヤ貝と比較して以下のような問題がある.

- 1 級品と評価される割合が低い (品質が悪い)
- 性質が多様であり, 養殖管理の手段が複雑である (必要数以上の飼育が必要)
- 生殖巣に日本産アコヤ貝に見られない卵細胞の混入がある (品質低下の原因)
- 日本産特有の遺伝情報が失われる (種の保存)

以上の問題から, 環境変化には弱いが以前の日本産アコヤ貝を用いた真珠養殖に回帰することで日本産真珠のブランドイメージと売上を復興することが進められている. しかし, 日本産アコヤ貝は動物性プランクトンの大量発生によって引き起こされる赤潮や水温変化によるへい死率が交配種と比較して高く, 交配種以上に水温・水質管理を適切に行う必要がある.

2.2 水温管理の重要性と課題

真珠養殖では母貝から真珠が採取されるまでに, 数多くの作業が必要となる. 稚貝の育成から始まり, 真珠養殖に利用できる母貝に育つまでには 3 年程度の育成が必要となる. その後, 人の手により真珠核が母貝の中に挿入され, 更に半年以上の養成を経て養殖真珠が採取される. このように真珠が生産されるまでには 3〜4 年程度かかり, 一般的な魚類などに比べ長期間の管理が必要となる. また, アコヤ貝の適正水温は冬季は 10 ℃以上, 夏季は 25 ℃以下であり, 冬季は越冬場所で冬を越し, 夏季は水温の急上昇が予想される場合には筏を水温の低い場所に移動するといった対応が行われる. その際, 水温変化の正確な予測が重要となるが, 現状養殖従業者の経験と勘によって行われており, 従業者の高齢化や引退により予測技術が失われる恐れがあり, 真珠養殖の持続可能性が問題となっている.

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, 052-735-5287, otsuka.takanobu@nitech.ac.jp

海水温予測に関して, 海面水温や海流の予測は一般に行われている [6]. しかし, 養殖の場合海産物は主に水深 2m～10m 程度で育成され, この部分の海水温が重要となる. 真珠養殖の場合もアコヤ貝は水深 2m 付近で育成されるため, 一般の水温予測を養殖に利用することは困難である. また, 予測範囲の問題も存在する. 一般の水温予測は広範囲を対象としているが, 例として本研究の実験場である三重県英虞湾はリアス式海岸の特徴があり, 同じ湾内でも数℃水温に差が見られる場合もある. そのため, 養殖には実際の養殖箇所周辺の水温収集や予測が必要となる. また, 三重県真珠養殖協議会では 2007 年より”三重県真珠養殖関連漁場 水温モニタリングシステム”[7] にて図 1 の示す養殖場 4 箇所それぞれ水深 0.5m, 2.0m, 5.0m, 8.0m の 4 地点の水温を計測しており, 養殖従業者に水温データを提供している. 本研究ではこれらの観測データを用い, 予測モデルの構築を行なう.

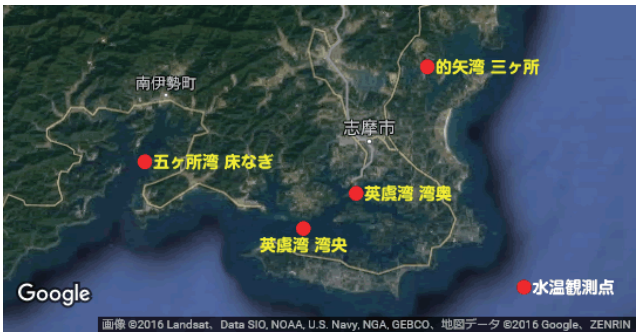


図 1: 三重真珠養殖場の水温観測地点

3. 観測データを用いた海水温予測

3.1 海水温データと気象データの取得

本研究では三重県真珠養殖場を実験場に設定し, 真珠養殖場 4 箇所を対象に予測を行なう. 海水温データに関しては, 先行研究 [8] において図 2 のような観測装置を用いて養殖場の海水温データをメールにて定期的に取得するシステムが構築されており, これを用いている.

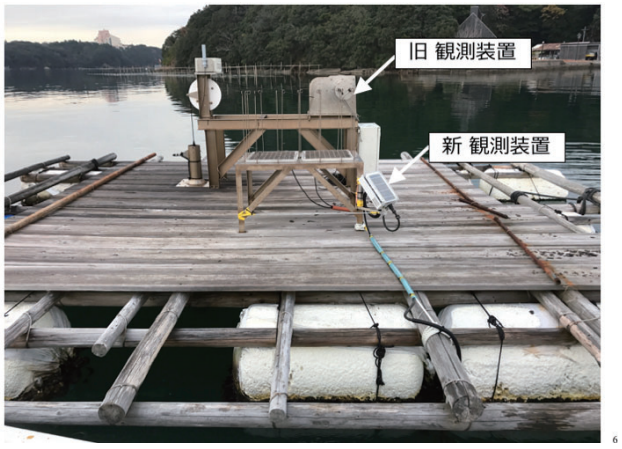


図 2: 養殖場内に設置された観測装置の外観

気象データに関しては, DarkSky[9] の API を用いて養殖場周辺の気象データを取得している. DarkSky は世界各地の気象データを提供するサービスであり, 詳細な位置指定と細かい時間単位での取得が可能となっている. 以下に DarkSky の特徴を示す.

- 世界各地の気象データを, 位置を緯度経度で指定可能
- 天気予報は 1 週間先まで, 過去の気象データは数十年前まで取得可能
- 1 時間毎や 1 日毎など, 様々な形のデータを JSON 形式で取得可能

3.2 海水温予測モデルの構築

予測モデルの構築を行う際, 学習のアルゴリズムとして Gated Recurrent Unit(GRU) を用いている. GRU は Reccurent Neural Network(RNN) の 1 種で, 代表的な RNN のモデルである LSTM と同様に学習時に過去の情報を考慮することが可能かつ, モデルがシンプルなため LSTM に比べ計算速度が早いという特徴がある. 先行研究 [8] では RandomForest が用いられていたが, 海水温予測を行う際に重要となるのは直前の海水温や気象の変化であり, RandomForest など単に過去データの組み合わせを学習するアルゴリズムではこの直前の変化を学習することは困難である. 一方, GRU ではデータを可変長の時系列の形で受け取るため直前の変化を学習することが可能であり, 高精度な予測を実現している.

また, 予測モデルを翌日までの 1 時間毎の予測を行う短期予測モデルと, 1 週間先までの 1 日毎の予測を行う長期予測モデルの 2 種類に分けて構築を行う. 実運用時を想定した場合, 予測が細かい時間単位であると 1 日の間の海水温変化が可視化され, 養殖従業者が利用しやすくなることや予測精度の向上が期待される. しかし, 予測が長期間になるに連れ 1 日の間の変化を予測することは困難となるため, 長期的な予測を細かい時間単位で行うことは現実的ではない. そのため, 予測モデルを短期と長期の 2 種類に分けることにより, 直近の予測は細かい時間単位での取得を可能とする一方, 長期的な予測も安定した精度で行うことが可能となり, 実用的な予測を実現している.

3.3 海水温予測の流れ

予測は, 3.1 節で述べた手法により取得した海水温データと気象データを学習済みの予測モデルに与え実行し, 結果をデータベースに追加する. また, 図 3 のような Web 上で現在の海水温や予測水温を確認可能なシステムを現在構築しており, 予測結果の可視化を今後行う予定である.

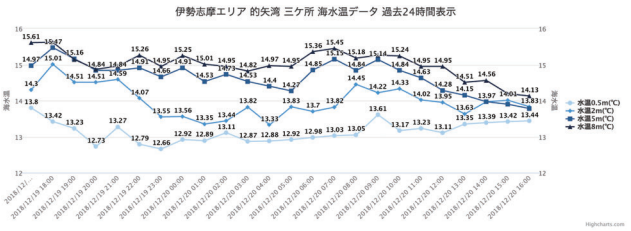


図 3: 予測結果等を表示する Web ページ

3.4 現状の予測精度

上記の手法を用いて試作した海水温予測モデルの実験結果を示す. 実験は各地点 1 年分の海水温データを用いて行われ, 表 1 は短期モデルの平均誤差, 表 2 は長期モデルの平均誤差を表している. 予測精度の指標として, 実際の養殖従業者から誤差± 1 ℃以内かつ 1 週間程度先のニーズがあることが仙台管

区気象台の報告 [10] で述べられている. そのため, 現状の予測モデルは全ての地点において平均誤差は十分な精度を示しており, 実運用時も問題ないと考えられる. しかし, 現状のモデルは外れ値など海水温の急変動に関しては精度が不十分であり, この部分に関して改善が必要である. 現状のモデルは予測に用いるデータの要素や入力長に関して十分に考慮されておらず, これらを適切なものにすることで更なる精度向上が期待される. 4 章ではモデル構築時の要素と入力長が精度に与える影響について実験を行なった結果について述べる.

地点	0.5m	2.0m	5.0m	8.0m
五ヶ所	0.385	0.275	0.236	0.245
的矢	0.385	0.282	0.233	0.263
英虞 湾奥	0.306	0.231	0.219	0.259
英虞 湾央	0.237	0.209	0.189	0.139

表 1: 短期モデルの平均誤差 (℃)

地点	0.5m	2.0m	5.0m	8.0m
五ヶ所	0.431	0.445	0.443	0.461
的矢	0.548	0.483	0.492	0.512
英虞 湾奥	0.385	0.409	0.444	0.491
英虞 湾央	0.328	0.316	0.256	0.259

表 2: 長期予測モデルの平均誤差 (℃)

4. モデル構築時のデータの要素と入力長

4.1 実験設定

予測モデルを構築する際, モデルに与えるデータの要素と入力長が精度に大きく関わってくる. そのため, 本研究ではこれらが予測精度に及ぼす影響について実験を行なった. 実験方法として, 水温データ, 気象データ毎に要素や入力長の異なるモデルを複数用意し, それぞれの精度を比較した. 比較は真珠養殖場のうち海水温変化が標準的な的矢湾を対象とし, 短期・長期モデル毎に 1 年分の海水温データを用いて平均平方二乗誤差 (RMSE) を算出している.

4.2 要素毎の比較

まず, データの要素毎の比較について示す. 水温データは予測水深のデータのみを用いた場合と, 予測水深に加え同じ湾内の他の水深のデータも合わせて用いた場合の 2 種類の比較を行った. 気象データは予測対象日の気象データと, 予測日直前の気象データを用いた場合を比較し, 長期モデルに関しては両方を合わせて用いた場合も追加して行なっている. 表 3 に短期モデルの結果, 表 4 に長期モデルの結果を示す. 表の上部分は水温データの比較, 表の下部分は気象データの比較を表している.

データの要素	0.5m	2.0m	5.0m	8.0m
予測地点のみ水温	0.587	0.446	0.383	0.423
予測+他の地点水温	0.592	0.409	0.361	0.422
予測対象日気象	1.215	1.196	1.234	1.199
予測日直前気象	1.142	1.154	1.22	1.138

表 3: 的矢湾での短期モデルの要素別 RMSE

データの要素	0.5m	2.0m	5.0m	8.0m
予測地点のみ水温	1.22	0.934	0.915	0.948
予測+他の地点水温	1.0	0.791	0.772	0.818
予測対象日気象	1.027	1.018	1.012	1.017
予測日直前気象	1.16	0.916	0.932	0.883
予測対象+直前気象	0.873	0.825	0.808	0.838

表 4: 的矢湾での長期モデルの要素別 RMSE

4.2.1 短期モデルの要素

まず短期モデルの比較についてだが, 水温データに関しては 0.5m, 8.0m 地点には差はないが, 2.0m, 5.0m 地点に関しては他の水深も合わせて用いた場合に RMSE の値が減少している. 真珠養殖の場合, アコヤ貝は主に水深 2.0m 付近で育成されるためこの部分の予測精度は重要となる. そのため, 短期モデルの水温データは予測地点に加え他の水深のデータも合わせて用いるべきだと考えられる.

気象データに関しては, どの水深においても予測日直前のものを用いた場合の方が RMSE の値が小さくなっている. これは気象条件の影響が水温変化に表れるまでには多少時間がかかることが原因であると考えられ, 今回の短期モデルのように翌日など短い期間の予測を行う際には予測日直前の気象データを用いることで精度が向上すると考えられる. 更に, 予測対象日の気象データを用いる場合, 予測の実運用時には天気予報データが用いられることとなる. この場合天気予報自体の精度の問題もあり, 検証時に比べ精度が大きく減少する可能性がある. それに対し直前のデータを用いる場合にはこのような問題を考慮する必要がなく, 実運用時も検証時と同様の精度で予測を行うことが可能となる. そのため, 短期モデルの気象データは予測日直前のものが良いと考えられる.

4.2.2 長期モデルの要素

次に長期モデルの比較についてだが, 水温データに関しては他の地点も合わせて用いた場合の RMSE の値が各水深大きく減少している. これは長期モデルの場合用いられるデータが日平均となるため, 予測地点のみのデータを用いる場合には予測に重要な直前の水温データが不十分となることが原因だと考えられる. そのため, 長期モデルの水温データは予測地点と他の水深を合わせて用いるべきだと考えられる.

気象データに関して, まず上 2 つの比較について述べる. 0.5m 地点に関しては予測対象日のデータを用いる場合の精度が高く, その他の地点に関しては予測日直前のデータを用いる場合の精度が高いという結果となっている. 長期モデルなど予測が長期にわたる場合, 予測対象日が離れるほど影響が弱くなるため, 直前のデータのみで予測することは困難となる. そのため, 特に気象の影響を受けやすい海面付近の 0.5m 地点の精度がこの場合悪くなったと考えられる. しかし, その他の水深に関しては予測対象日のものを用いた場合に比べ RMSE の値は小さく, どちらの要素を用いる場合にも利点と欠点が存在する. そのため, 長期モデルに関しては 2 つを合わせて用いたモデルを作成し, その場合の RMSE の値も算出した. 結果として, 片方ずつ用いた場合に比べ各地点 RMSE の値が大きく減少していることが表から分かる. このように気象データに関しては両方を合わせて用いることで双方の利点が反映され精度の向上が期待できるため, 長期モデルの気象データは予測対象日と直前のものを合わせたものが良いと考えられる.

4.3 入力長毎の比較

次に, データの入力長毎の比較について示す. 表 5 に短期モデルの結果, 表 6 に長期モデルの結果を示す. 要素の場合同様, 表の上部分は水温, 下部分は気象の場合を表している.

データ入力長	0.5m	2.0m	5.0m	8.0m
8 時間前水温	0.614	0.407	0.36	0.406
16 時間前水温	0.581	0.405	0.365	0.426
24 時間前水温	0.592	0.409	0.361	0.422
8 時間前気象	1.22	1.197	1.224	1.205
24 時間前気象	1.142	1.154	1.22	1.138
48 時間前気象	1.059	1.102	1.04	1.102
72 時間前気象	1.069	1.027	1.08	1.025

表 5: 的矢湾での短期モデルのデータ入力長別 RMSE

データ入力長	0.5m	2.0m	5.0m	8.0m
3 日前水温	1.133	0.847	0.83	0.861
7 日前水温	1.0	0.791	0.772	0.818
14 日前水温	0.96	0.754	0.755	0.772
21 日前水温	0.933	0.764	0.777	0.794
3 日先気象	1.131	1.05	1.02	1.08
5 日先気象	1.1	1.044	1.01	1.039
7 日先気象	1.027	1.018	1.012	1.017
7 日前気象	1.16	0.916	0.932	0.883
14 日前気象	1.032	0.846	0.83	0.84
21 日前気象	0.979	0.811	0.798	0.787

表 6: 的矢湾での長期モデルのデータ入力長別 RMSE

4.3.1 短期モデルの入力長

まず短期モデルの比較についてだが, 水温データに関しては 8 時間前から 16 時間前に増やした場合 RMSE の値は全体的に小さくなっているが, 16 時間前と 24 時間前では差が見られない. そのため海水温データに関しては 16〜24 時間前で十分であると考えられる.

気象データに関しては 48 時間前までは期間が長くなるにつれどの水深も RMSE の値が減少しているが, 72 時間前では値が増加している地点も見られる. そのため気象データは海水温に比べ長期間のものを用いる方が良いと考えられる. しかし, 72 時間前では精度が悪くなる地点が存在することからデータを長期にする場合には過学習などに注意する必要がある.

4.3.2 長期モデルの入力長

次に長期モデルの比較についでだが, 水温データに関しては 14 日前までは期間が長くなるにつれ各地点 RMSE の値が減少しているが, 21 日前では値が増加している地点も見られる. そのため海水温データは 14 日以上のデータを用いると良いと考えられるが, この場合も過学習に注意する必要がある.

次に気象データに関してだが, 予測日以降のデータの比較と予測日以前のデータの入力長について比較する. まず予測日以降に関しては, 5.0m 地点ではほぼ差は見られないが, その他の地点では予測日が長くなるにつれ RMSE の値が減少しており, 特に気象の影響を受けやすい 0.5m 地点では値が比較的大きく減少していることが分かる. そのため, 予測日以降の気象データは長期のものが良いと考えられる. 次に予測日以前に関してだが, この場合 21 日前までを用いたモデルの RMSE の値が各地点最も小さく, 長期的な予測を行う際には数週間前などの気象も精度に影響を与えている可能性が考えられる. しかし, 短期モデルでは気象データの期間が長くなると過学習の傾向が見られたことから, この部分については更なる検証が必要だと考えられる.

5. まとめと今後の課題

本論文では, 養殖場内の海水温予測モデル構築時におけるデータの要素と入力長が精度に及ぼす影響について示した. 実験により, 各モデルについて要素と入力長が精度にどのような影響を与えているかが RMSE の値で示され, 今後予測精度の更なる向上が期待される. しかし, 短期モデルの気象データに関しては RMSE の値が全体的に大きいため, 気温と風速以外の要因の調査が必要である. また, 今回は的矢湾のみを対象に比較を行なったため, 他の湾を予測対象としたモデルを構築する際はその湾の特徴を考慮するなど, 柔軟にモデルを構築する必要があると考えられる. 今後は本論文の結果の予測モデルへの反映と海水温変化要因の更なる調査を行い, 高精度な予測モデル構築実現に向け研究を行う. また海水温予測の可視化部分を実装し, 予測の実運用時の検証と評価も合わせて行い, 真珠養殖を始め養殖業の更なる発展を支援していく.

参考文献

[1] 農林水産省, ”平成 28 年度 海面漁業生産統計調査”(2016).

[2] 水産庁, ”平成 28 年度 水産白書”(2016).

[3] 真珠の養殖と加工, http://www.nihongo.com/aaa/pearl/p2youshoku/p21youshoku.htm (2019/2/14 参照)

[4] e-Gov 法令検索, ”真珠の振興に関する法律 (平成二十八年六月七日法律第七十四号)”, https://elaws.e-gov.go.jp/search/elawsSearch/elaws_search/lsg0500/detail?lawId=428AC1000000074 (2019/2/14 参照)

[5] NPO 法人水産業・漁村活性化推進機構, ”立神地域真珠養殖復興プロジェクト”, http://www.fpo.jf-net.ne.jp/ (2019/2/14 参照)

[6] 気象庁, ”海水温・海流のデータ 海面水温・海流 1 か月予報”, https://www.data.jma.go.jp/kaiyou/data/db/kaikyo/ocean/forecast/month.html (2019/1/28 参照)

[7] 三真協, ”三重県真珠養殖関連漁場 水温モニタリングシステム”, www.ohyamanet.info/~m-shinkyo/index.php(2019/2/14 参照)

[8] 大塚孝信, 北澤裕司, 伊藤孝行, ”持続可能な海産養殖のための海水温予測アルゴリズムの提案”, 情報処理学会論文誌ネットワークサービスと分散処理 (59-2) 特集 (2018/02)

[9] DarkSky, https://darksky.net/ (2019/2/13 参照)

[10] 中川憲一, 福田義和, 金子秀毅, 中村寛, 中村辰男, ”東北地方の養殖漁業のための沿岸水温予測手法の紹介”, 測候時報 第 85 巻 (2018)

General Session | General Session | [GS] J-2 Machine learning

[2Q3-J-2] Machine learning: explainability, knowledge acquisition

Chair:Yasuhiro Sogawa Reviewer:Shohei Higashiyama

Wed. Jun 5, 2019 1:20 PM - 3:00 PM Room Q (6F Meeting room, Bandaijima bldg.)

[2Q3-J-2-01] Investigation of the influence of over training on CNN focusing on change of heat map which brings interpretability

○Yoshihisa Furusawa[1], Yoshimasa Tawatsuji[3,2], Tatsunori Matsui[2] （1. Waseda University, 2. Faculty of Human Sciences, Waseda University, 3. Graduate School of Human Sciences, Waseda University）

1:20 PM - 1:40 PM

[2Q3-J-2-02] Visualization of cluster structure transition in deep learning

○Chihiro Watanabe[1] （1. NTT Communication Science Laboratories）

1:40 PM - 2:00 PM

[2Q3-J-2-03] Explanation of frequency domain features contributing to EEG classification

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

2:00 PM - 2:20 PM

[2Q3-J-2-04] Model-agnostic Explainer using Feature Patterns

○Kohei Asano[1], Jinhee Chun[1], Takeshi Tokuyama[1] （1. Tohoku University）

2:20 PM - 2:40 PM

[2Q3-J-2-05] Visualization of learning process for Convolution Neural Network

○Soichi Sakai[1], Yoichi Takenaka[2] （1. Graduate School of Informatics, Kansai University, 2. School of Informatics, Kansai University）

2:40 PM - 3:00 PM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

解釈可能性をもたらすヒートマップの変化に着目した過剰学習が CNN にもたらす影響の検討

Investigation of the influence of over training on CNN focusing on change of heat map which brings interpretability

古澤 嘉久 *1 FURUSAWA Yoshihisa
田和辻 可昌 *2*3 TAWATSUJI Yoshimasa
松居 辰則 *3 MATSUI Tatsunori

*1早稲田大学人間科学部 School of Human Sciences, Waseda University
*2早稲田大学 大学院人間科学研究科 Graduate School of Human Scineces, Waseda University
*3早稲田大学 人間科学学術院 Faculty of Human Sciences, Waseda University

Although Convolutional Neural Network (CNN) is used in many studies, the interpretability of CNN have been considered problematic and various methods have already been proposed from related research. All of these methods have been verified with selected models based on Early Stopping and are evaluated with only one model. However, in the classification problem, it is reported that the accuracy increases due to over training, so it is not known whether model selection by Early Stopping is appropriate. Therefore, in this research, the influence of this over training is considered from the viewpoint of the explanability of CNN. As a result, for each learning period, we found a dataset in which the value of the correct class and entropy of the output oscillate in the learning process. And we found that it is possible to create a heatmap with different similarity from the heatmap created by Early Stopping.

1. はじめに

近年の機械学習に関する研究の成果として, 特に画像分類に関しては, Convolutional Neural Network(CNN) が高い精度が出るようになり, 注目が集められている. しかし高い精度が出る反面, CNN は「どのようにしてその出力に至ったか」という人間にとっての解釈可能性に問題が残るモデルである.

この問題に関しては, すでに多くの既往研究により研究が進められており [Zhang 18], 入出力の関係を調査する際には, 最終層の出力の特定のクラスに関してのみ逆伝播を行い, 適宜制約を加えることで入力に寄与した画像箇所をヒートマップとして表現することによって, この CNN の解釈可能性を補う手法がいくつか提案されている.

そして, これらの解釈可能性を補う手法は Early Stopping などの指標に基づき学習を止めた学習済みモデルで評価を行なっている. しかしながら, Implicit Regularization と呼ばれる適当な条件下であれば, 学習回数を増やすほど対数的に精度が上昇する正則化現象が生じている [Soudry 18] ことから, 精度に関して言えば, Early Stopping によるモデル選択が最良なモデルを選択できるとは限らない可能性が示唆されている.

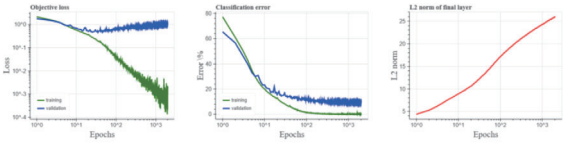
そこで本研究では, 既存の手法が Implicit Regularization が生じるような Early Stopping 以降の学習 (過剰学習) 過程における解釈可能性を補う手法が作成するヒートマップの変化を調査した. そして,Implicit Regularization による精度上昇がモデルにどのような影響を与えるかを実験的に評価した. また, 本研究の図中のプロットの横軸は特別な記載がない限り, 全て Epoch 数とする.

連絡先: 古澤 嘉久, 早稲田大学, 〒 359-1165 埼玉県所沢市堀之内 135-1 フロンティア リサーチセンター 213 実験室, f.y_1996_w-skk@akane.waseda.jp

2. 先行研究

2.1 Implicit Regularization

Implicit Regularization[Soudry 18] とは, 重みの初期値の値に依存することなく, 学習データでの損失関数の値が十分に小さくなった場合に, 適当な条件を満たしていれば, 学習データから学習した境界超平面付近のデータセットが摂動として作用し, 学習が進むことによって成立する重みの正則化現象である. これは例えテストデータにおける損失関数の値が上昇したとしても図 1 のように, テストデータに対するモデルの精度は非常に遅い速度ではあるが, 上昇するというものである. また [Soudry 18] によると, 適当条件にはいくつかあり, まず最適化手法として最急降下法を使用していること, そしてデータセットが Low Noise な線形分離可能なものであること. また, 損失関数の形がクロスエントロピー誤差のような指数型の損失関数であったり, 損失関数を各パラメータで偏微分したものが常に正の値をとるなどが挙げられる.



Epoch	50	100	200	400	2000	4000
L_2 norm	13.6	16.5	19.6	20.3	25.9	27.54
Train loss	0.1	0.03	0.02	0.002	10^{-4}	$3 \cdot 10^{-5}$
Train error	4%	1.2%	0.6%	0.07%	0%	0%
Validation loss	0.52	0.55	0.77	0.77	1.01	1.18
Validation error	12.4%	10.4%	11.1%	9.1%	8.92%	8.9%

図 1: [Soudry 2018] より結果の引用

2.2 解釈可能性を補う手法

本研究では, 過剰学習期間における解釈可能性を補う手法の影響を調査するために, 以下のような手法を使用した. そして今準備として, 入力画像を $\boldsymbol{x} \in \mathbb{R}^n$ とし, $i \in \{1, 2, ..., n\}$ をピ

クセルのインデックスとする. これを C クラス分類するモデルを考え, 入力画像 $\boldsymbol{x}$ に対して, クラス $c \in C$ の出力を $S_c(\boldsymbol{x})$ と表すことにする.

2.2.1 Saliency Map

[Simonyan 14] は, $S_c(\boldsymbol{x})$ が線形的なモデルの場合は, 入力画像に対する重要さとはそのモデルの重みとして表現されるとして, 下記のように, クラス c へ連結する重み $\boldsymbol{w_c} \in \mathbb{R}^n$ が重要さに該当していると主張する.$b_c \in \mathbb{R}$ はバイアス項.

$$S_c(\boldsymbol{x}) = \boldsymbol{w_c^T x} + b_c \tag{1}$$

また実際のモデル $S_c(\boldsymbol{x})$ は非線形であるため, 入力画像に関してテイラー展開し, 一次近似した際に, 以下のように入力画像での勾配が重み部分に該当することがわかる.

$$S_c(\boldsymbol{x}) \approx \boldsymbol{w^T x} + b, \ \ \boldsymbol{w} = \left.\frac{\partial S_c(\boldsymbol{x})}{\partial \boldsymbol{x}}\right|_{\boldsymbol{x}=\boldsymbol{x_0}} \tag{2}$$

そこで [Simonyan 14] は, 最終的なクラス c への出力から逆伝播を行い, 入力画像に逆伝播されてきた勾配を Saliency Map として採用することを提案している.

2.2.2 Deconvolution

[Zeiler 14] は, CNN の誤差逆伝播と同じ計算過程を誤差ではなく入力に対して行い, どの層の出力がどのような画像的特徴を持った箇所に寄与しているのかに関する調査を行なった. 本実験では, [Ramprasaath 17] のように誤差逆伝播の際の制約として, この Deconvolution の制約を使用する. 深層学習は, 誤差逆伝播法と呼ばれる最急降下法の各パラメータの更新に必要な勾配を連鎖律に基づき計算を行うが, この際に活性化関数に ReLU(max(0, x)) を使用する場合は, 入力時にユニットの出力が正をとる箇所のみに誤差が逆伝播していく. つまり, Deconvolution の制約とは, この ReLU の制約ではなく, 順伝播の際の出力にかかわらず勾配が正の値をとる時のみ逆伝播するというものである.

2.2.3 Guided Backpropagation

[Springenberg 15] は, 先ほど紹介した Deconvolution の制約と ReLU の制約を同時に満たす場合のみに逆伝播を行う手法を提案している. つまり, 順伝播の際には正となり, 逆伝播の際にも勾配が正となる箇所のみで逆伝播を行い, その他の部分はその層よりも入力側に存在する層には, 逆伝播をしないようしている. また今回は, 解釈可能性を補う手法としてではなく, 逆伝播される勾配の変化を見るために, Guided Backpropagation Minus として,Guided Backpropagation のように入力時に正となり, 勾配が負になるようなものを手法の一つとして使用する.

2.2.4 Grad-CAM

[Zhou 16] は, k 番目の特徴マップ $\boldsymbol{A^k} \in \mathbb{R}^{u \times v}$ とそれに対応する重み $a_k^c \in \mathbb{R}$ を用いた重み付け和を計算することで, 解釈可能性を補うヒートマップを出力する手法を提案している. つまり, 最終的なヒートマップ $\mathrm{L}^{\boldsymbol{c}}_{\text{Grad-CAM}} \in \mathbb{R}^{u \times v}$ は下記のようになる.

$$\mathrm{L}^{\boldsymbol{c}}_{\text{Grad-CAM}} = \ \mathrm{ReLU}\left(\sum_k \alpha_k^c \boldsymbol{A^k}\right) \tag{3}$$

$$\alpha_k^c = \frac{1}{Z}\sum_i^u \sum_j^v \frac{\partial S_c(\boldsymbol{x})}{\partial A_{ij}^k} \tag{4}$$

$z \in \mathbb{R}$ は正規化定数であり, 本研究では $u \times v$ を使用. つまり, α_k^c の計算は, 最終的なクラス c の出力である $S_c(\boldsymbol{x})$ から逆伝播を行い, 特徴マップ $\boldsymbol{A^k}$ に返ってきた勾配の幾何平均をとっている.

2.2.5 Guided Grad-CAM

Grad-CAM は, 特徴マップの重み付け和を行なっているため, 特徴マップの大きさとヒートマップの大きさが同じになり, 入力画像 x とサイズが異なってしまう. つまり, 入力画像と同じ解像度の画像として見た際に, ピクセル単位でのヒートマップにはならない. そこで, Grad-CAM により作成したヒートマップをバイリニアサンプリングし, 拡大した後に, 入力画像の要素積を計算することでピクセル単位での可視化を可能にしている.

3. データセットの選択

本研究は Early Stopping により学習をやめたモデルから, Implict Regularization により精度が上昇したモデルの変化を比較することを目的とするため, 下記のようなデータセットをテストデータより抜粋した.

3.1 選択基準

下記のような選択基準に基づきデータセットを抜粋した. この指標は, [Wang 16] が Active Learning の分野で使用した Least confidence の考えに基づいている. データの選択には式 (5) を使用し, 上の式は最終層の最大予測クラスと正解クラスが同じ場合に, 正解クラスの予測確率をとり, 異なった場合は, 最大予測確率と正解クラスの予測確率の絶対値をとる.

$$\begin{cases} S_c(\boldsymbol{x}) \left(\arg\max_{i \in C} S_i(\boldsymbol{x}) = c\right) \\ \left|\max_{i \in C} S_i(\boldsymbol{x}) - S_c(\boldsymbol{x})\right| \left(\arg\max_{i \in C} S_i(\boldsymbol{x}) \neq c\right) \end{cases} \tag{5}$$

3.2 データセットの作成方法

データの選択は, 二つのリストから行なっており, 一つ目は式 (5) の上の式についてまとめたリスト A であり, 二つ目は式 (5) の下の式についてまとめたリスト B がある. またこれを各クラスに対して行なった. そして, リスト A, B を共に降順に並べ, リスト A から上位 5 つをデータ A「明らかに正確に分類されているもの」とし, リスト B から上位 5 つをデータ B「明らかに誤分類されるもの」とし, リスト A から下位 3 つとリスト B の下位 3 つを合わせたものをデータ C「分類がどちらにもされうるもの」とした.

4. 対象となるモデルの作成

解釈可能性を補う手法を使用する対象であるモデルを作成した際の詳細と実験的に得られた知見について述べる.

4.1 モデル詳細

モデルとしては [Soudry 18] の実装を元に ResNet18[He 15] を採用した. データセットは CIFAR-10, 活性化関数は ReLU, 最適化手法はモーメンタム確率的最急降下法を使用.

4.2 結果

モデルを準備する上で図 2 のように, Implict Regularization の有無が発生に寄与している可能性が実験的に示唆された. 本研究では, Data Augmentation として, Random Crop と左右反転をしている.

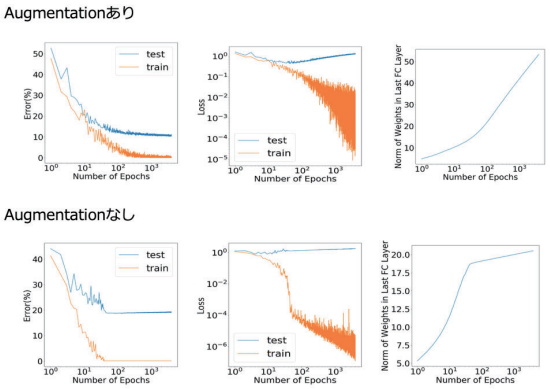


図 2: Augumentation の有無による影響. エラー率 (左図),Loss(中央図), 最終層の重み行列のノルム (右図)

5. 評価

解釈可能性をもたらすヒートマップの変化について考察をするために, まず定性的な変化を先ほどのデータセットに対して行い, 学習過程において, それぞれの手法がどのような変化をするか考察した. 次に定性的に敏感に変化していた手法に関して, SSIM(Structural Similarity), スピアマンの順位相関係数を用いて, Early Stopping を行なった際のヒートマップと各学習過程でのヒートマップの類似度を比較した. また Early Stopping によって選択したモデルが Epoch 数が 41 の時のモデルであるため, ヒートマップの比較に関しては, こちらを比較対象とする.

5.1 定性的評価

5.1.1 解釈可能性を補う手法の変化

選択したデータセットに関して, 各手法の変化の過程を定性的に評価した. 結果として, Saliency Map, Grad-CAM 系の手法は, 敏感に変化している様子が見て取れた. 変化の傾向としては, 局所的な特徴に留まるもしくは, 様々な箇所を可視化するようになるなど人間にとっての解釈性に問題が生じるということが実験的に確認された. また Grad-CAM 系に関しては, 図 3 のように,Implict Regularization によっても他のあまり変化しなかった既往研究の手法に関しては, [Nie 18], [Adebayo 18] からモデルの重みに依存しにくい手法と報告されているため, 今回も変化が少なかったと考えられた. また今回調査のために使用した Guided Backpropagation Minus に関しても変化があまり見られず, 逆伝播に単純な制約をつける手法は, モデルの変化に依存しにくい手法となる可能性も示唆されたと考えている. この変化の具合に関しては, 今回分割したデータ群において明らかな違いや傾向が見られなかった.

5.1.2 出力層のエントロピーと正解クラスの出力値の変化

図 4 は, データ C のクラス 0 の場合に, 対する出力層のエントロピーと正解クラスの予測確率と Epoch 数のプロットである. データ A に関しては, 下段中央図のようにエントロピー, 正解クラスの出力値共に 1 に近くで一定であった. そして, データ B, C に関してはエントロピー, 出力値共に振動するように, 不安定になる様子が多く見られた. この結果から,Implict Regularization は精度面では上昇するが, Early Stopping を採用したモデルの時点で「明らかに正確に分類されているもの」以外のデータセットでは, 出力が不安定になる可能性が示唆された.

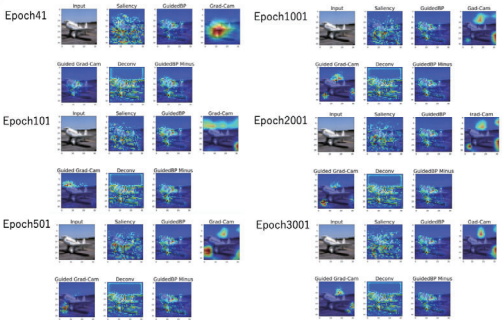


図 3: 学習過程ごとのヒートマップの変化

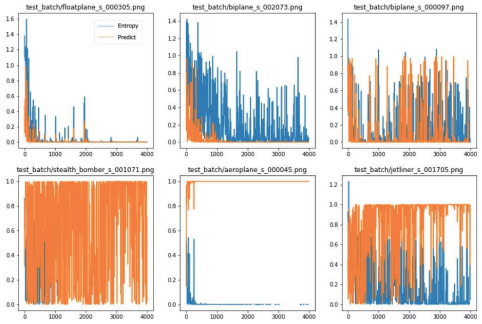


図 4: クラス 0(飛行機) に対する出力層のエントロピーと正解クラスの予測確率の変化

5.2 定量的評価

5.2.1 評価指標

本研究ではヒートマップの変化具合の定量的な評価を行うために, [Nie 18] を参考にし, SSIM とスピアマンの順位相関係数を使用した. SSIM とは, 画像圧縮の分野などで使用される指標であり, 0 から 1 の値をとり, 値が大きい方がより類似度が大きい画像とされている. また, 0.9 以上の値を下回ると画像としての劣化が見られるとされている.SSIM の定義に関しては, 下記のようになる. X,Y はそれぞれ比較する画像であり, window と呼ばれる crop 処理を行い, $\mathbf{x_j} \in \mathbb{R}^n$,$\mathbf{y_j} \in \mathbb{R}^n$ は, それぞれの画像から j 番目に crop してきた画像である.$\mu_x \in \mathbb{R}$ は,x_j 内の標本平均であり, σ_{xy} は不偏共分散, C_1, C_2 は定数項である.M は総 window 数である. そして, 全ての window に関しての SSIM の平均をとることで今回の指標とした.

$$\mathrm{SSIM}(\mathbf{x}, \mathbf{y}) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \tag{6}$$

$$\mathrm{MSSIM}(\mathbf{X}, \mathbf{Y}) = \frac{1}{M}\sum_{j=1}^{M} \mathrm{SSIM}(\mathbf{x}_j, \mathbf{y}_j) \tag{7}$$

次にスピアマンの順位相関係数について説明する. スピアマンの順位相関係数はノンパラメトリックな指標の一つであり, -1 から 1 の値をとり, 絶対値が大きい方が強い相関を表している. d_i は, 画像 X,Y の同じ位置にある i 番目インデックスを表し, その順位の差である. n は総ピクセル数.

$$r_s = 1 - \frac{6\sum_{i=1}^{n} d_i^2}{n(n^2 - 1)} \tag{8}$$

5.2.2 変化に関する評価

定性的に評価した際に, Saliency Map と Grad-CAM 系の手法がモデルに対して敏感な変化をしていたことから,Saliency Map と Grad-CAM に絞り, 上記の指標を用いて定量的に評価を行なった. 結果としては, 過剰学習期間においてのヒートマップを比較した際に, 図 5 のように SSIM に関しては 0.4 以下になり, スピアマンの順位相関係数に関しては 0.4 以下になった. 特に 1000Epoch 以上学習させた場合に関しては, 全てのデータセット・指標において 0.3 以下になった. つまり, どちらも Early Stopping で学習を止めた場合と画像としての類似度に違いがでていることが確認された.

また, Saiency Map は全てのデータセットと学習期間に対して, スピアマンの順位相関係数が 0.1 以下と小さくなっていた. 既往研究よりノイズがひどい手法であることが問題視されている手法であるため [Smilkov 18], 物体の存在しない部分の順位の大小が結果に大きく反映されている可能性が考えられた. そこで, SmoothGrad[Smilkov 18] のような Saliency Map と同じように制約の加えていない入力層での勾配を使用しつつ, ノイズの少ない手法での評価を追加し, 行う必要があることが示唆された.

スピアマンの順位相関係数に関して,Grad-CAM の方が Saliency Map よりも大きくなっている背景としては, Grad-CAM は, 最終出力が 0 以上になるように処理されるため, マイナスの出力は 0 に直されることがあげられた. これは, 物体の存在する可視化を行なっているために, 物体外に存在する箇所に関しては 0 となり, その部分に順位の違いが生じにくいと考えられルためである. この結果から, モデル選択として, Implicit Regularization を考慮し学習を続けることは, Early Stopping により作成したヒートマップとは異なったものを作成するようになるため, いたずらに学習をさせ続ければ良いとはならない可能性が示唆された.

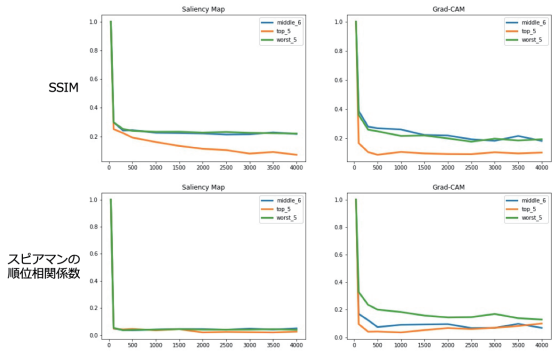


図 5: 学習過程ごとの SSIM(上段) とスピアマンの順位相関係数 (下段) の変化

6. まとめと今後の展望

本研究により, 出力層のエントロピーと出力値が振動するように学習が進む傾向がいくつかのデータセットにおいて見られ, それは主に「明らかに正確に分類されているもの」以外のデータセットで見られた. 解釈可能性を補う手法に関しては, Grad-CAM 系の手法は Implicit Regularization の影響を受けやすく, Grad-CAM によるヒートマップは過剰学習の与える精度の上昇によって, 局所的な特徴に留まるもしくは, 様々な箇所を可視化するようになるなど大きく変化する傾向にあることが定性的評価から確認された. また, 定量的な評価に関しても, 画像としての類似度は低下していることが確認された. 今後の展望としては, 変化したヒートマップが人間にとっての可読性に沿っているかを評価するために, [Ramprasaath 17] のようにアンケート調査を行い, Early Stopping と比べた際に人間にとっての可読性に差が現れるか調査する必要がある. また, その他のデータセット, モデルでの評価を行い, この結果が CIFAR-10 と ResNet 系のモデル特有のものであるかという汎用性に関する調査が必要である.

参考文献

[Adebayo 18] Julius Adebayo, Justin Gilmer, Michael Muelly, Ian Goodfellow, Moritz Hardt, Been Kim: Sanity Checks for Saliency Maps, Advances in Neural Information Processing Systems 31, (2018)

[He 15] Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun: Deep Residual Learning for Image Recognition, Large Scale Visual Recognition Challenge 2015, (2015)

[Nie 18] A Theoretical Explanation for Perplexing Behaviors of Backpropagation-based Visualizations: Weili Nie, Yang Zhang, Ankit Patel, International Conference on Learning Representations 2018, (2018)

[Ramprasaath 17] Ramprasaath R. Selvaraju, Michael Cogswell, Abhishek Das, Ramakrishna Vedantam, Devi Parikh, Dhruv Batra: Grad-CAM:Visual Explanations from Deep Networks via Gradient-based Localization, International Conference on Computer Vision 2017, (2017)

[Simonyan 14] Karen Simonyan, Andrea Vedaldi, Andrew Zisserman: Deep Inside Convolutional Networks: Visualising Image Classification Models and Saliency Maps, International Conference on Learning Representations 2014, (2014)

[Soudry 18] Daniel Soudry, Elad Hoffer, Nathan Srebro: The Implicit Bias of Gradient Descent on Separable Data, International Conference on Learning Representations 2018, (2018)

[Springenberg 15] Tobias Springenberg, Alexey Dosovitskiy, Thomas Brox, Martin Riedmiller: Striving for Simplicity: The All Convolutional Net, International Conference on Learning Representations Workshop 2015, (2015)

[Smilkov 18] Daniel Smilkov, Nikhil Thorat, Been Kim, Fernanda Vi egas, Martin Wattenberg: SmoothGrad: removing noise by adding noise, International Conference on Machine Learning Workshop 2018, (2018)

[Wang 16] Keze Wang, Dongyu Zhang, Ya Li, Ruimao Zhang, Liang Lin: Cost-Effective Active Learning for Deep Image Classification, Transactions on Circuits and Systems for Video Technology 2016 (2016)

[Zeiler 14] Zeiler,M. D.,Fergus, R: Visualizing and understanding convolutional networks, European Conference on Computer Vision 2014, No.818 833 (2014)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

深層学習の学習経過におけるクラスタ構造の推移の可視化

Visualization of cluster structure transition in deep learning

渡邊千紘 *1
Chihiro Watanabe

*1NTT コミュニケーション科学基礎研究所
NTT Communication Science Laboratories

Deep neural networks have achieved high performance in various tasks, and to interpret their prediction mechanism is an important open problem. Recently, a series of methods have been proposed for decomposing a trained neural network into a simple interpretable module structure. In this paper, to acquire knowledge about the training process of a deep neural network, we proposed a method for visualizing the cluster structure transition during the training phase. Our proposed framework consists of two parts: we first decompose the network at each training step into modules based on hierarchical clustering, and then reveal the relationships between clusters at different training steps based on the ratio of their common units. The experimental results showed that our proposed method could provide us with knowledge about division and integration of neural network modules, and also information about the role of each module in terms of input-output mappings.

1. はじめに

深層学習における学習結果を人間が解釈するための手法を構築することは，近年の機械学習分野における主な課題のひとつである．深層ニューラルネットは，画像認識や音声変換など，多様な課題において有効性が確認されているが，その学習結果として得られる関数は深い階層構造を通した非線形変換の繰り返しで表現され，予測の仕組みをそのまま人間が理解することは困難である．

近年，ニューラルネットの学習結果の解釈性向上を目的として，データから学習されたニューラルネットをモジュール構造に分割する手法が提案されている [1, 2, 3]．これらの手法は，ニューラルネット全体をひとつのブラックボックス関数とみなしてその挙動を解析する手法 [4, 5] や，ユニットや層など決められた単位での挙動を解析する手法 [6, 7] と異なり，ニューラルネットにおいて類似した役割を持つ部分構造を自動的に獲得できるという利点がある．

本論文では，学習済みニューラルネットをモジュール構造に分解する手法を，ニューラルネットの学習時における各エポックでの学習結果に対して適用することにより，深層学習の学習経過におけるクラスタ構造の推移を可視化する手法を提案する．この手法により，ニューラルネットの学習過程において，隠れ層におけるユニットの (1) 異なる役割を持つ部分への分割と，(2) 類似した役割を持つ部分の統合がどのようになされているかを知ることが可能になる．

実際に，画像認識を行うように学習された深層畳み込みネットワークに対し，提案法を適用することにより，学習の過程において隠れ層のユニットが分割・統合されていく様子を可視化する実験を行い，提案法の有効性と課題の検討を行った．

2. ニューラルネットのモジュール構造抽出

本節では，与えられた学習データを用いて学習済みのニューラルネットにおいて，各隠れ層のユニットが持つ役割を表す特徴ベクトルを定義し，それに基づいて階層的クラスタリングを適用することにより，ニューラルネットを類似する役割を持つモジュール構造に分解する手法を説明する．

2.1 隠れ層の各ユニットに対応する特徴ベクトルの定義

まず，学習済みのニューラルネットが与えられたとき，各隠れ層のユニット k が果たす役割を表す特徴ベクトル v_k を定義する．本論文では，特徴ベクトル v_k を，ユニット k の出力値と各入出力次元の値との相関に基づいて定義することとする．これにより，ユニット k が主に，入力データのどの次元の値を用いて，どの出力次元の値を予測するのに用いられているか（画像認識のタスクであれば，ユニット k が入力画像のどの画素の値を用いて，どの出力クラスの認識を行っているか）を定量的に求めることができる．

2.1.1 i 番目の入力次元の値が隠れ層のユニット k の出力値に与える影響の大きさ

i 番目の入力次元の値が隠れ層のユニット k の出力値に与える影響の大きさ v_{ik}^{in} を，以下の式で定義する．

$$v_{ik}^{\mathrm{in}} = \frac{E\left[\left(X_i^{(n)} - E[X_i^{(n)}]\right)\left(o_k^{(n)} - E[o_k^{(n)}]\right)\right]}{\sqrt{E\left[\left(X_i^{(n)} - E[X_i^{(n)}]\right)^2\right]E\left[\left(o_k^{(n)} - E[o_k^{(n)}]\right)^2\right]}}.$$

ただし，$E[\cdot]$ は全学習データに対する平均値を表し，$X_i^{(n)}$ を n 番目の学習データに対する i 番目の入力次元の値，$o_k^{(n)}$ を n 番目の学習データに対する（学習済みニューラルネットにおける）ユニット k の出力値とする．

2.1.2 隠れ層のユニット k の出力値が j 番目の出力次元の値に与える影響の大きさ

隠れ層のユニット k の出力値が j 番目の出力次元の値に与える影響の大きさ v_{kj}^{out} を，以下の式で定義する．

$$v_{kj}^{\mathrm{out}} = \frac{E\left[\left(o_k^{(n)} - E[o_k^{(n)}]\right)\left(y_j^{(n)} - E[y_j^{(n)}]\right)\right]}{\sqrt{E\left[\left(o_k^{(n)} - E[o_k^{(n)}]\right)^2\right]E\left[\left(y_j^{(n)} - E[y_j^{(n)}]\right)^2\right]}}.$$

ただし，$y_j^{(n)}$ を n 番目の学習データに対する j 番目の出力次元の値とする．

連絡先: chihiro.watanabe.xz@hco.ntt.co.jp

Algorithm 1 学習済みニューラルネットにおける隠れ層のユニットの特徴ベクトル $\{v_k\}$ に対する階層的クラスタリング

1: 隠れ層のユニット k の特徴ベクトルを v_k とする（$k = 1, \cdots, k_0$）．各時刻 t において，クラスタ m に割り当てられたユニットの集合を $\{C_m^{(t)}\}$ とおく．$t \leftarrow 1, C_m^{(1)} \leftarrow \{m\}$.
2: ユニット i, j の特徴ベクトル間のコサイン距離を以下で定義する：$f(i,j) \equiv 1 - (v_i \cdot v_j)/(\|v_i\|_2 \|v_j\|_2)$.
3: コサイン距離に基づくクラスタ C_1, C_2 間の距離を以下で定義する：$d(C_1, C_2) \equiv (\sum_{i \in C_1, j \in C_2} f(i,j))/(|C_1||C_2|)$.
4: **for** $t = 2$ to $k_0 - 1$ **do**
5: $(m_1^*, m_2^*) \leftarrow \arg\min_{(m_1, m_2)} d(C_{m_1}^{(t-1)}, C_{m_2}^{(t-1)})$.
6: $m_1^* < m_2^*$ と仮定し，以下のようにクラスタを更新する．

$$C_m^{(t)} \leftarrow \begin{cases} C_{m_1^*}^{(t-1)} \cup C_{m_2^*}^{(t-1)} & (m = m_1^*) \\ C_m^{(t-1)} & (m \leq m_2^* - 1, m \neq m_1^*) \\ C_{m+1}^{(t-1)} & (m_2^* \leq m) \end{cases}.$$

7: **end for**

2.1.3 隠れ層のユニット k の特徴ベクトル

2.1.1, 2.1.2 節の定義に基づき，隠れ層のユニット k の特徴ベクトルを以下で定義する：$v_k \equiv [v_{1k}^{\text{in}}, \cdots, v_{i_0 k}^{\text{in}}, v_{k1}^{\text{out}}, \cdots, v_{kj_0}^{\text{out}}]$. ただし，$i_0$ は入力次元の数，j_0 は出力次元の数を表す．定義より，特徴ベクトル v_k は，ユニット k の出力値と各入出力次元の値との相関値を並べたベクトルであり，ユニット k がどの入力次元の値を主に用い，どの出力次元の予測に寄与するかを表すという意味で，ユニット k の推論における役割を表すものとなっている．

2.2 階層的クラスタリングに基づくユニットの分類

2.1 節で定義した特徴ベクトル $\{v_k\}$ に基づき，隠れ層のユニットのクラスタリングを行う．本論文では，ユニット i, j の特徴ベクトル間の距離をコサイン距離

$$f(i,j) \equiv 1 - \frac{v_i \cdot v_j}{\|v_i\|_2 \|v_j\|_2}.$$

で測るものとし，クラスタ C_1, C_2 間の距離を以下で定義する．

$$d(C_1, C_2) \equiv \frac{1}{|C_1||C_2|} \sum_{i \in C_1, j \in C_2} f(i,j).$$

上記の定義に基づき，全てのユニットが異なるクラスタに属する状態を初期状態として，各時刻で距離が最小のクラスタ対を 1 つのクラスタに統合することを繰り返す．全てのユニットが 1 つのクラスタに属する状態になった時点でクラスタリングを終了する．階層的クラスタリングの手続きの全体を Algorithm 1 に記載した．

3. ニューラルネットの学習経過におけるクラスタ構造の推移の可視化

ニューラルネット学習時の各エポックごとに，学習されたニューラルネットに対し 2. 節に述べたモジュール構造抽出法を適用することで，ニューラルネットの学習が進むにつれ，そのモジュール構造や各モジュールの役割がどのように変化していくかを知ることができる．以下では，s エポックの学習が完了した時点でのニューラルネットのクラスタを $C_1^{(s)}, \cdots, C_{m_s}^{(s)}$ とし（$s = 1, \cdots, s_0$），ニューラルネットの学習経過におけるクラスタ構造の推移を可視化するための手法について説明する．

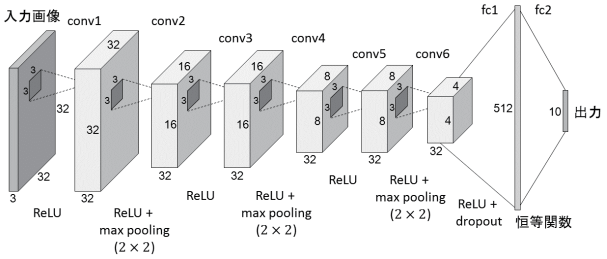


図 1: CIFAR-10 [8] の学習に用いたニューラルネットの構造

本論文では，ニューラルネットの学習経過におけるクラスタの分割や統合の様子を可視化するために，エポック (s_1, s_2) におけるクラスタ間の関係を行列 $R^{(s_1,s_2)}$ で表す．具体的には，s_1 エポックの学習完了時の m_1 番目のクラスタ $C_{m_1}^{(s_1)}$ と，s_2 エポックの学習完了時の m_2 番目のクラスタ $C_{m_2}^{(s_2)}$ の関係を，以下のように定義する．クラスタ $C_{m_1}^{(s_1)}$ に含まれるユニットの数 $|C_{m_1}^{(s_1)}|$ に対する，クラスタ $C_{m_1}^{(s_1)}$ とクラスタ $C_{m_2}^{(s_2)}$ に共通するユニットの数 $|C_{m_1}^{(s_1)} \cap C_{m_2}^{(s_2)}|$ の割合を行列 $R^{((s_1,s_2)}$ の (m_1, m_2) 成分として定義する．

$$R_{m_1,m_2}^{(s_1,s_2)} \equiv \frac{|C_{m_1}^{(s_1)} \cap C_{m_2}^{(s_2)}|}{|C_{m_1}^{(s_1)}|}.$$

上記の行列 $R^{(s_1,s_2)}$ から，エポック (s_1, s_2) 間でのクラスタ構造の推移について知識を得ることができる．

4. 実験

10 種類のクラスからなる画像データセット CIFAR-10 [8] を用いて，画像認識を行うニューラルネットの学習を行い，提案法を適用することにより，ニューラルネットの学習経過におけるクラスタ構造の推移の可視化を行った．

ニューラルネットの学習においては，図 1 に示す畳み込みネットワークを用い，学習率は Adam [9] に基づいて決めることとし，バッチサイズを 100, エポック数を 30 とした．全ての畳み込み層において，サイズ 1 の padding を適用した．

学習されたニューラルネットに対し，全学習データの中からランダムサンプリングした 2500 個の入力データを用いて特徴ベクトルの計算を行った．ここで，あるユニットの出力値の入力データに対する分散が 0 であるとき，各入出力次元の値との相関値が定義できないため，そのようなユニットは削除してから階層的クラスタリングを適用した．各エポックの学習完了時におけるニューラルネットに対し，2.2 節に述べた手法に基づき階層的クラスタリングを行い，各クラスタ内の 2 点におけるコサイン距離が 0.83 以下となるようなクラスタ構造のうち，最大のクラスタ数を持つものを結果として用いた．3. 節に述べた手法に基づき，学習経過におけるクラスタ構造の推移を可視化した結果を図 2 に示した．また，1, 10, 20, 30 エポックにおける各クラスタのセントロイドをそれぞれ図 3, 4, 5, 6 に示した．

図 2 より，$(1, 10)$, $(10, 20)$ エポック間では，行クラスタに含まれるユニットのうち大部分が 1 つの列クラスタに割り当てられるケースが多く，行クラスタが複数の列クラスタに均等に分割されるケースは少ないことが分かる．一方，$(20, 30)$ エポック間では，行クラスタが分割され異なる列クラスタに統合されるケースが比較的多く見られる．また，図 3, 4, 5, 6 か

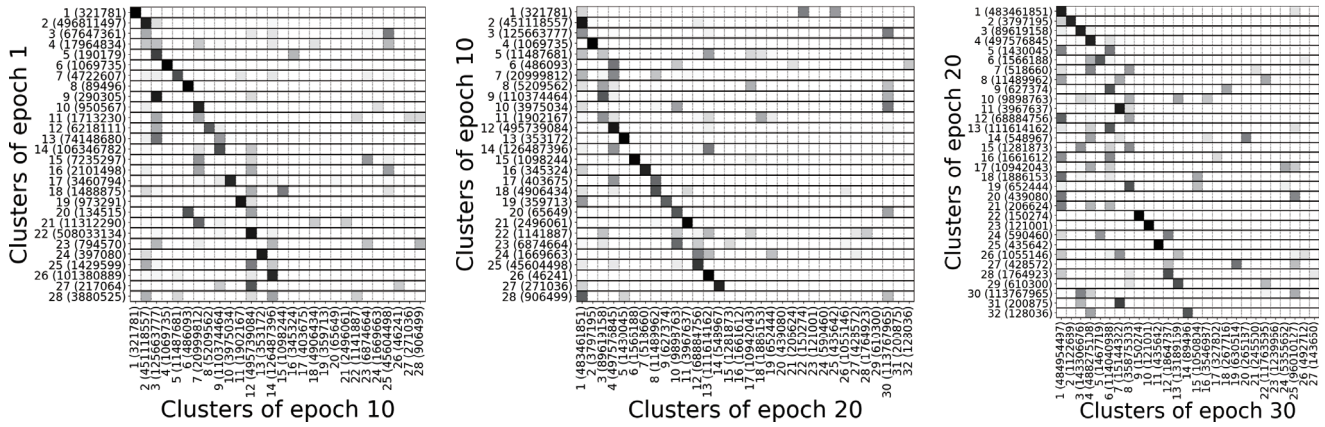


図 2: ニューラルネットの学習経過におけるクラスタ構造の推移．左から，$(1, 10)$, $(10, 20)$, $(20, 30)$ エポックの学習完了時におけるクラスタ間の関係を表す．行列の各行は，その行に対応するクラスタに含まれるユニットが，各列に対応するクラスタに分割される（行クラスタ内のユニット数に対する）割合を表す．かっこ内の数字は各クラスタに割り当てられたユニットの数を表す．

ら，学習経過における各クラスタの代表的な役割について知ることができる．たとえば，30 エポックの学習完了時におけるクラスタ 21（図 6）は，入力画像の中心に馬のような形があり，背景が緑色であることの情報を主に用いており，出力への寄与としては主に馬の認識を行うのに用いられていることがわかる．また，図 2 より，このクラスタは 20 エポックの学習完了時におけるクラスタ 7 に含まれるユニットの一部からなり，このクラスタ 7 も類似した役割を持つことが図 5 より読み取れる．他にも，例えば 30 エポックの学習完了時におけるクラスタ 25（図 6）は，主に自動車やトラックの画像と，それ以外の画像との判別に用いられていることが分かる．

5. 考察

本論文の提案手法に基づき，ニューラルネットの学習経過におけるクラスタ構造の推移を可視化することが可能になったが，この手法により得られる結果は，各クラスタ内の 2 点におけるコサイン距離の上限を示すハイパーパラメータを変化させることにより異なるものになる．このハイパーパラメータの値を大きくすれば，粗いクラスタ構造が得られ，各エポックにおける数の代表的なクラスタとその役割を知ることができるが，役割が大きく異なるユニットも同一クラスタに割り当てられてしまい，各クラスタの役割がセントロイドから読み取りづらくなる（符号のキャンセリングにより，どの入出力とも相関が見られなくなる）可能性がある．このことは，本論文の実験結果において，各クラスタにおける入出力との相関値の平均が比較的小さな値となったことの原因になっている（実際，1, 10, 20, 30 エポックにおいて，ユニット単位での入力次元との相関値の範囲はそれぞれ $[-0.71, 0.99]$, $[-0.71, 0.99]$, $[-0.71, 0.99]$, $[-0.71, 0.99]$ であり，出力次元との相関値の範囲はそれぞれ $[-0.59, 0.60]$, $[-0.60, 0.60]$, $[-0.58, 0.61]$, $[-0.58, 0.59]$ であった）．一方，この値を小さくすれば，コサイン距離の意味で近い特徴ベクトルのみを含むきめ細やかなクラスタ構造が得られるが，クラスタ数が膨大になり全体構造を把握することが難しくなるという問題がある．このようなクラスタ構造の解釈性におけるトレードオフを数量的に評価し，最適な結果を選択する手法を構築することは，提案法の重要な課題である．

6. 結論

本論文では，階層的クラスタリングに基づき，学習経過の各段階におけるニューラルネットのモジュール構造を抽出し，クラスタ構造の推移を可視化する手法を提案した．また，実際に画像認識を行うネットワークに提案法を適用し，その有効性と課題について検討を行った．

参考文献

[1] C. Watanabe, K. Hiramatsu, and K. Kashino. Modular representation of layered neural networks. *Neural Networks*, 97:62–73, 2018.

[2] C. Watanabe, K. Hiramatsu, and K. Kashino. Recursive extraction of modular structure from layered neural networks using variational Bayes method. In *Proceedings of Discovery Science 2017, Lecture Notes in Computer Science*, volume 10558, pages 207–222, 2017.

[3] C. Watanabe, K. Hiramatsu, and K. Kashino. Modular representation of autoencoder networks. In *Proceedings of 2017 IEEE Symposium on Deep Learning, 2017 IEEE Symposium Series on Computational Intelligence*, 2017.

[4] J. Chen, L. Song, M. Wainwright, and M. Jordan. Learning to explain: An information-theoretic perspective on model interpretation. In *Proceedings of the 35th International Conference on Machine Learning*, pages 883–892, 2018.

[5] X. Zhang, A. Solar-Lezama, and R. Singh. Interpreting neural network judgments via minimal, stable, and symbolic corrections. In *Advances in Neural Information Processing Systems 31*, pages 4879–4890, 2018.

[6] T. Zahavy, N. Ben-Zrihem, and S. Mannor. Graying the black box: Understanding DQNs. In *Proceedings of the 33rd International Conference on Machine Learning*, pages 1899–1908, 2016.

[7] M. Raghu, J. Gilmer, J. Yosinski, and J. Sohl-Dickstein. SVCCA: Singular vector canonical correlation analysis for deep learning dynamics and interpretability. In *Advances in Neural Information Processing Systems 30*, pages 6076–6085, 2017.

[8] A. Krizhevsky. Learning multiple layers of features from tiny images. Technical report, University of Toronto, 2009.

[9] D. P. Kingma and J. Ba. Adam: A method for stochastic optimization. In *Proceedings of the 3rd International Conference on Learning Representations*, 2015.

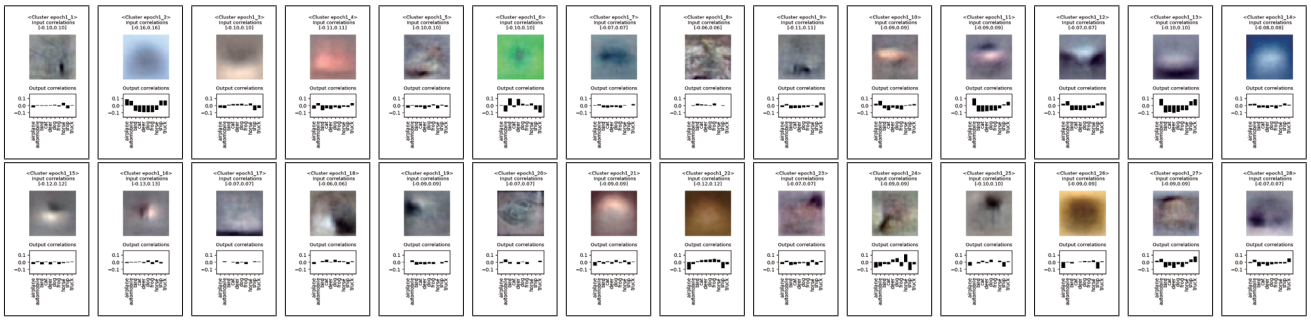


図 3: 1 エポックの学習完了時におけるニューラルネットの各クラスタのセントロイド．各クラスタの図について，上：クラスタに含まれるユニットの出力値と，各入力次元との相関値の平均（入力画像におけるどの画素の値を用いているか）．見やすさのため，各画像は，大かっこ内に示した実際の相関値の範囲を，その絶対値の最大値が 1 に対応するように引き伸ばした上で可視化している．下：クラスタに含まれるユニットの出力値と，各出力次元との相関値の平均（どの出力クラスの認識に寄与するか）．

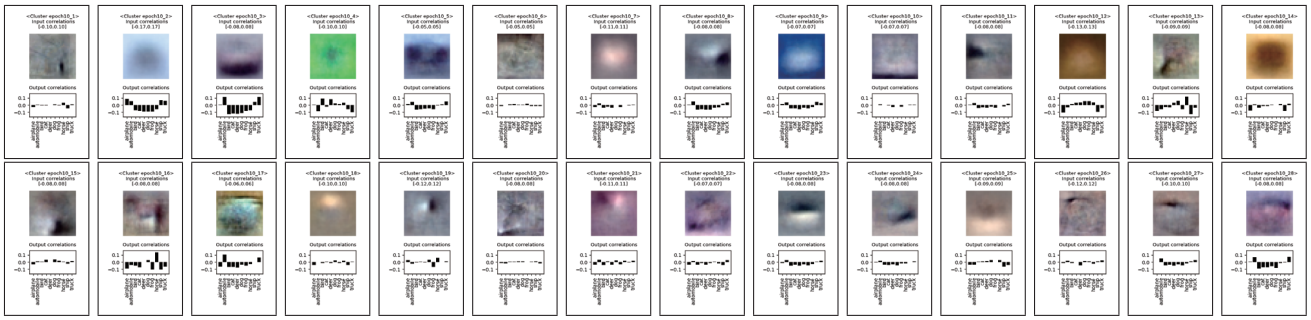


図 4: 10 エポックの学習完了時におけるニューラルネットの各クラスタのセントロイド．

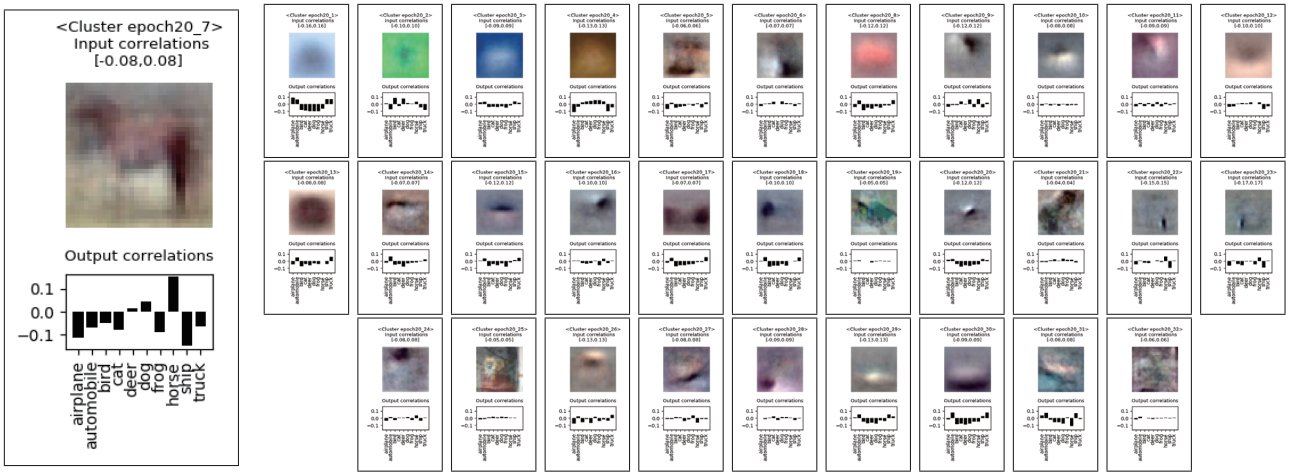


図 5: 20 エポックの学習完了時におけるニューラルネットの各クラスタのセントロイド．

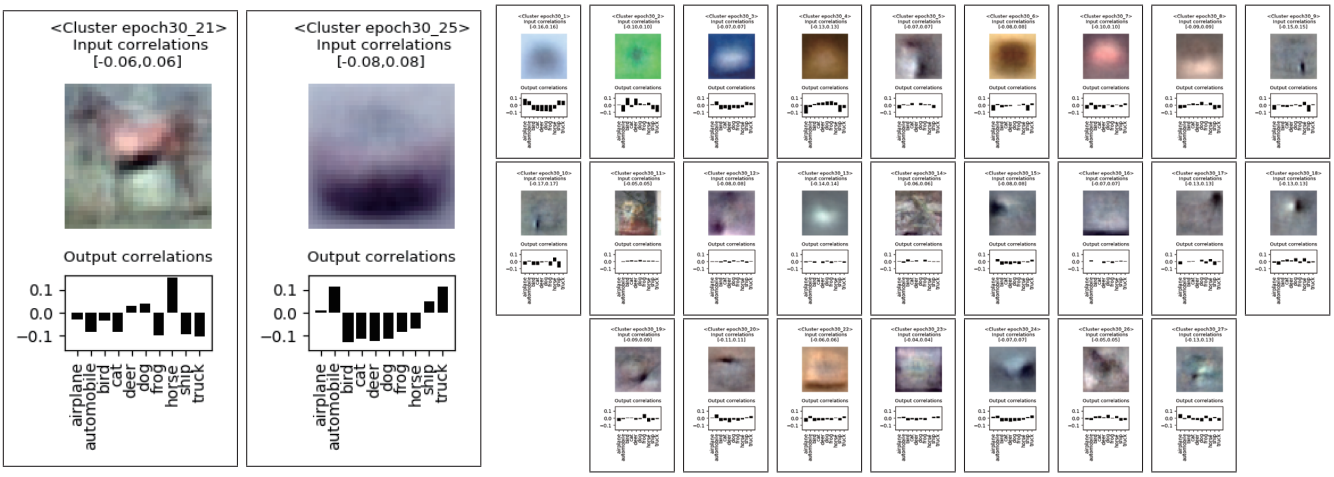


図 6: 30 エポックの学習完了時におけるニューラルネットの各クラスタのセントロイド．

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

勾配積分法に基づく脳波識別に貢献した周波数領域特徴の説明

Explanation of frequency domain features contributing to EEG classification using integrated gradients

立川 和樹 *1 Kazuki Tachikawa　河合 祐司 *2 Yuji Kawai　朴 志勲 *2 Jihoon Park　浅田 稔 *2 Minoru Asada

*1大阪大学大学院工学研究科
Graduate School of Engineering, Osaka University

*2大阪大学先導的学際研究機構
Institute for Open and Transdisciplinary Research Initiatives, Osaka University

Interpreting prediction of deep learning models is important in many applications, especially in medical diagnosis systems. Several methods have been proposed to interpret black-box predictions, but most of these studies are intended to calculate the contributions of input features. In this paper, we propose a method to compute the contributions in another feature space. The method applies differentiable transformations to input features and compute the contributions of the mapped features using integrated gradients. This approach enables us to calculate the contributions of amplitude and phase for each frequency in EEG classifications because the fast Fourier transform is differentiable. The proposed method is verified using three EEG datasets and the results show that the contributions of the proposed method are more reliable and has less computational cost than those of a conventional method. Our method will thus enhance the reliability of data-driven approaches in EEG analysis.

1. はじめに

深層学習は物体認識だけでなく，脳波を入力とした識別でも高い識別性能を有する [Schirrmeister 17, Hartmann 18]．特に，畳み込みニューラルネットは，脳波を周波数帯ごとに分けそれぞれの周波数帯で特徴量を設計する従来の手法とは異なり，簡単な前処理のみを施した脳波を入力として高い精度で識別できる [Schirrmeister 17]．この識別器を医療診断支援に応用する場合，どのような脳領域や周波数帯を根拠に識別したかを示すことで，医師が従来の知見との整合性を確認できる．

そのため，各入力特徴が識別に貢献した度合いを求める手法が提案されている [Sundararajan 17, Lundberg 17] が，これらの手法の多くは計算コストが非常に高く，一例の説明に数十分を要することもある [Zintgraf 17]．また，一部の手法は識別器とは関係のない説明をしている可能性があり [Adebayo 18]，計算コストを低く抑えつつ真に識別に貢献した特徴を求めることが重要である．これらの説明法の中で，勾配積分 (integrated gradients) 法は，特徴の貢献を求めるために望ましい性質を満たすという説明の正確さが理論的に裏付けられているだけでなく，計算コストも低いため，入出力勾配が計算できる場合には，優れた説明法であるといわれている [Sundararajan 17]．しかし，この手法は画像や言語のデータのように入力空間での貢献のハイライトを人が理解しやすいことを前提にしている．時系列の脳波データにおいては入力空間のハイライトを求める勾配積分法による説明を人が理解することは難しく，医学・神経科学での知見の蓄積のある周波数領域での貢献の提示が望ましい．そのため，周波数ごとの振幅成分と位相成分の貢献を求める Input Perturbation Network Prediction Correlation Map (IPNPCM) 法が提案されている [Schirrmeister 17]．しかし，この方法は勾配積分法のように説明の正確さが理論的に裏付けられておらず，また，計算コストは，ハイパーパラメータであるサンプル回数次第であるが，少ないとはいえない．

連絡先: 河合祐司，大阪大学先導的学際研究機構，〒 565-0871，大阪府吹田市山田丘 2-1，kawai@ams.eng.osaka-u.ac.jp

そこで，本研究では勾配積分法に基づいて，周波数ごとの振幅成分と位相成分の貢献を，少ない計算量で正確に計算することを目指す．識別器入力の空間を人が理解しやすい空間へと変換することで，その変換が微分可能であれば，勾配積分法により変換後の空間での貢献の計算が可能になる．脳波の場合，高速フーリエ変換 (fast Fourier transform: FFT) が微分可能であることを利用して，周波数領域での貢献を計算する．今回，三つのデータセットを用いて IPNPCM 法と比べたときの提案法の有効性を実験的に示す．

2. 提案手法

図 1 に示すように，従来は識別器の入力 $\boldsymbol{x}$ に対する出力 $f(\boldsymbol{x})$ の勾配 $\partial f(\boldsymbol{x})/\partial \boldsymbol{x}$ を計算していたが，本研究では識別器の入力を，人が理解可能な空間である振幅 $\boldsymbol{a}$ と位相 $\boldsymbol{p}$ に変換したものを入力とした勾配 $\partial f(\boldsymbol{x})/\partial \boldsymbol{a}$ と $\partial f(\boldsymbol{x})/\partial \boldsymbol{p}$ を計算する．脳波識別の場合，脳波を複素数の周波数空間に変換する FFT，振幅成分に変換する複素数の絶対値の計算，および，位相成分に変換する複素数の偏角の計算はどれも微分可能である．そのため，周波数空間を $\boldsymbol{c}$ とすると、$\partial f(\boldsymbol{x})/\partial \boldsymbol{a}$ は連鎖律を用いて，

$$\frac{\partial f(\boldsymbol{x})}{\partial \boldsymbol{a}} = \frac{\partial \boldsymbol{c}}{\partial \boldsymbol{a}} \times \frac{\partial \boldsymbol{x}}{\partial \boldsymbol{c}} \times \frac{\partial f(\boldsymbol{x})}{\partial \boldsymbol{x}}$$

のように，変換した入力に対する勾配が計算できる．

この勾配を用いて，周波数空間の i 番目の特徴の貢献 IG_i は，変数 α と基準点 $\tilde{a}$ を用いて以下の式から計算できる [Sundararajan 17]．

$$\mathrm{IG}_i = (a_i - \tilde{a}_i) \int_0^1 \frac{\partial f(\tilde{a} + \alpha(a - \tilde{a}))}{\partial a_i} d\alpha \qquad (1)$$

なお，位相の場合も同様に計算できる．

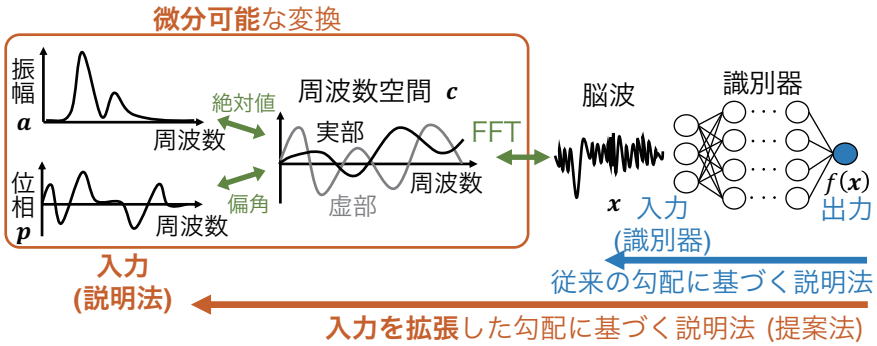


図 1: 提案法の概要．青線は識別器の入力に対する勾配を用いる従来法を示す．橙色部分は，微分可能な変換を入力特徴に施し，変換先の空間での特徴を入力として勾配を用いる提案法を示す．

3. 実験

3.1 データセットと識別器

一つの人工データセットと，二つの脳波データセットを用いた．脳波データの多くは，被験者の情報に基づいてラベル付けされ，貢献の真値は不明あるが，人工データセットの貢献の真値は既知である．

人工データセットは 5 チャンネル，60Hz で計測され，50 秒で 1 エポックとした．すなわち，1 データは 5×3000 のデータ点から成る．それぞれの時系列データは，2, 5, 10, 20, 30 Hz の正弦波が重ね合わせられたものからサンプリングされたものであり，それぞれの正弦波の振幅値は 0.3 ～ 0.7 でランダムで決定された．教師データはそれぞれの振幅値にそれぞれのチャンネルに設定された重み (-1.5, -0.5, 0.1, 1.0, 2.0) を掛けて合計した値とした．このとき、識別器が教師データを微小な誤差で回帰できるならば，それぞれの特徴の真の貢献は振幅値にチャンネルの重みをかけた値になる．2 層の畳み込みニューラルネットを用いて教師データを回帰し，誤差は 1.0×10^{-6} 以下になった．

一つ目の脳波データセットは，PhysioNet[*1] [Goldberger 00] で公開されている睡眠ポリグラフデータセット (PSG データセット) [*2] である．このデータセットは，男性 10 名，女性 10 名の計 20 名 [*3] の二晩分の睡眠データを 100Hz のサンプリング周波数で計測し， 30 秒を 1 エポックとしている．このデータセットには， Fpz-Cz と Pz-Oz に配置された電極から得られた脳波データと眼電データ（EOG），および，それらのデータに対する睡眠段階を Wake (W), REM (R), N1, N2, N3 に分類したラベルデータが付与されている．6 層の畳み込みニューラルネットを用いて 5 つの睡眠段階を識別した．

もう一つの脳波のデータセットは UCI Machine Learning Repository で公開されている EEG データセット [*4] である．このデータセットは 256Hz-64 チャンネル脳波計で，被験者に視覚刺激を提示した際の 1 秒分の脳波を計測したものである．被験者は 122 人であり，その内 45 人は健常であり， 77 人はアルコール依存である．4 層の畳み込みニューラルネットを用いてアルコール依存の有無を識別した．

*1 https://www.physionet.org/
*2 https://www.physionet.org/physiobank/database/sleep-edfx/
*3 version 1 を使用した
*4 https://archive.ics.uci.edu/ml/datasets/eeg+database

3.2 評価方法

まず，提案法と IPNPCM 法のそれぞれで，人工データセットを用いて周波数ごとの振幅成分と位相成分の識別への貢献を計算し，貢献の真値と比較した．人工データセットは貢献の真値が既知であるため，貢献の真値との誤差を top-k intersection [Ghorbani 17] と L2 ノルムの二つの指標で評価した．top-k intersection は貢献した特徴のインデックスを正しい順位で評価する能力を定量的に評価し，L2 ノルムは順位だけでなく，値の正確さも評価できる．このとき，貢献の正確さと計算量に影響するパラメータである，勾配積分法の積分区間の分割数と IPNPCM 法のサンプル回数を変化させ，貢献の正確さと計算量の両面から評価した．次に，二つの脳波データセットを用いてピクセルフリッピング法 [Bach 15] により貢献の正確さを評価した．これは識別の説明と実際に識別モデルから特徴が取り除かれたときの出力の値の変化量が一貫していることを定量的に示す方法である．全ての実験で，各クラスから 200 データずつランダムに選び，提案法と IPNPCM 法で識別に貢献した特徴を求めた．提案法の基準点 (baseline) は [Sundararajan 17] と同じく全ての値を 0 に設定した．また，提案法の積分区間の分割数は大きくするほど貢献が正確に求められるため，推奨されている値 [Sundararajan 17] の 2 倍である 500 に，IPNPCM 法のサンプル回数も同様の理由で既に推奨される回数 [Schirrmeister 17] の 2 倍の 1000 とした．

3.3 実験結果

図 2 に人工データセットを用いた場合の貢献の真値との誤差を示す．左のグラフは top-k intersection を箱ひげ図で示したものであり，縦軸の値が大きいほど貢献の順位が真値に近い説明であることを示す．また，横軸のステップ数は提案法と IPNPCM 法でそれぞれ必要な逆伝播計算の回数と順伝播計算の回数である．提案法はわずか 2 回の逆伝播計算で貢献の順位を正確に計算できることがわかる．右のグラフは縦軸に貢献の真値との L2 ノルムの平均値を示したものである．提案法はわずか 2 回の逆伝播計算で順伝播計算を 5000 回した IPNPCM 法よりもより真値に近い貢献の値を求めることができた．

図 3 に脳波データセットを用いた場合のピクセルフリッピング法の結果の平均と標準偏差を示す．縦軸は識別器の出力値で，横軸は除去された特徴の数である．同一データセットで比較したときに，曲線がより下方にある説明法は，説明法による貢献とその特徴が実際に除去された場合の出力値への影響が一貫しており，優れているといえる．この図から，提案法は IPNPCM 法よりも貢献を正確に求められたことがわかる．

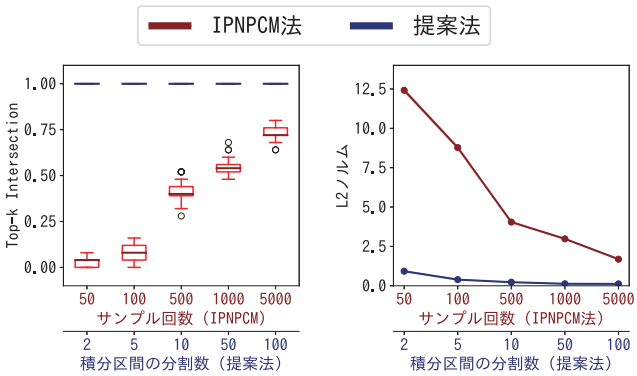


図 2: 人工データセットでの貢献の真値との誤差．200 データを用いた結果．左：top-k intersection．右：L2 ノルム．

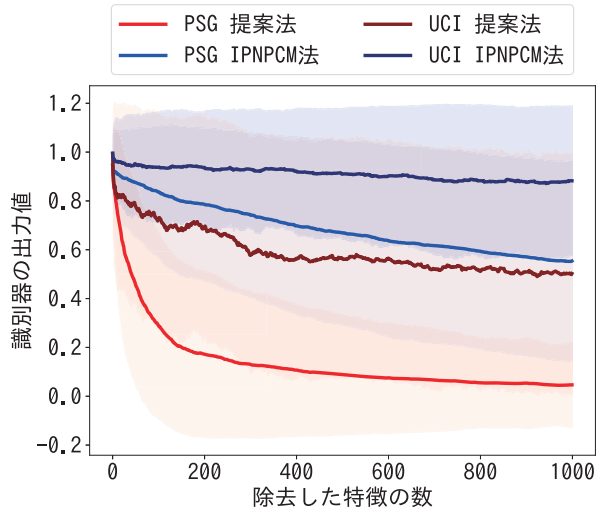


図 3: ピクセルフリッピングの結果．それぞれの曲線は 200 データでの平均値を示し，塗りつぶし範囲は標準偏差を示す．縦軸：識別器の出力値．横軸：除去された特徴の数．

図 4 に PhysioNet PSG データセットの二つの脳波センサの N2 クラス識別への貢献を可視化した．横軸は周波数であり，上段が提案法による説明で下段が IPNPCM 法による説明である．提案法により求まる貢献がより正確であることは既に図 3 に示しており，IPNPCM 法による説明はノイズが大きいことがわかる．また，デルタ帯 (0 ～ 2Hz) の活動の貢献は正であることは N3 クラスの定義と一致するため，この識別器は妥当であるといえる．

図 5, 6 に UCI EEG データセットのアルコール依存識別への貢献を可視化した．提案法と IPNPCM 法で説明の見た目が大きく異なるが，提案法による説明が正確であることは既に図 3 に示したため，二つの図の違いは従来法による誤説明の危険性を示す．

4. おわりに

脳波を入力とした識別器の周波数ごとの振幅成分と位相成分の貢献を少ない計算量で正確に計算するために，FFT の微分可能性を利用して，勾配積分法を用いて周波数領域である振幅成分と位相成分の貢献を求める方法を提案した．貢献の真値が既知である人工データセットを用いて，提案法は少ない計算量で貢献の真値を計算できることを示した．また，二つの脳波データセットを用いて提案法は従来法である IPNPCM 法よりも正確な説明が可能であることを示した．本研究は，微分可能な変換で人が理解しやすい空間に特徴を変換し，その空間を入力とみなして勾配を計算することを提案しており，振幅成分と位相成分への変換だけではなく，ほかの微分可能な変換にも適用可能である．例えば，脳波の信号源に変換できればより詳細に脳波識別の根拠と識別に使用した脳領域の関係を示すことができる．そのため，様々な種類のデータで人がデータの意味を理解しやすい特徴空間を調べることが今後の課題である．

謝辞

本研究は国立研究開発法人科学技術振興機構 (JST) の研究成果展開事業「センター・オブ・イノベーション (COI) プログラム」及び，JST，CREST，JPMJCR17A4 の支援によって行われた．

参考文献

[Adebayo 18] Adebayo, J., Gilmer, J., Muelly, M., Goodfellow, I. J., Hardt, M., and Kim, B.: Sanity Checks for Saliency Maps, in *Advances in Neural Information Processing Systems 31*, pp. 9525–9536 (2018)

[Bach 15] Bach, S., Binder, A., Montavon, G., Klauschen, F., Müller, K.-R., and Samek, W.: On Pixel-Wise Explanations for Non-Linear Classifier Decisions by Layer-Wise Relevance Propagation, *PLOS ONE*, Vol. 10, No. 7, pp. 1–46 (2015)

[Ghorbani 17] Ghorbani, A., Abid, A., and Zou, J.: Interpretation of Neural Networks is Fragile, in *NIPS workshop on Machine Deception* (2017)

[Goldberger 00] Goldberger, A. L., Amaral, L. A. N., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., Mietus, J. E., Moody, G. B., Peng, C.-K., and Stanley, H. E.: PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals, *Circulation*, Vol. 101, No. 23, pp. e215–e220 (2000)

[Hartmann 18] Hartmann, K. G., Schirrmeister, R. T., and Ball, T.: Hierarchical Internal Representation of Spectral Features in Deep Convolutional Networks Trained for EEG Decoding, in *Proceedings of the 6th International Conference on Brain-Computer Interface*, pp. 1–6IEEE (2018)

[Lundberg 17] Lundberg, S. M. and Lee, S.-I.: A Unified Approach to Interpreting Model Predictions, in *Advances in Neural Information Processing Systems 30*, pp. 4765–4774 (2017)

[Schirrmeister 17] Schirrmeister, R. T., Springenberg, J. T., Fiederer, L. D. J., Glasstetter, M., Eggensperger, K., Tangermann, M., Hutter, F., Burgard, W., and Ball, T.: Deep Learning with Convolutional Neural Networks for EEG Decoding and Visualization, *Human Brain Mapping*, Vol. 38, No. 11, pp. 5391–5420 (2017)

[Sundararajan 17] Sundararajan, M., Taly, A., and Yan, Q.: Axiomatic Attribution for Deep Networks, in *Proceedings of the 34th International Conference on Machine Learning*, Vol. 70, pp. 3319–3328 (2017)

[Zintgraf 17] Zintgraf, L. M., Cohen, T. S., Adel, T., and Welling, M.: Visualizing Deep Neural Network Decisions: Prediction Difference Analysis, in *Proceedings of the 5th International Conference on Learning Representations* (2017)

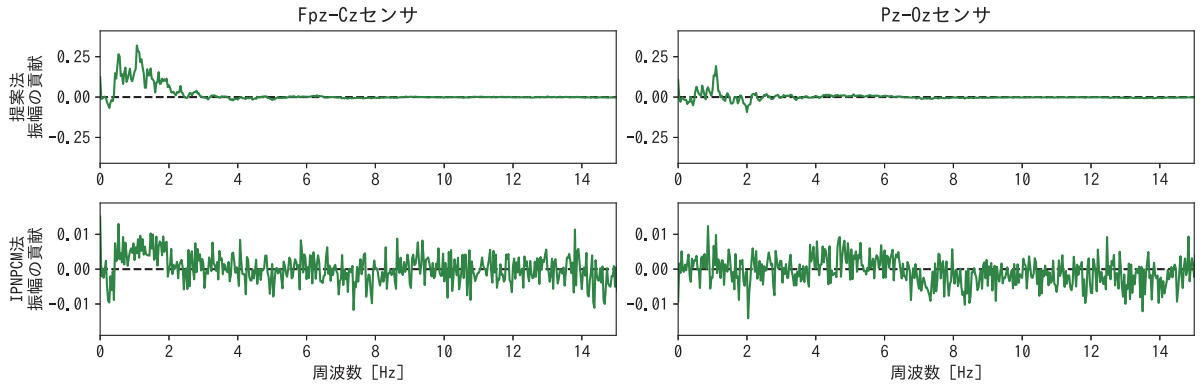


図 4: PhysioNet PSG データセットで N3 クラスの出力に貢献した振幅成分の 200 データ平均．位相成分は貢献が小さいため省略．上段：提案法での貢献．下段：IPNPCM 法での貢献．左：Fpz-Cz センサの貢献．右：Pz-Oz センサの貢献．

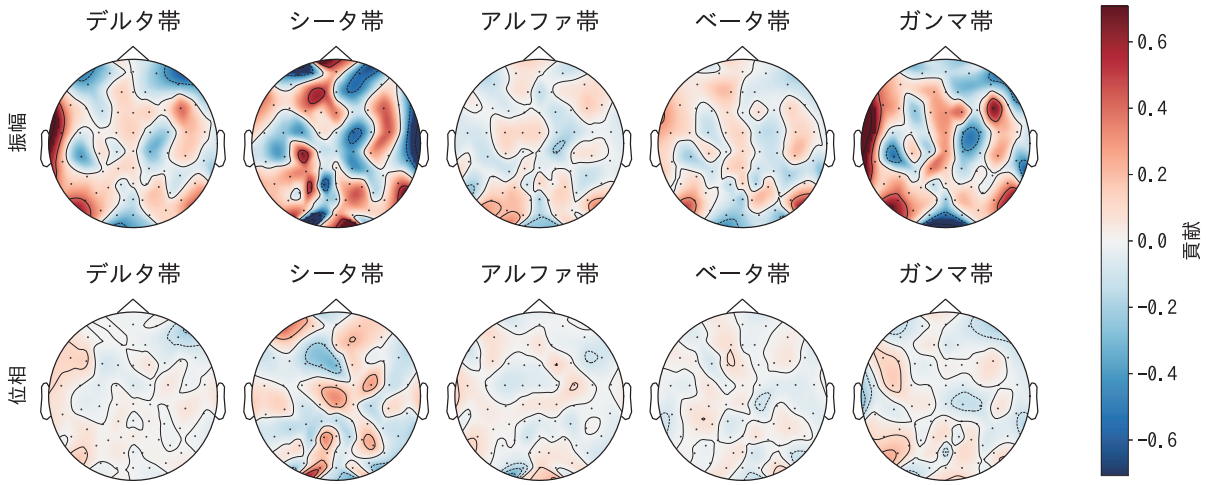


図 5: UCI EEG データセットでアルコール依存クラスの出力に貢献した特徴の 200 データ平均．提案法により貢献を計算．

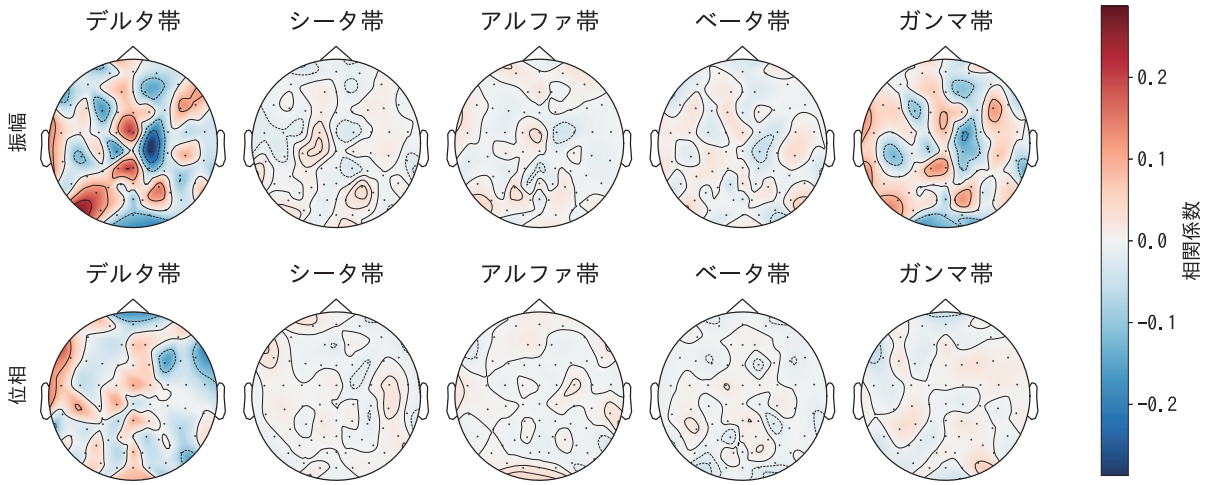


図 6: UCI EEG データセットでアルコール依存クラスの出力に貢献した特徴の 200 データ平均．IPNPCM 法により貢献を計算．

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

特徴パターンを用いた機械学習の説明手法

Model-agnostic Explainer using Feature Patterns

浅野孝平 *1　全眞嬉 *1　徳山豪 *1
Kohei Asano　Jinhee Chun　Takeshi Tokuyama

*1東北大学情報科学研究科
Graduate School of Information Sciences, Tohoku University

Recently, high performance, though very complex, machine learning models have been proposed. Being able to interpret such black boxed decision making models is clearly critical for sensible tasks. In this paper, we propose a model-agnostic explanation method that details the prediction behavior of any models using feature patterns. Since the relationship between features is still unclear in the previous works, we focus on a combination of these features. We propose an algorithm which finds several minimal feature patterns that lead target prediction sufficiently using hill climbing search. In our experiments, we aim at measuring the faithfulness of our explanation, thus apply our method to sentiment analysis dataset and evaluate the faithfulness using two metrics: recall and precision. At last, we demonstrate the benefit of our method based on some image classification use cases with a black-box model.

1. はじめに

近年，深層学習をはじめとする高い識別性能をもつ機械学習モデルが様々な分野に応用されている．それらのモデルの多くはブラックボックスであり，ユーザがモデルの挙動や予測の原因について知ることが困難になっており，モデルや予測結果に解釈性に関する研究が活発に行われている．予測の原因となる特徴を特定する手法として Local Interpretable Model-agnostic Explanations (LIME) [Ribeiro 16] がある．LIME では，個々の特徴の重要性を測ることはできるが，重要な特徴の組み合わせを特定することはできない．そこで，本研究では予測に影響を与えた特徴の組み合わせに着目した，新たなモデル依存性のない説明手法を提案する．提案手法では，特徴の組み合わせの中から，対象となる予測結果を得るために必要な特徴の組み合わせを探索アルゴリズムによって発見する．計算機実験によって提案手法の説明能力を定量的に評価した．また，画像分類への応用を行い，提案手法の有用性を検証した．

2. Local Interpretable Model-agnostic Explanations (LIME)

識別モデル $f : \mathcal{X} \to \mathbb{R}$ から得られた，インスタンス $x \in \mathcal{X}$ の予測結果 $f(x)$ に対して解釈を与えることを考える．ここで，x を被説明データと呼び，$\mathcal{X}$ は x のドメインである．LIME では，はじめに被説明インスタンス x をバイナリベクトル $\mathbf{x} \in \{0,1\}^d$ に変換する．例えばインスタンス x がカラー画像である場合，$\mathcal{X}$ は階数 3 のテンソルである．ここで，画像をピクセルやスーパーピクセルなどの手法を用いて領域分割し，その領域の有無で画像を表現することで，x をバイナリベクトルとして表現できる．

LIME ではスパースな線形関数 $g(x) = \mathbf{w}^\top \mathbf{x}$ によって，f を x の近傍で局所的に近似する．重みベクトル $\mathbf{w}$ から，識別に大きな影響を及ぼす $\mathbf{x}$ の特徴が特定できるため，予測結果に解釈を与えられる．g のように，予測結果に解釈を与えるモデルを説明モデルと呼ぶ．

次に，g の生成法について述べる．はじめに $\mathbf{x}$ の近傍のデータを $\mathbf{x}$ 中の 1 となっている特徴量をランダムに 0 にすることでサンプルし，これをサンプルベクトルと呼ぶ．次に，N 個のサンプルベクトル $\mathbf{x}_k$ $(k = 1, \ldots, N)$ を生成し，それらを元のデータ表現 $x_i \in \mathcal{X}$ に戻し，$\{(\mathbf{x}_k,\ \pi(x_k)f(x_k)) : k = 1, \ldots, N\}$ を訓練データとして Lasso 回帰することで，g を導出する．ここで，π は類似度関数であり，これを用いて局所性を測る．

以下では，この線形モデルによる定式化を Linear-LIME と記す．

連絡先: asano/jinhee/tokuyama@dais.is.tohoku.ac.jp

3. 極小パターンを用いた LIME の定式化

本論文では，極小な特徴パターンを用いた LIME (Minimal Patterns-LIME: MP-LIME) の定式化を提案する．MP-LIME では $\mathbf{x}$ の非零の要素を特徴の集合とみなし，$\mathcal{I} = \{1, \ldots, d\}$ と記す．また，特徴の部分集合 $e \in 2^{\mathcal{I}}$ を特徴パターンと呼び，ある特徴パターン e に対応するもとのデータ表現を x_e と記す．MP-LIME では説明モデル $\mathcal{E}_{\exp}$ を極小な特徴パターンの集合として定式化する．極小な特徴パターンを定義 1 として定める

定義 1.

$$f(x_{e_{\min}}) \sim f(x) \tag{1}$$

$$\forall i \in e_{\min},\ f(x_{e_{\min}\setminus\{i\}}) \nsim f(x) \tag{2}$$

を満たす $e_{\min}$ を極小な特徴パターンとして定義する．ここで，$\sim$ は右辺と左辺の識別結果が同じクラスに属することを表す比較演算子である．

定義 1 では，極小な特徴パターンを被説明インスタンス x と同じクラスに属するために最低限必要な特徴の集合として定義している．この定式化では，説明モデルに含まれるパターンは必ず被説明インスタンス x と同じクラスに属することが保証されており，識別に重要な特徴の組み合わせを表現できると考えられる．

次に，極小な特徴パターンの探索アルゴリズムについて述べる．探索はモデル f の評価値に基づいた山登り探索によって行う．はじめに $\mathcal{I}$ を初期状態として，$\mathcal{I}$ の近傍の特徴パターンすなわち，全ての $i \in \mathcal{I}$ について $f(x_{\mathcal{I}\setminus\{i\}})$ を評価する．こ

のとき，最も評価値の高いパターンを次の状態として，同様に近傍のパターンを評価して，極小な特徴パターンを探索する．この探索法で複数の極小な特徴パターンを発見するためには，再度繰り返し探索が必要となる．そこで，一度評価したパターン e のうち $f(x) \sim f(x_e)$ を満たすパターンは極小パターンの候補として $\mathcal{E}_{\text{cand}}$ に保存し，パターンを評価するたびに更新する．ひとつの極小な特徴パターンを発見したら，

$$\forall e_{\min} \in \mathcal{E}_{\text{exp}},\ e_{\min} \cap e \neq \varnothing \tag{3}$$

を満たすパターン e を $\mathcal{E}_{\text{cand}}$ から削除し，縮約された $\mathcal{E}_{\text{cand}}$ の要素の中から最も評価値の高いパターンを次の状態として再度探索を行う．式 (3) の制約を加えて探索を行うことで，評価されるパターン候補を削減する．

説明モデルの構築において，全ての極小な特徴パターンの列挙すると，評価されうるパターンの組み合わせは 2^d 個あるため，計算時間が膨大になりうる．そこで，極小な特徴パターンを L 個の発見するまで探索を行うことによって，この問題を回避する．ひとつの極小な特徴パターンを発見するために必要な評価回数は $\mathcal{O}(d^2)$ なので，L 個発見する場合でも $\mathcal{O}(Ld^2)$ の評価回数である，全パターンを探索するより効率が良い．

4. 計算機実験

4.1 説明能力の定量的評価

LIME と MP-LIME の説明能力を計算機実験によって評価した．説明能力は，識別モデルがデータを識別する際に使用した重要な特徴を LIME 及び MP-LIME によって予測した．本実験では識別モデル f として，ホワイトボックスなモデルである決定木を用いた．データセットとして，レビューデータ (books, DVD) [Blitzer 07] を用いた．各レビューは Word one-hot 表現で数値化し，1600 サンプルを訓練データとし，400 サンプルをテストデータとして用いた．Linear-LIME のパラメータは $N = 15000$ とし，正の重みを持つ特徴のうち上位 10 個を予測結果とした．MP-LIME については $L = 3$ とした．

説明能力を Precision, Recall を用いて評価した．表 1 に結果を示す．表 1 から，MP-LIME は Linear-LIME に比べ Recall は低くく，Precision が高いことが確認された．Precision は予測した特徴のうち，実際に予測に用いられた特徴の割合を意味するため，Precision が低い場合，予測した特徴の多くは識別結果に影響を与えていないことを意味している．そのため，MP-LIME の予測した特徴の多くが識別に影響したものであるため，Linear-LIME に比べ高い説明能力を持つと考えられる．

表 1: 説明能力の比較結果

	Recall		Precision	
	books	DVD	books	DVD
Linear-LIME	0.932	0.948	0.134	0.202
MP-LIME	0.768	0.758	0.980	0.980

4.2 画像分類への応用

深層学習モデルを用いた画像識別への応用を行う．Google が公開しているモデルである Inception-v3[*1] に図 1 を入力すると，96.8% で goose であると識別された．Inception-v3 はブラックボックスな畳み込みニューラルネットワークであり，このモデルが識別の際に画像のどの領域を重要視しているかは不明である．はじめに，画像をスーパーピクセルによって 40 分割し，画像を二値表現 (図 2) した．図 3 に $N = 10000$ とし，上位 10 個のスーパーピクセルについての Linear-LIME の出力結果を示す．また，図 4 に MP-LIME から得られたふたつの極小パターン ($L = 2$) を示す．赤色と青色でマスクしたスーパーピクセルがそれぞれ極小パターンを表している．

Linear-LIME による説明結果 (図 3) からは重要なスーパーピクセルは分かるが，重要な組み合わせは分からない．図 4 では，2 つのガチョウの頭部がそれぞれ説明結果として独立して出力されている．このことから，MP-LIME では，複数の特徴パターンが識別結果に影響している場合に，それらを検知できると考えられる．

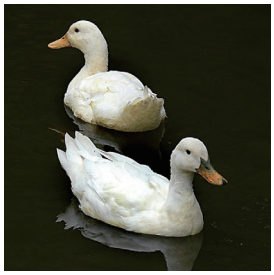


図 1: 元画像

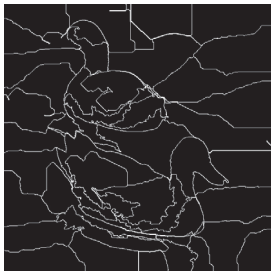


図 2: スーパーピクセルによる領域分割



図 3: Linear-LIME の出力

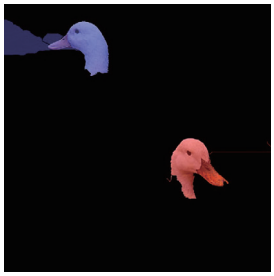


図 4: MP-LIME の出力

5. まとめ

本研究では，極小パターンの集合を説明モデルとした LIME の定式化である MP-LIME を提案した．計算機実験では，従来の Linear-LIME よりも高い Precision で説明が可能であることが示された．また，画像分類への応用より，複数の特徴の組み合わせが識別結果に影響している場合，それらを特定できることが確認された．

参考文献

[Blitzer 07] Blitzer, J., Dredze, M., and Pereira, F.: Biographies, bollywood, boom-boxes and blenders: Domain adaptation for sentiment classification, in *Proceedings of the 45th annual meeting of the association of computational linguistics*, pp. 440–447 (2007)

[Ribeiro 16] Ribeiro, M. T., Singh, S., and Guestrin, C.: Why should i trust you?: Explaining the predictions of any classifier, in *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining*, pp. 1135–1144ACM (2016)

∗1 https://github.com/tensorflow/models

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

畳み込みニューラルネットワークの学習過程の可視化

Visualization of learning process for Convolution Neural Network

坂井 創一　　竹中 要一
sakai soichi　　takenaka yoichi

関西大学 大学院総合情報学研究科
Graduate School of Informatics, Kansai University

Convolutional Neural Network (CNN) is an image classifier using deep neural network. However, it hardly gives the evidence why it classifies an image into a class. To solve this problem, some methods producing visual explanations has been proposed. Grad-CAM produces visual information for localized important regions for a class in an input image. As well as the visual explanations of classification, it is important to visualize of the learning process. The performance of CNN, such as accurate classification, is highly rely on the parameters. We convince the visualization of the learning process helps the parameter tuning. We propose a method that visualize the learning process. It generates the visual explanation images of arbitrary classes for each epoch. We validated the effectiveness of our method using MNIST dataset. The result shows the proposed method can visualize the learning process for every class for every epoch, whereas the usual method cannot.

1. はじめに

近年，深層学習を用いた画像認識は様々なタスクで優れた結果を出している．深層学習の一種である畳み込みニューラルネットワーク (Convolutional Neural Network : CNN)[LeCun 98] は画像認識や画像キャプション生成などのタスクに利用され，既存手法の性能を大きく上回っている．

CNN では，多くの畳み込み層や全結合層，プーリング層等複数種類の層を重ねることによって計算処理が行われている．それゆえ，識別器の構造が複雑化し，識別根拠や識別理由を人間が理解することが難しく，誤識別原因の調査に曖昧さが残り，識別精度の向上に多くの労力を要している．これらの問題を解決するために，SmoothGrad [Smilkov 17] や LIME [Ribeiro 16] など CNN が推論を行なった際にその判断根拠として，推論結果に大きく影響を与えた箇所を提示できるようなモデルを作る研究がなされている．

その中でも一般的によく使われている Grad-CAM [Selvaraju 17] は入力画像中で出力クラスに大きく影響を与えた領域を可視化することで，CNN による出力が入力画像のどの部分に注目して行なわれているのかを提示している．Grad-CAM は医療のように利用者に判断の根拠を説明する必要がある分野に対応することが考えられてきた．

しかし，ニューラルネットワークの設計者にむけて，学習時の学習率や畳み込み層のカーネルサイズ，ドロップアウトの割合といったハイパラメータの調節に役立たせるために判断根拠を分析する研究などは見られなかった．

本研究では，このようなハイパラメータの調節といった精度を上げるための情報の一つとして学習過程に着目する．学習過程の段階で，CNN が入力画像中の対象領域を正しく注目しているかを見ることで，テストデータに対する正答率や損失関数の値とは違った評価値を得ることができ，多角的にモデルの性能を判断することが考えられる．そこで学習過程を可視化するために Grad-CAM の応用を行なった．

本稿では学習過程の可視化に Grad-CAM を応用した際，可視化が行われないパターンがある事を示し，そのようなパターンに対して可視化を可能にする手法を提案する．

連絡先: 坂井創一，関西大学大学院総合情報学研究科，
k603014@kansai-u.ac.jp



図 1: 入力画像

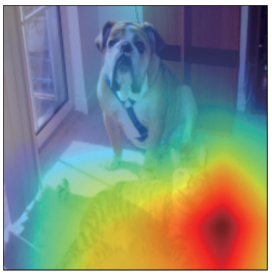


図 2: クラス ‘cat’ の可視化

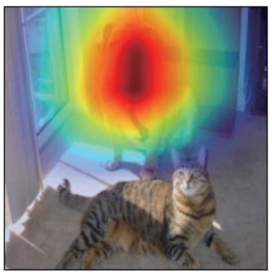


図 3: クラス ‘dog’ の可視化

2. 先行研究

Grad-CAM は，畳み込み層の最終層を使うことにより，あるクラスにおける入力画像中の注目した領域を可視化する手法である．図 1 を Grad-CAM に入力として与え,‘cat’ のクラスの注目領域を可視化すると図 2 が出力される．また同じ入力を用いて，‘dog’ のクラスの注目領域を可視化すると図 3 が出力される．

Grad-CAM は次の手順によって可視化を行なっている．

1. クラス c に対する各チャンネルの重要度をもとめる．

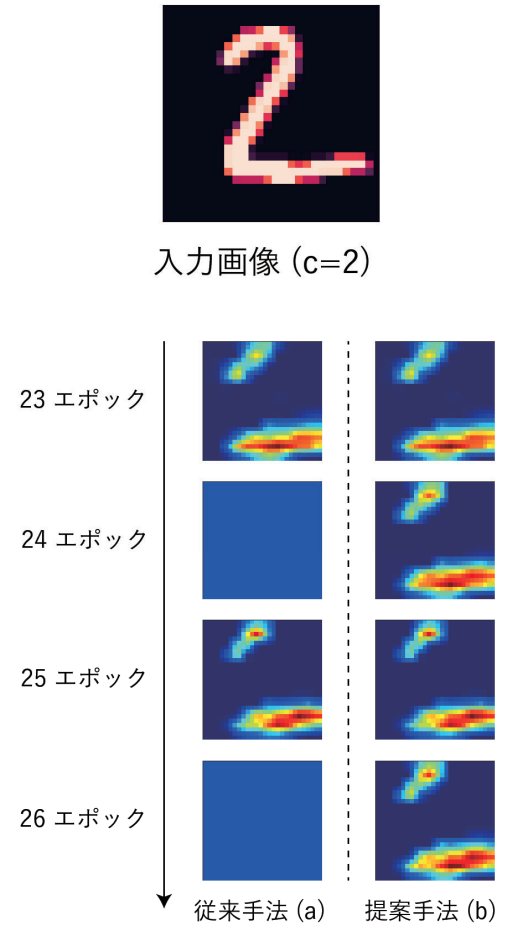


図 4: 学習過程の可視化

k を層のチャンネル数，c を求める目的クラス，α をチャンネルの重要度，A を可視化したい畳み込み層の k チャンネルが出力する特徴マップ，y を目的クラスのスコアとする．

$$\alpha_k^c = \frac{1}{Z}\sum_i\sum_j \frac{\partial y^c}{\partial A_{ij}^k} \tag{1}$$

式 (1) では畳み込みレイヤの特徴マップ A_{ij}^k がクラス c のスコアに与える影響，すなわち y_cの勾配を計算する．そしてチャンネルの重要度の重みα_k^cを得るために平均化している．

2. クラス c に対するニューラルネットワークの注目度マップを求める．

$$L_{Grad-CAM}^c = ReLU(\sum a_k^c A^k) \tag{2}$$

式 (2) では各チャンネルの重要度と a_k^cとそのチャンネルが出力する特徴マップ A^k を足し合わせ，ReLU 関数を掛けている．

3. 注目度マップを可視化するため，出力が 1 から 0 の間になるよう正規化を行う．

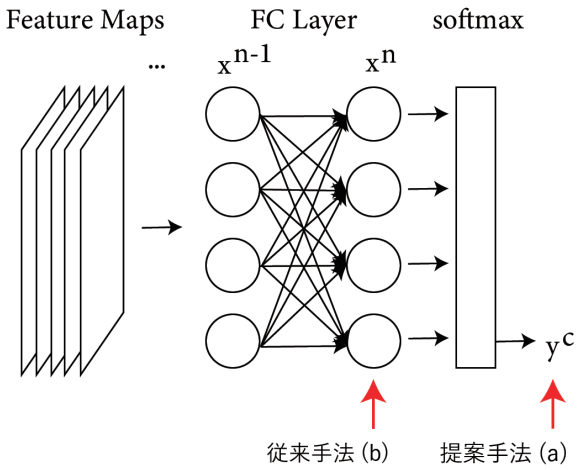


図 5: 微分箇所

$$L_{Grad-CAM}^c = \frac{L^c - min(L^c)}{max(L^c) - min(L^c)} \tag{3}$$

式 (3) によって可視化されたヒートマップが与えられる．

この手法を学習過程の可視化に応用した際，図 3 の入力に図 4(左 a) に示すように注目箇所が可視化が行われなかった．

3. 提案手法

従来手法において可視化が行われなかった際，目的クラスのスコアである y^c が 1 なっていた．y^c の微分値を求める際，CNN の全結合部のシグモイド関数と softmax 層によって勾配情報が失われ，チャンネルの重要度 α_k^c が 0 になってしまう問題があることがわかった．

提案手法では，α_k^c の値を 0 にしないため，チャンネルの重要度の計算式に変更を加えた．n を層の数，x をパーセプトロン，x^n を n 層目のパーセプトロンとする．従来手法では式 (1) の中で (図 5:a) の位置にある目的クラスのスコアの値 α_k^c に対して行われていた微分を，提案手法では (図 5:b) の位置にある softmax 層に入力するユニットのシグモイド関数をかける前の値　x_i^n に対して微分を行う．

つまり，提案手法では従来手法では式 (1) で計算を行なっていた α_k^c を代わりに式 (4) によって行う．

$$\alpha_k^c = \frac{1}{Z}\sum_i\sum_j \frac{\partial x_n^c}{\partial A_{ij}^k} \tag{4}$$

こうすることによって，softmax 層やシグモイド関数で勾配が消失している場合にも注目領域の可視化が可能となる．結果，図 4(右:b) のように可視化がされた．

4. 実験

手書き数字画像データセットである MNIST[*1] を利用し，従来手法と提案手法の比較実験を行なった．

実験に使用した CNN の構造は 1 である．畳み込み層の活性化関数には ReLU を，Batch size は 100 を採用した．全結合層のみに 0.5 の選出確率で Dropout を導入した．1 エポック

*1　http://yann.lecun.com/exdb/mnist/

表 1: CNN の構成

		入力次元			出力次元				
層番号	種類	H	W	D	H	W	D	カーネル	ストライド
1	畳み込み	28	28	1	26	26	32	3 × 3	1 × 1
2	畳み込み	26	26	32	24	24	64	3 × 3	1 × 1
3	プーリング	24	24	64	12	12	64	2 × 2	2 × 2
4	Flatten	1	1	9216	1	1	128	-	-
5	Flatten	1	1	128	1	1	10	-	-

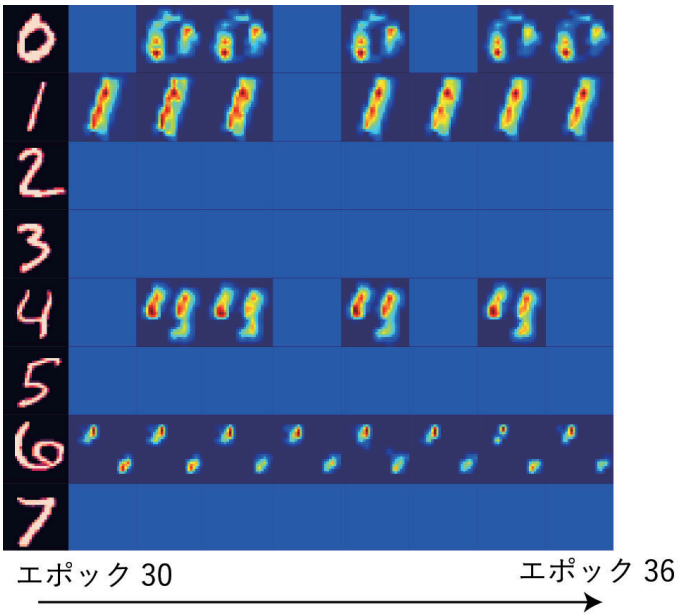


図 6: 実験：従来手法

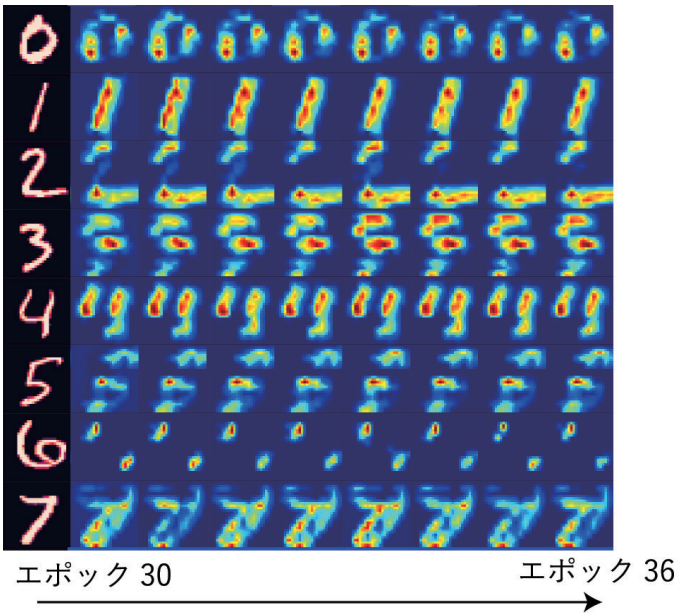


図 7: 実験：提案手法

に学習データ 60000 枚中からランダムで 10000 枚選んで学習を行なった．テストデータから 0 から 9 までの数字を 1 枚ずつ選び，1 エポック毎に従来手法と提案手法の Grad-CAM を掛け，可視化が行われていない画像の枚数を調べた．それぞれ実験を行なった，従来手法の出力結果を図 6 提案手法の出力結果を図 7 に示す．結果から従来手法では可視化されなかった画像においても，可視化されていることが分かる．学習を 100 エポック行った結果，可視化が行われていなかった画像は 500 枚のうち，従来手法では 217 枚，提案手法では 0 枚であった．

5. 終わりに

提案手法により，CNN の学習過程の可視化が可能となることを示すことができた．指定したクラスの判断根拠を注目領域としてエポック毎に出力が可能である，これを用いることにより

モデルのあるクラスにおける判断根拠が誤っていた場合，他クラスの判別にどのように影響を与えるかや，誤った判断根拠にどう修正を施すか，判断根拠を元にどのような追加学習を行うことが適切かなどを検証する手段として利用できる事を示した．

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, pages 2278-2324, 1998.

[Selvaraju 17] Selvaraju, Ramprasaath R., et al. :Grad-cam: Visual explanations from deep networks via gradient-based localization. (2017) IEEE International Conference on Computer Vision (ICCV). IEEE, 2017.

[Smilkov 17] D. Smilkov, N. Thorat, B. Kim, F. Vigas, and M. Wattenberg. Smoothgrad: removing noise by adding noise. arXiv preprint arXiv:1706.03825, 2017.

[Ribeiro 16] Ribeiro, Marco Tulio, Sameer Singh, and Carlos Guestrin. "Why should I trust you?: Explaining the predictions of any classifier." Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining. ACM, 2016.

General Session | General Session | [GS] J-2 Machine learning

[2Q4-J-2] Machine learning: bayesian network

Chair:Togoro Matsui Reviewer:Masakazu Hirokawa

Wed. Jun 5, 2019 3:20 PM - 4:20 PM Room Q (6F Meeting room, Bandaijima bldg.)

[2Q4-J-2-01] Learning huge Bayesian network structures by RAI algorithm with transitivity

Kazunori Honda[1], Kazuki Natori[1], ○Shouta Sugahara[1], Takashi Isozaki[1], Maomi Ueno[1] （1. The University of Electro-Communications）

3:20 PM - 3:40 PM

[2Q4-J-2-02] Learning huge Augmented Naive Bayes Classifier

○Naruchika Kikuya[1] （1. The University of Electro-Communications）

3:40 PM - 4:00 PM

[2Q4-J-2-03] Exact Learning Augmented Naive Bayes Classifier

○Shouta Sugahara[1], Maomi Ueno[1] （1. The University of Electro-Communications）

4:00 PM - 4:20 PM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

推移性を利用したRAIアルゴリズムによる大規模ベイジアンネットワーク構造学習

Learning huge Bayesian network structures by RAI algorithm with transitivity

本田和雅 Kazunori Honda　名取和樹 Kazuki Natori　菅原聖太 Shouta Sugahara　磯崎隆司 Takashi Isozaki　植野真臣 Maomi Ueno

電気通信大学大学院情報理工学研究科
Graduate school of Information and Engineering, The University of Electro-Communications

Learning Bayesian networks (BNs) is NP-hard. Recently, we can learn 1000 nodes BNs with consistency by the RAI algorithm using Bayes factor, which is the state-of-the-art learning method. However, it is important to enable learning huger BNs to apply it in practice. This paper proves that conditional independence (CI) of BNs has the transitivity that can infer, from CI between a pair of variables, CI between each of them and another variable, and proposes a constraint-based algorithm, using the RAI algorithm with the transitivity. The experimental results show that the proposed method decreases the number of CI tests and run-time, and can learn huge BNs which prototypical constraint-based algorithms cannot learn.

1. はじめに

ベイジアンネットワークは，確率変数をノードとし，ノード間の依存関係を非循環有向グラフ（Directed Acyclic Graph: DAG）と各ノードの条件付き確率で表現する確率的グラフィカルモデルである．ベイジアンネットワークのネットワーク構造は一般に未知であるため，データから推定する必要がある．この問題をベイジアンネットワーク構造学習と呼ぶ．

ベイジアンネットワーク構造学習手法として，漸近一致性を有する学習スコアが最大となる構造を全ての構造の候補から探索する厳密解探索アプローチが知られている．この手法は構造の探索数がノード数に対し指数的に増加する NP 困難問題 [Chickering 96] である．厳密解を効率的に探索するために，動的計画法 [Silander 06]，A^* 探索 [Yuan 11]，整数計画法 [Cussens 11] などの最適化手法による構造学習法が提案されてきたが，未だ 60 変数程度の構造学習が限界である．

一方，因果モデルの分野では，より計算効率の高い手法である制約ベースアプローチが提案されている．制約ベースアプローチは完全無向グラフの各エッジに対する条件付き独立性検定（Conditional Independence test: CI テスト）で独立と判定されたエッジを削除し，それによって得られた無向グラフをオリエンテーションルール [Pearl 00] で方向付けることで構造を推定する．この手法の代表的なアルゴリズムとして，PC アルゴリズム [Spirtes 00]，MMHC アルゴリズム [Tsamardinos 06]，RAI アルゴリズム [Yehezkel 09] が知られており，RAI アルゴリズムが最も高速に学習できると報告されている．近年では RAI アルゴリズムの CI テストに Bayes factor を用いることにより，漸近一致性を有しつつ 1000 変数程度の学習が可能となった [Natori 17][名取 18] が，本研究ではより大規模の構造学習を実現できる手法の開発を目的とする．

制約ベースアプローチの時間計算量は学習に要する CI テスト数に依存し，一般に，学習のできる限り早期にエッジを削除するほど CI テスト数を少なくして学習できる．そこで本研究では，まず，ある二変数の条件付き独立性からその各変数と他変数との条件付き独立性の少なくとも一つを保証できる推移性が成り立つことを示す．そして，ある条件付き独立性を検出したとき，推移性により少なくとも一つが条件付き独立となる二組のエッジを優先して CI テストできるエッジ削除法を提案し，Bayes factor を用いた RAI アルゴリズムに組み込む．これにより，より学習の早期にエッジを削除することで CI テスト数を削減でき，従来手法では実現できない大規模構造学習の実現を期待できる．

本研究は数千ノードのネットワークを用いたシミュレーション実験により従来ではできない大規模構造学習を実現する．

連絡先: 電気通信大学大学院情報理工学研究科，
東京都調布市調布ケ丘 1-5-1，
{hondak,natori,sugahara,ueno}@ai.lab.uec.ac.jp

2. ベイジアンネットワーク構造学習

今，$\mathbf{V} = \{X_1, \ldots, X_n\}$ を n 個の離散確率変数集合とし，各変数 X_i は r_i 個の状態集合 $\{1, \ldots, r_i\}$ から一つの値 k を取る（$X_i = k$ と書く）とする．また，ベイジアンネットワーク構造 G において，各変数 X_i の親変数集合を $\mathbf{\Pi}_i^G$ とする．このとき，ベイジアンネットワークは非循環有向グラフ（Directed Acyclic Graph: DAG）を仮定することで同時確率分布 $P(X_1, \ldots, X_n)$ を以下の条件付き確率の積に厳密分解できる．

$$P(X_1, \ldots, X_n) = \prod_{i=1}^{n} P(X_i \mid \mathbf{\Pi}_i^G). \tag{1}$$

ベイジアンネットワーク構造学習では漸近一致性を有する周辺尤度スコアを最大にする構造を探索する厳密解探索アプローチが一般的に用いられる．今，観測データを $\mathbf{D} = \{D_1, \ldots, D_N\}$ とすると，ネットワーク G における周辺尤度スコア $P(\mathbf{D} \mid G)$ は以下となる．

$$P(\mathbf{D} \mid G) = \prod_{i=1}^{n} \prod_{j=1}^{q_i} \frac{\Gamma(\alpha_{ij})}{\Gamma(\alpha_{ij} + N_{ij})} \prod_{k=1}^{r_i} \frac{\Gamma(\alpha_{ijk} + N_{ijk})}{\Gamma(\alpha_{ijk})}. \tag{2}$$

ここで，N_{ijk} は変数 X_i の親変数集合 $\mathbf{\Pi}_i^G$ が j（$j = 1, \ldots, q_i$）番目のパターンを取るときの $X_i = k$ となる頻度を表し，$N_{ij} = \sum_{k=1}^{r_i} N_{ijk}$ である．また，α_{ijk} はハイパーパラメータを表し，$\alpha_{ij} = \sum_{k=1}^{r_i} \alpha_{ijk}$ である．近年では，$\alpha_{ijk} = \alpha/(r_i q_i)$ とした Bayesian Dirichlet equivalent uniform（BDeu）が最も用いられる [Heckerman 95]．ここで，α は Equivalent Sample

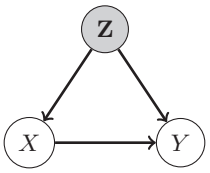


図 1: 従属モデル G_1

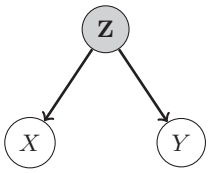


図 2: 独立モデル G_2

Size (ESS) と呼ばれる事前知識の重みを示す擬似サンプルである．

周辺尤度スコアを最大化する厳密解探索アプローチとして，動的計画法 [Silander 06]，A^* 探索 [Yuan 11]，整数計画法 [Cussens 11] などが提案されてきたが，未だ 60 変数程度の構造学習が限界であり，大規模構造を学習できない．

因果モデル分野では，大幅に計算量を削減できる制約ベースアプローチと呼ばれる構造学習法が提案されてきた．このアプローチの基本的なアルゴリズムは以下の通りである．

1. 確率変数をノードとした完全無向グラフを生成する．
2. 1 の完全無向グラフに対し条件付き独立性検定（Conditional Independence test: CI テスト）を行い，独立と判定されたエッジを削除する．
3. 2 で得られた無向グラフに対してオリエンテーションルール [Pearl 00] を用いて方向付けを行う．

制約ベースアプローチによる学習アルゴリズムとして，PC アルゴリズム [Spirtes 00] や MMHC アルゴリズム [Tsamardinos 06]，RAI アルゴリズム [Yehezkel 09] が提案されており，RAI アルゴリズムは最も高速に学習できると報告されている．しかし，これらのアルゴリズムは CI テストに χ^2 検定や G^2 検定，条件付き相互情報量を用いるために漸近一致性を持たない．

Steck らは Bayes factor を用いた CI テストを提案している [Steck 02]．今，二ノード X，Y とそれらの共通親ノード集合 $\mathbf{Z}$ からなる従属モデルを G_1，独立モデルを G_2 とし，それぞれ図 1，2 に示す．このときの Bayes factor を $\mathrm{BF}(X, Y \mid \mathbf{Z})$ とすると，対数 Bayes factor は以下となる．

$$\log \mathrm{BF}(X, Y \mid \mathbf{Z}) = \log \frac{P(\mathbf{D} \mid G_1, \boldsymbol{\alpha})}{P(\mathbf{D} \mid G_2, \boldsymbol{\alpha})}. \tag{3}$$

ここで，$P(\mathbf{D} \mid G_1, \boldsymbol{\alpha})$，$P(\mathbf{D} \mid G_2, \boldsymbol{\alpha})$ は式（2）の BDeu を用いる．Bayes factor を用いた CI テストでは対数 Bayes factor が 0 以上か否かで図 1，2 のどちらを選択するか判定する．この CI テストは漸近的に真の条件付き独立性を判定できる [名取 18]．

3. Bayes factor を用いた RAI アルゴリズム

RAI アルゴリズムは，制約ベースアプローチの中で最も高速に学習できるアルゴリズムである [Yehezkel 09]．RAI アルゴリズムは学習途中にエッジを方向付け，全体のグラフを部分グラフへ分割するため，各ノードの親候補となるノード集合を制約し，高次の CI テストを削減して学習できる．近年では，RAI アルゴリズムの CI テストに Bayes factor を用いることで漸近一致性を有しつつ最も大規模の構造学習を実現している [Natori 17][名取 18]．

Bayes factor を用いた RAI アルゴリズムの詳細を Algorithm1 に示す．関数 RAI はグラフとデータ，CI テストの次

Algorithm 1 The RAI algorithm using Bayes factor

```
 1: function Main(G_uc, D)
      G_uc = (V_uc, E_uc): 完全無向グラフ
      D: データ
 2:     return RAI (0, G_uc, φ, G_uc, D)
 3: end function

 4: function RAI(n_z, G_s, G_ex, G_all, D)
      n_z: CI テストの次数
      G_s = (V_s, E_s): 入力グラフ
      G_ex: 分割されたグラフの集合
      G_all = (V_all, E_all): CI テストと方向付けによって得られる出力グラフ
 5:     if 全ての V ∈ V_s について |Pa_p(V, G_all)| < n_z + 1 then
 6:         return G_all
 7:     end if
    // CI テストによるエッジの削除
 8:     for G_ex = (V_ex, E_ex) ∈ G_ex do
 9:         for X ∈ V_s, Y ∈ V_ex do
10:             for Z ⊆ Pa_p(X, G_s) ∪ Π_X^{G_ex} \ {Y} do
11:                 if |Z| = n_z かつ log BF(X, Y | Z) < 0 then
12:                     E_all ← E_all \ {E_XY}        ▷ E_XY: XY 間のエッジ
13:                 end if
14:             end for
15:         end for
16:     end for
17:     for X ∈ V_s, Y ∈ V_s do
18:         for Z ⊆ Pa_p(X, G_s) ∪ Π_X^{G_ex} \ {Y} do
19:             if |Z| = n_z かつ log BF(X, Y | Z) < 0 then
20:                 E_all ← E_all \ {E_XY}, E_s ← E_s \ {E_XY}
21:             end if
22:         end for
23:     end for
24:     オリエンテーションルールを用いて E_all, E_s を方向付け
    // G_s を部分グラフに分割
25:     V_c ← {V | V ∈ V_s, V は子ノードを持たず，無向エッジで親に到達不可能 }
26:     E_c ← {E_XY | X, Y ∈ V_c, E_XY は無向エッジ }
27:     G_e ← G_s \ (V_c, E_c)
28:     G_e ← G_e の個々の連結グラフからなる集合
    // 再帰的に関数 RAI を呼び出す
29:     for i = 1 to |G_e| do
30:         G_all ← RAI(n_z + 1, G_e[i], G_ex, G_all, D)
31:     end for
32:     G_ex ← G_ex ∪ G_e
33:     return RAI(n_z + 1, (V_c, E_c), G_ex, G_all, D)
34: end function
```

数 n_Z を入力されたとき，まず，各ノード V の子ノードを除いた隣接ノード集合 $\mathbf{Pa}_p(V, G_s)$ の大きさが $n_Z + 1$ 未満か判定し，そうであれば学習を終了する（5 から 7 行目）．学習を続ける場合，各エッジに対して Bayes factor を用いた CI テストを行いエッジを削除し（8 から 23 行目），残ったエッジをオリエンテーションルールで方向付ける（24 行目）．方向付けられたグラフから子ノードを持たないノード集合からなる部分グラフを取り出し，それ以外のグラフを個々の連結な部分グラフに分割する（25 から 28 行目）．以上を各部分グラフに対して再帰的に実行する（29 から 33 行目）．これにより各ノードの親ノード候補を制約することができ，高速に学習できる．

4. 提案手法

制約ベースアプローチの時間計算量は学習に要する CI テスト数に依存する．一般的に，制約ベースアプローチは学習のできる限り早期にエッジを削除するほど CI テスト数を抑えて学習できる．本研究は，まず，ベイジアンネットワークのある二変数の条件付き独立性からその各変数と他変数との条件付き独立性の少なくとも一つを保証できる推移性が成り立つことを示す．そして，推移性を利用することで，ある条件付き独立性を検出したときに少なくとも一つが条件付き独立となる二組のエッジを優先して CI テストする手法を提案し，Bayes factor を用いた RAI アルゴリズムに組み込む．これにより，より学習の早期にエッジを削除できるため，学習に要する CI テスト数を削減し，従来より大規模の構造学習の実現を期待できる．

4.1 推移性

今，ノード X からノード Y への隣接ノードの連なりを道と言い，道上で三ノードが $A \to C \leftarrow B$ と結合するとき，C を合流結合するノードと言う．また，$X \perp Y \mid \mathbf{Z}$ は X と Y のノード集合 $\mathbf{Z}$ を所与とした条件付き独立性を表すとする．このとき，以下の定理で示す推移性が成り立つ．

定理 1 $G = (\mathbf{V}, \mathbf{E})$ を DAG とし，X，$Y \in \mathbf{V}$ で，Y は X の非子孫とする．このとき，$A \in \mathbf{V} \setminus (\{X, Y\} \cup \mathbf{\Pi}_X^G \cup \mathbf{W})$ とすると，以下が成り立つ．

$$X \perp Y \mid \mathbf{\Pi}_X^G \Rightarrow X \perp A \mid \mathbf{\Pi}_X^G \ or \ A \perp Y \mid \mathbf{\Pi}_X^G. \tag{4}$$

ここで，$\mathbf{W}$ は X の子孫であり，X と Y が合流結合するノードとその子孫からなるノード集合を表し，$\mathbf{\Pi}_X^G$ は X の G における親ノード集合を表す．

証明は省略する．定理 1 より，ある二変数の条件付き独立性からその各変数と他変数との条件付き独立性を少なくとも一つ保証できる．これを制約ベースアプローチに利用することで，あるエッジを削除したとき，その両端と他ノードとのエッジの少なくとも一つの削除が保証される．これにより，より学習の早期にエッジを削除でき，CI テスト数の削減を期待できる．

4.2 提案アルゴリズム

本節では，定理 1 の推移性を用いたエッジ削除法を提案し，それを Bayes factor を用いた RAI アルゴリズムへ組み込む．

定理 1 の推移性を利用するためには推移性を有する候補ノード A の探索空間を同定する必要がある．今，$\mathbf{V}$ をノード集合とし，X，$Y \in \mathbf{V}$，$\mathbf{\Pi}_X^G$ を X のグラフ G における親ノード集合とする．また，$\mathbf{W}$ を X の子孫で，X と Y が合流結合するノードとその子孫からなるノード集合とする．このとき，候補ノード A の探索空間は $\mathbf{V} \setminus (\{X, Y\} \cup \mathbf{\Pi}_X^G \cup \mathbf{W})$ であるため，まずノード集合 $\mathbf{W}$ の要素を列挙しなければならない．$\mathbf{W}$ の要素を列挙するためには合流結合を同定する必要があるが，これは X，Y 間で X の子孫を持つ全ての道を探索しなければならず，計算量が大きい．しかし，推移性を有するノード A の探索空間は式（4）でさらに制約でき，これにより探索空間を同定する計算量を軽減できる．今，X，Y のエッジを削除したとき，X と A か A と Y（もしくは両方）のエッジがすでに削除されていたとする．このとき，X と A か A と Y（もしくは両方）の条件付き独立性がすでに検出されているため，式（4）はすでに成り立っており，推移性を利用する必要がない．すなわち，A の探索空間は X と Y の共通隣接ノード集合 $\mathbf{Adj}(X, G) \cap \mathbf{Adj}(Y, G)$ に含まれなければならない．ここで，X と Y の共通子ノード集合 $\mathbf{Ch}(X, G) \cap \mathbf{Ch}(Y, G)$ はノード集合 $\mathbf{W}$ に含まれるために A の探索空間から除外する．また，定理 1 より，$\mathbf{\Pi}_X^G$ も除外する．したがって，A の探索空間は $\mathbf{Adj}(X,G) \cap \mathbf{Adj}(Y,G) \setminus (\mathbf{Ch}(X,G) \cap \mathbf{Ch}(Y,G) \cup \mathbf{\Pi}_X^G)$ となる．この探索空間は条件付き独立となる二ノード X，Y の共通隣接ノードを探索すれば同定できるため，ノード数に対して線形時間で計算できる．

定理 1 の推移性を利用した CI テストとエッジ削除法を Algorithm2 に示す．関数 TRANSITIVE_CUT は学習途中のグラフ G，$\log \mathrm{BF}(X, Y \mid \mathbf{Z}) < 0$ となる二ノード X，Y とノード集合 $\mathbf{Z}$，データ $\mathbf{D}$ を入力とし，推移性に基づくエッジの削除を行ったあとにグラフを出力する．具体的には，$\mathbf{Adj}(X, G) \cap \mathbf{Adj}(Y, G) \setminus (\mathbf{Ch}(X, G) \cap \mathbf{Ch}(Y, G) \cup \mathbf{Z})$ を前述の探索空間とし，この探索空間に属するノードを A とする．二つのノード対 X と A，A と Y のそれぞれに対して $\mathbf{Z}$ を所与とした Bayes factor を用いる CI テストを行い，独立と判定されたノード対の間のエッジをグラフから削除する．以上を探索空間に属する全てのノードに対して繰り返す．

Algorithm 2 Edge cutting with transitivity

```
1:  function TRANSITIVE_CUT(G, X, Y, Z, D)
    G = (V, E): 全体グラフ
    X, Y, Z: log BF(X, Y | Z) < 0 となる二ノード X，Y とノード集合 Z
    D: データ
2:      A ← Adj(X,G)∩Adj(Y,G)\(Ch(X,G)∩Ch(Y,G)∪Z)
3:      for A ∈ A do
4:          if log BF(X, A | Z) < 0 then
5:              E ← E \ {E_XA}                    ▷ E_XA: XA 間のエッジ
6:          end if
7:          if log BF(A, Y | Z) < 0 then
8:              E ← E \ {E_AY}
9:          end if
10:     end for
11:     return G
12: end function
```

前述のとおり，推移性を有するノード A の探索空間は条件付き独立となる二ノード X，Y の共通子ノード集合を含まない．すなわち，推移性を利用したエッジ削除法を利用するためには事前にエッジを方向付け，子ノードを同定する必要がある．したがって，無向グラフにおいてエッジを削除する PC アルゴリズムや MMHC アルゴリズムでは推移性を利用できない．一方で，RAI アルゴリズムは学習途中にエッジを方向付けるため，推移性を利用できる．そこで，本研究では推移性を利用したエッジ削除法を RAI アルゴリズムに組み込む．

推移性を用いたエッジ削除法を RAI アルゴリズムに利用するためには関数 TRANSITIVE_CUT を関数 RAI におけるエッジの削除後（Algorithm1 の 12 行目と 20 行目の直後）に呼び出せば良い．ここで，CI テストの次数が 0 のとき，関数 RAI は，推移性の利用の有無に関わらず，全てのノード対に対して一回ずつの CI テストを行わなければならない．そのため，提案手法は関数 TRANSITIVE_CUT を 0 次の CI テストでは呼び出さず，1 次以降のときにのみ呼び出す．

提案手法は推移性によって少なくとも一つの条件付き独立性が保証される二組のエッジの CI テストを優先的に実施できるため，学習の早期にエッジを削除でき，CI テスト数を削減できる．制約ベースアプローチの時間計算量は CI テスト数に依存するため，提案手法は計算時間も削減できる．また，データ数が十分に大きくないとき，信頼性の低い CI テストを削減するため，従来の制約ベースアプローチ以上の学習精度を保証する．さらに，提案手法は従来では実現してこなかった大規模構造学習の実現を期待できる．

5. 比較実験

本提案手法の有効性を示すため，シミュレーション実験によって従来では最も高速な手法である RAI アルゴリズムと比較する．各手法の CI テストには Bayes factor（ESS= 1.0[Ueno 10]）を用いる．真のネットワークとして *bnlearn*[Scutari 11] に登録されているベンチマークネットワークの munin（ノード数 : 1041，エッジ数 : 1397）と *BNGenerator*[*1] を用いてランダムに生成したネットワーク random（ノード数 : 2000，エッジ数 : 2973）を使用する．実験は，(1) 各ネットワークからデータをランダム生成し，(2) 各手法で構造学習することを（3）それぞれ 10 回繰り返すことで行う．ただし，6 時間の制限時間を設け，超過する場合は実験を打ち切った．評価尺度は，学習速度を表す CI テスト数，計算時間と学習精度を表す Structural Hamming

*1 http://sites.poli.usp.br/pmr/ltd/software/bngenerator/

表 1: 実験結果

ネットワーク	munin		random	
CI テスト数（$\times 10^3$）				
データ数	RAI	提案	RAI	提案
10,000	560.4	553.4	2024.6	2022.8
20,000	588.9	562.4	2025.6	2022.8
50,000	653.4	575.8	2030.0	2025.1
100,000	705.1	582.1	2034.9	2027.5
200,000	665.3	588.2	-	2031.3
計算時間（秒）				
データ数	RAI	提案	RAI	提案
10,000	773	621	4933	3189
20,000	1593	871	4794	2945
50,000	2587	1457	6354	3625
100,000	4784	2195	7761	6907
200,000	7256	3908	-	13172
SHD				
データ数	RAI	提案	RAI	提案
10,000	504.4	461.8	2736.1	2545.7
20,000	504.1	430.4	2800.1	2546.6
50,000	525.9	404.0	2924.4	2569.6
100,000	552.5	405.6	3037.9	2592.6
200,000	540.6	404.1	-	2627.1

Distance（SHD）[Tsamardinos 06] を使用する．SHD は真の構造と推定された構造間の距離を表し，小さいほど学習精度が高いことを示す．

表 1 に各手法の学習結果を示す．表 1 より，提案手法は従来の RAI アルゴリズムより CI テスト数と計算時間を削減して学習した．したがって，提案手法は大規模構造を従来より高速に学習できる．また，提案手法は従来の RAI アルゴリズムより SHD を減少して学習した．大規模構造ではデータがスパースになるために CI テストの信頼性が低下する傾向がある．提案手法は CI テストを削減したことで，信頼性の低い CI テストを減少して学習できたためと考えられる．従来の RAI アルゴリズムはデータ数 200,000 のときに random を制限時間内に学習できなかったが，提案手法は全パターンで学習できた．これより，提案手法は従来手法では実現できない構造学習を実現できる．

6. まとめ

本研究はベイジアンネットワークにおける条件付き独立性の推移性を示し，Bayes factor を用いた RAI アルゴリズムの CI テストとエッジ削除に推移性を利用した学習手法を提案した．これにより，学習に要する CI テスト数を削減し，より短い計算時間で大規模構造学習を実現した．また，信頼性の低い CI テストを減少して学習したために従来手法以上の精度で大規模構造を学習した．さらに，提案手法は従来手法では実現できない構造学習を実現した．

今後の課題として，大規模構造学習の精度向上と，推論精度を最適化する学習やベイジアンネットワーク分類器の厳密学習への拡張が挙げられる，

参考文献

[Chickering 96] Chickering, D. M.: Learning Bayesian Networks is NP-Complete, in *Learning from Data: Artificial Intelligence and Statistics*, Vol. V, pp. 121–130, Springer (1996)

[Cussens 11] Cussens, J.: Bayesian network learning with cutting planes, in *Proceedings of Uncertainty in Artificial Intelligence (UAI)*, pp. 153–160, AUAI Press (2011)

[Heckerman 95] Heckerman, D., Geiger, D., and Chickering, D.: Learning Bayesian Networks: The Combination of Knowledge and Statistical Data, *Machine Learning*, Vol. 20, pp. 197–243 (1995)

[Natori 17] Natori, K., Uto, M., and Ueno, M.: Consistent learning Bayesian networks with thousands of variables, in *Advanced Methodologies for Bayesian Networks (Proceedings of Machine Learning Research)*, Vol. 73, pp. 57–68 (2017)

[Pearl 00] Pearl, J.: *Causality: Models, Reasoning, and Inference*, Cambridge University Press (2000)

[Scutari 11] Scutari, M.: Learning Bayesian Networks with the bnlearn R Package, *Journal of Statistical Software*, Vol. 35, No. 3, pp. 1–22 (2011)

[Silander 06] Silander, T. and Myllymaki, P.: A simple approach for finding the globally optimal Bayesian network structure, in *Proceedings of Uncertainty in Artificial Intelligence (UAI)*, pp. 445–452, AUAI Press (2006)

[Spirtes 00] Spirtes, P., Glymour, C., and Scheines, R.: *Causation, Prediction, and Search*, MIT press (2000)

[Steck 02] Steck, H. and Jaakkola, T.: On the Dirichlet Prior and Bayesian Regularization., in *Neural Information Processing Systems (NIPS 2002)*, pp. 697–704, MIT Press (2002)

[Tsamardinos 06] Tsamardinos, I., Brown, L. E., and Aliferis, C. F.: The Max-min Hill-climbing Bayesian Network Structure Learning Algorithm, *Machine Learning*, Vol. 65, No. 1, pp. 31–78 (2006)

[Ueno 10] Ueno, M.: Learning networks determined by the ratio of prior and data, in *Proceedings of Uncertainty in Artificial Intelligence (UAI)*, pp. 598–605, AUAI Press (2010)

[Yehezkel 09] Yehezkel, R. and Lerner, B.: Bayesian Network Structure Learning by Recursive Autonomy Identification, *Journal of Machine Learning Research*, Vol. 10, pp. 1527–1570 (2009)

[Yuan 11] Yuan, C., Malone, B., and Xiaojian, W.: Learning Optimal Bayesian Networks Using A* Search, in *International Joint Conference on Artificial Intelligence (IJCAI)*, pp. 2186–2191 (2011)

[名取 18] 名取和樹, 宇都雅輝, 植野真臣 FBayes factor を用いた RAI アルゴリズムによる大規模ベイジアンネットワーク学習, 電子情報通信学会論文誌 D, Vol. 101, No. 5, pp. 754–768 (2018)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

Augmented Naive Bayes Classifierの大規模構造学習

Learning huge Augmented Naive Bayes Classifier

菊谷成慎 Naruchika Kikuya　菅原聖太 Shouta Sugahara　名取和樹 Kazuki Natori　本田和雅 Kazunori Honda　植野真臣 Maomi Ueno

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

For classification problems, Bayesian networks are often used to infer a class variable when given feature variables. Earlier reports have described that classification accuracies of exact learning augmented naive Bayes (ANB) achieved by maximizing the marginal likelihood (ML) were higher than the Bayesian network of the identification model However, the method cannot learn structures that have more than several dozen variables. To resolve this difficulty, this study proposed exact learning ANB using RAI algolithm. The experimental results show that the proposed method outperforms the other methods.

1. まえがき

ベイジアンネットワークは，離散確率変数をノードで表しノード間の依存関係を非循環有向グラフ（Directed Acyclic Graph: DAG）で表現する確率的グラフィカルモデルである．ベイジアンネットワークは，確率構造に DAG を仮定することにより，同時確率分布を条件付き確率の積に分解する．ベイジアンネットワークの構造は一般にデータから推定する必要があり，これをベイジアンネットワークの構造学習という．構造学習法として，漸近一致性を有する学習スコアを用いて，候補構造から最適なスコアを持つ構造を探索する厳密解探索アプローチが従来から用いられている．また，一般に学習スコアとして周辺尤度（Marginal Likelihood: ML）が用いられてきた．

ベイジアンネットワークにおける一つのノードを目的変数とし，その他のノードを説明変数としたベイジアンネットワーク分類器（Bayesain Network Classifier: BNC）は，離散変数を扱う分類器として知られている [Friedman 97]．BNC は説明変数を所与とした目的変数の条件付き確率をモデル化する識別モデルのほうが，通常のベイジアンネットワークを構造学習した生成モデルよりも分類精度が高いことが報告されている [Carvalho 11]．しかし，近年，Sugahara ら [Sugahara 18] は，データが十分大きいならば，生成モデルのほうが分類精度が高いことを示した．しかし，データが少ないときに目的変数の親が多い構造をとる場合，分類精度が著しく低下してしまうと指摘した．この問題を解決するために，彼らは目的変数が親を持たず，全ての説明変数を子に持つ構造を仮定した Augmented Naive Bayes（ANB）[Friedman 97] を厳密学習する手法を提案している．これにより，データが少ない場合も高い分類精度を得られることを経験的に示した．

しかし，厳密解探索アプローチによる厳密学習は NP 困難問題である．様々な学習アルゴリズムが提案されているが，未だに数十変数程度の構造学習が限界であり，Sugahara らの手法は多くの変数に対応できない．

一方，因果モデル分野では，漸近一致性は持たないが，より計算効率の高い制約ベースの構造学習法が提案されている．条件付き独立性検定（Conditional Independence test: CI テスト）と，オリエンテーションルールによるエッジの方向付けを行うことで DAG を効率的に学習する．従来の CI テストでは漸近一致性を持たないことが問題であったが，名取らは，最先端手法である RAI アルゴリズム [Yehezkel 09] の CI テストに Bayes factor を用いることで漸近一致性を有しつつ，1000 変数以上の大規模構造学習を実現している [名取 18]．さらに，本田らは推移性を組み込むことで，2000 変数程度の大規模構造学習を実現している [本田 19]．

そこで本論文では，本田らの手法を ANB 学習に拡張させ，従来よりも大規模な BNC を学習することを目指す．さらに，評価実験により，提案手法が従来手法よりも大規模な説明変数を持つ分類問題で精度が高いことを示す．

連絡先: 電気通信大学大学院情報理工学研究科，調布市調布ヶ丘 1-5-1，042-484-8585，
{kikuya,sugahara,natori,hondak,ueno}@ai.lab.uec.ac.jp

2. ベイジアンネットワーク

ベイジアンネットワークは，離散確率変数をノードとし，ノード間の依存関係を非循環有効グラフ（Directed Acyclic Graph: DAG）と各ノードの条件付き確率で表現する確率的グラフィカルモデルである．今，$\mathbf{X} = \{X_0, X_1, \ldots, X_n\}$ を離散確率変数集合とし，各変数 X_i は r_i 個の状態集合 $\{1, \ldots, r_i\}$ から一つの値 k を取る（$X_i = k$ と書く）とする．このとき，構造 G において，各ノード X_i の親ノード集合を Π_i としたときの同時確率分布 $P(X_0, X_1, \ldots, X_n \mid G, \Theta)$ は以下のように表現できる．

$$P(X_0, X_1, \ldots, X_n \mid G, \Theta) = \prod_{i=0}^{n} P(X_i \mid \Pi_i, G, \Theta). \quad (1)$$

ここで，θ_{ijk} を Π_i が j 番目のパターンを取るとき ($\Pi_i = j$ と書く) に $X_i = k$ となる条件付き確率 $P(X_i = k \mid \Pi_i = j, G)$ を示すパラメータとし，パラメータ集合 $\Theta = \{\theta_{ijk}\}, (i = 0, \ldots, n; j = 1, \ldots, q_i; k = 1, \ldots, r_i)$ とする．

ベイジアンネットワークでは，パラメータ推定値として，期待事後確率推定値（Expected a Posteriori: EAP）が最もよく用いられる．変数集合 $\mathbf{X}$ に対する N 個のデータを $\mathbf{D} = \{D_1, \ldots, D_N\}$ とすると，EAP は事前分布にディリクレ分布を仮定することで次式で求まる．

$$\hat{\theta}_{ijk} = \frac{\alpha_{ijk} + N_{ijk}}{\alpha_{ij} + N_{ij}}. \quad (2)$$

ここで，N_{ijk} は，X_i の親変数集合 Π_i が j 番目のパターンを取った時の $X_i = k$ となるデータの頻度を表し，$n_{ij} = \sum_{k=1}^{r_i} n_{ijk}$ を表す．また，$\boldsymbol{\alpha} = \{\alpha_{ijk}\}, (i = 0, \ldots, n; j = 1, \ldots, q_i; k = 1, \ldots, r_i)$ はディリクレ事前分布のハイパーパラメータであり，$\alpha_{ij} = \sum_{k=1}^{r_i} \alpha_{ijk}$ である．

ベイジアンネットワークは最適な構造もデータから推定する必要がある．これをベイジアンネットワークの構造学習という．構造学習法として，候補構造から最適なスコアを持つ構造を探索する厳密解探索アプローチが従来から用いられている．一般に学習スコアとして周辺尤度 $P(\mathbf{D} \mid G)$（Marginal Likelihood: ML）が用いられる．ML はパラメータの事前分布にディリクレ分布を仮定することで次のように閉形式で表せる．

$$P(\mathbf{D} \mid G) = \prod_{i=0}^{n} \prod_{j=1}^{q_i} \frac{\Gamma(\alpha_{ij})}{\Gamma(\alpha_{ij} + N_{ij})} \prod_{k=1}^{r_i} \frac{\Gamma(\alpha_{ijk} + N_{ijk})}{\Gamma(\alpha_{ijk})}. \quad (3)$$

近年では，$\alpha_{ijk} = \alpha/(r_i q_i)$ とした Bayesian Dirichlet equivalent uniform (BDeu) が最も用いられる．ここで，α は Equivalent Sample Size (ESS) と呼ばれる事前知識の重みを示す疑似サンプルである．BDeu を用いた厳密学習は漸近一致性を持つことから，学習データが十分大きいならば真の構造を推定することが知られている．

しかし，厳密解探索アプローチは NP 困難であり，変数数に対して計算時間が爆発的に増加してしまう．厳密解を効率的に探索するために，動的計画法，A*探索，整数計画法などが提案されているが，数十変数の構造学習が限界であり，大規模構造を学習することができない．

3. ベイジアンネットワーク分類器

ベイジアンネットワーク分類器（BNC）は，ベイジアンネットワークにおける一つのノードを目的変数，それ以外のノードを説明変数とした分類器であり，高い分類精度を持つ [Friedman 97]．今，X_0 を目的変数とし，$X_1, \ldots, X_n$ を説明変数とした BNC を考える．説明変数のデータ $\mathbf{e} = \langle x_1, \ldots, x_n \rangle$ が与えられた時，目的変数の推定値 $\hat{c}$ は以下のように得られる．

$$\begin{aligned}
\hat{c} &= \arg\max_{c \in \{1,\ldots,r_0\}} P(c \mid x_1, \ldots, x_n, G) \quad (4)\\
&= \arg\max_{c \in \{1,\ldots,r_0\}} \prod_{i=0}^{n} \prod_{j=1}^{q_i} \prod_{k=1}^{r_i} (\theta_{ijk})^{1_{ijk}} \\
&= \arg\max_{c \in \{1,\ldots,r_0\}} \left[\prod_{j=1}^{q_0} \prod_{k=1}^{r_0} (\theta_{0jk})^{1_{0jk}} \right. \\
&\qquad \left. \times \prod_{i:X_i \in \mathbf{C}} \prod_{j=1}^{q_i} \prod_{k=1}^{r_i} (\theta_{ijk})^{1_{ijk}} \right]
\end{aligned}$$

ここで，1_{ijk} はデータ $\mathbf{e}$ が与えられた時，$X_i = k$ かつ $\Pi_i = j$ の時 1 をとり，それ以外の場合は 0 をとる変数である．さらに，$\mathbf{C}$ は目的変数の子集合である．式 (4) より，目的変数 X_0 の親集合，子集合，X_0 と子を共有している変数集合の和集合のみで推定値 $\hat{c}$ を求めることができる．また，この集合を X_0 のマルコフブランケット（Markov Blanket: MB）と呼ぶ．

BNC の構造学習は通常，ベイジアンネットワークと同様にデータから学習する．構造に制約を持たない BNC を General Bayesian Network（GBN）と呼ぶ．しかし，BDeu などで学習された GBN は目的変数が子を持たず，親を多く持つ構造をとることがある．このような構造では条件付きパラメータ数が多くなり，パラメータの推定に用いられるデータがスパースになる．その結果，パラメータの推定精度が悪くなり，分類精度が著しく低くなる傾向がある．この問題を回避できる BNC として，目的変数が全ての説明変数を子に持ち，説明変数間が独立であると仮定する Naive Bayes，目的変数が全ての説明変数を子に持ち，説明変数間で木構造をとると仮定した Tree-Augmented Naive Bayes（TAN）[Friedman 97] などが提案されている．また，これらを一般化したモデルとして，目的変数が全ての説明変数を子に持つことのみ仮定する Augmented Naive Bayes（ANB）[Friedman 97] が知られている．

ML を最大にする BNC は同時確率をモデル化した生成モデルであるが，説明変数を所与とした目的変数の条件付き尤度をモデル化する識別モデルのほうが，漸近的な分類精度が高いことが報告されていた [Carvalho 13]．しかし，識別モデルとしての BNC が生成モデルとしての BNC よりも高い分類精度を得られる根拠が理論的に示されていない．そこで，Sugahara ら [Sugahara 18] は ML で厳密学習した BNC は，識別モデルの BNC よりも生成モデルの分類精度が低いとは限らないことを示した．しかし，先述したように生成モデルの BNC は目的変数の親が多い構造を学習した場合，分類精度が著しく低下してしまう．この問題を解決するため，彼らは ANB を生成モデルとして厳密学習する手法を提案した．結果は，提案手法がデータが少ない場合でも安定した分類精度を得ることができ，識別モデルの BNC より有意に分類精度が高いことを示した．しかし，厳密学習は数十変数の学習が限界であり，変数数が多いデータに対して用いることができない．そこで本論文では，BNC の大規模構造学習法を提案する．

4. 制約ベース厳密構造学習

4.1 Bayes factor を用いた制約ベース厳密学習

制約ベースアプローチは計算量を大幅に削減できる構造学習法である．このアプローチの基本的なアルゴリズムは次のとおりである．

(1) 完全無向グラフを生成する．

(2) (1) で生成された完全無向グラフに対し条件付き独立検定（Conditional Independence test: CI テスト）によりエッジを削除する．

(3) (2) で得られた無向グラフに対してオリエンテーションルールを用いて方向付けを行う．

一般に，制約ベースアプローチの学習精度は CI テストの精度に依存し，学習速度は学習に要する CI テストの回数に依存する．制約ベースアプローチとして，PC アルゴリズム，MMHC アルゴリズム，RAI アルゴリズム [Yehezkel 09] が提案されてきた．しかし，これらのアルゴリズムでは χ^2 検定，G^2 検定，条件付き相互情報量などを CI テストに用いるため，漸近一致性を持たない．

一方で，二変数間が従属・独立モデルの周辺尤度の比による Bayes factor を用いた漸近一致性を有する CI テストが提案されている．ベイジアンネットワークのノード X,Y において X と Y 間について各ノードの共通親ノード集合 $\mathbf{Z}$ をとしたときの従属なモデルを G_1，独立モデルを G_2 としたときの Bayes factor を $\mathrm{BF}(\mathrm{X}, \mathrm{Y} \mid \mathbf{Z})$ とすると，対数 Bayes factor は，

$$\log \mathrm{BF}(X, Y \mid \mathbf{Z}) = \log \frac{P(\mathbf{D} \mid G_1, \boldsymbol{\alpha})}{P(\mathbf{D} \mid G_2, \boldsymbol{\alpha})} \quad (5)$$

と表される．ここで，$P(\mathbf{D} \mid G_1, \boldsymbol{\alpha})$，$P(\mathbf{D} \mid G_2, \boldsymbol{\alpha})$ は式（3）の BDeu を用いる．Bayes factor を用いた CI テストでは，対数 Bayes factor が 0 以上か否かで従属，独立を判断する．名取ら [名取 18] は Bayes factor を用いた CI テストが漸近的に真の条件付き独立性を判定できることを示した．さらに，Bayes factor を用いた CI テストを RAI アルゴリズムに組み込んだ手法を提案し，漸近一致性を有しつつ 1000 変数を超える大規模構造学習を実現した．

4.2 推移性を用いた厳密アルゴリズム

前述のように、制約ベースの学習速度はＣＩテストの回数に依存する．一般にＣＩテストの回数は学習のできる限り早期にエッジを削除するほど削減できる．そのために以下の推移性を用いる手法が提案されている．

定理 4..1 $G = (\boldsymbol{V}, \boldsymbol{E})$ を DAG とし，$X, Y \in \boldsymbol{V}$ で，Y は X の非子孫とする．このとき，$A \in \boldsymbol{V} \backslash (\{X, Y\} \cup \boldsymbol{Pa}(X, G) \cup \boldsymbol{W})$ とすると，以下が成り立つ．

$$X \perp Y \mid \mathbf{Pa}(X, G) \rightarrow X \perp A \mid \mathbf{Pa}(X, G) \; or \; A \perp Y \mid \mathbf{Pa}(X, G) \tag{6}$$

ここで，$\mathbf{W}$ は X の子孫であり，X と Y が合流結合するノードとその子孫からなるノード集合を表し，$\mathbf{Pa}(X, G)$ は X の G における親ノード集合を表す．証明は [本田 19] を参照してほしい．定理 4..1 より，ある二変数の条件付き独立性からその各変数と他変数との条件付き独立性の少なくとも一つを保証できる．これを利用することで，二変数の条件付き独立性から少なくとも一つの条件付き独立が保証される二組のエッジの CI テストを列挙できる．列挙されたＣＩテストを優先して行うことでより学習の早期にエッジを削除できる．本田らは推移性によるエッジの削除法を Bayes factor を用いた RAI アルゴリズムに組み込むことで CI テストの回数を削減し，2000 変数程度の大規模構造を実現した．

本論文では，本田らの手法 [本田 19] を用いることで，従来よりも大規模な BNC の構造学習の実現を目指す．

5. 提案手法

本章では，本田らの手法を ANB 学習に拡張させる方法を示す．まず，RAI アルゴリズムの基本的な動作を紹介する．今，グラフを $G = (\mathbf{V}, \mathbf{E})$ と表し，$\mathbf{V}, \mathbf{E}$ はそれぞれ G に含まれるノード集合，エッジ集合を表す．ここで，G は有向エッジと無向エッジを併せ持つとする．また，$G_{ex} = (\mathbf{V}_{ex}, \mathbf{E}_{ex})$ を RAI アルゴリズムによって分割された部分グラフとする．

(1) 完全無向グラフ G_{uc} とデータ $\mathbf{D}$ を入力する．

(2) 各次数の CI テストにおいて $\log \mathrm{BF}(X, Y \mid \mathbf{Z}) < 0$ となり X，Y が条件付き独立と判定されるとき，XY 間のエッジを削除する．

(3) 1 次以降の CI テストによるエッジの削除の直後，推移性に基づくエッジの削除を行う．ここでは，(2) の CI テストで推定した条件付き独立性から推移性により条件付き独立が成り立つ候補ノード集合 $\mathbf{A}$ を検出する．その後，X と A，A と Y（$A \in \mathbf{A}$）に対してそれぞれ CI テストを行い，条件付き独立と判定されるときエッジを削除する．

(4) 得られたグラフに対してオリエンテーションルールを適用して方向付けを行う．

(5) 方向付けの結果から部分グラフ G_{ex} に分割する．

(6) 各部分グラフで再帰的に RAI を呼び出す．

アルゴリズムの詳細は，[名取 18] や [本田 19] を参照してほしい．

ANB は目的変数が親を持たず，全ての説明変数を子に持つ構造である．上記のアルゴリズムで推定される構造に ANB を仮定するために，手順 (1) の初期グラフと，手順 (2)，手順 (3) の CI テストの実施範囲に制約を加えることで，RAI アルゴリズムを用いた ABN 厳密学習を実現する．ここで，目的変数のノードを X_0 それ以外のノードを目的変数のノードとする．

まず手順 (1) において，初期グラフを完全無向グラフ G_{uc} ではなく，G_{uc} に対して，目的変数 X_0 から全ての説明変数に向けてエッジの方向付けを行う．つまり，目的変数から説明変数へ向かう有向エッジと，説明変数間の無向エッジを併せ持つ完全グラフを初期グラフとする．

次に手順 (2) において，目的変数と説明変数を接続するエッジが CI テストで削除されないように，CI テストの実施範囲に制約を加える．つまり，目的変数 X_0 を除く二変数 $X', Y' \in \mathbf{V} \setminus \{X_0\}$ に対して CI テストを実施する．

手順 (3) においても同様に CI テストの実施範囲に制約を加える．ここでは，推移性により検出された候補ノード集合 $\mathbf{A}$ から目的変数 X_0 を除いた $A' \in \mathbf{A} \setminus \{X_0\}$ に対して CI テストを実施する．

これらの変更を加えることで RAI アルゴリズムは出力グラフに ANB を返す．

6. 評価実験

6.1 実験手順

UCI リポジトリデータベースから，変数数が大きな 13 個のデータセットを用いて従来手法で学習した BNC と提案手法で学習した BNC の分類精度を比較した．各データセットは欠損値を含まず，データに含まれる連続量はいずれも中央値を境に 2 値に離散化した．比較手法は，Naive Bayes，対数尤度を最適化した TAN（TAN），RAI アルゴリズムを用いて学習した GBN（RAI-GBN），RAI アルゴリズムを用いて学習した ANB（RAI-ANB）である．いずれの RAI アルゴリズムも CI テストに Bayes factor（ESS=1.0）を適用している．2 章で述べたように厳密解探索アプローチは数十ノードの学習が限界であるため比較対象から除外した．本論文では，RAI-ANB を提案手法とする．

また，解析の妥当性を示すため，各 BNC の構造学習と分類に対して 10 分割交差検証を行った．表 1 に各データセットに対する各手法の分類精度を載せた．提案手法の有意性を示すため，各手法の分類精度に対し Hommel 法を用いて多重検定を行い，p 値を表 1 の最下部に載せた．

6.2 結果と考察

表 1 より，提案手法は他手法よりも有意水準 0.05 のもとで有意に分類精度が高かった．また，RAI-GBN は分類精度の平均が最も低かった．表 2 は各データセットにおける RAI-GBN で学習した構造のエッジ数，目的変数の親と子の数，マルコフブランケット（MB）の平均を表している．表 2 より，RAI-GBN は，ほとんどのデータセットに対して親が多く，子が少ない構造を学習している．また，MB の数が全説明変数に対して小さ

表 1: 提案手法と従来手法の分類精度（太字は最大の分類精度）

	データセット	説明変数	目的変数の状態数	データ数	Naive Bayes	TAN	RAI-GBN	RAI-ANB
1	Connect-4	42	3	67557	0.7213	0.7643	0.7337	**0.7928**
2	dota2	116	2	102944	**0.5981**	0.5810	0.5442	0.5957
3	Epileptic Seizure	178	5	11500	0.2344	0.3650	0.1887	**0.4044**
4	Flowmeters D	43	4	180	**0.8389**	0.8389	0.6778	0.8278
5	kr-vs-kp	36	2	3196	0.8774	0.9240	0.9406	**0.9468**
6	madelon	500	2	2000	0.5905	0.5270	**0.6215**	0.5820
7	mfeat-fac	218	10	2000	0.3520	0.4590	0.2630	**0.4610**
8	MicroMass	1300	10	360	0.9472	0.9472	0.7361	**0.9500**
9	movement libras	90	15	360	0.5028	0.5389	0.2278	**0.5583**
10	Musk1	166	2	478	0.6517	0.7566	0.6744	**0.7965**
11	Musk2	166	2	6598	0.7445	0.8406	0.8821	**0.9627**
12	Parkinson's Disease	754	2	756	0.7182	0.7898	0.7672	**0.8108**
13	semeion	256	10	1600	0.8550	0.8719	0.4557	**0.8745**
	平均				0.6640	0.7080	0.6064	**0.7356**
	p 値				0.0026	0.0012	0.0009	-

表 2: RAI-GBN の統計概要

	データセット	エッジ数	子変数	親変数	MB
1	Connect-4	92.6	8.4	1.7	17.7
2	dota2	151.6	0	3.0	3.0
3	Epileptic Seizure	325.1	0	0	0.0
4	Flowmeters D	63.6	0	3.7	3.7
5	kr-vs-kp	249.4	0	5.1	5.1
6	madelon	249.4	0.1	2.6	3.0
7	mfeat-fac	630.7	0	3.5	3.5
8	MicroMass	2892.4	0	7.0	7.0
9	movement libras	109.7	0	2.4	2.4
10	Musk1	413.2	0	2.0	2.0
11	Musk2	946.9	0	6.1	6.1
12	Parkinson's Disease	1475.6	0	2.4	2.4
13	semeion	820.1	0	4.0	4.0

いことから，ほとんどの説明変数が目的変数の推定に関与していないことがわかる．また，目的変数の状態が多いデータを用いた場合，他手法と比べて著しく分類精度が低いことがわかる．このことから，データ数が不十分である場合，厳密解探索アプローチによる厳密学習の場合と同様に分類精度が著しく低くなることがわかる．それに対し提案手法は，目的変数が全ての説明変数を子に持つため，全ての説明変数が目的変数の分類に寄与している．また，目的変数が親を持たないため，パラメータ数が抑えられ，データ不足が緩和される．これらの理由から，提案手法を用いることで分類精度が高い構造が学習できたと考えられる．

7. むすび

本論文では，ベイズファクターを用いた RAI アルゴリズムを ANB 学習に拡張させることで，従来より大規模で高精度な BNC を学習する手法を提案した．提案手法は変数数が 1000 以上の大規模な ABN を学習できることを示した．また，評価実験により，提案手法は同規模の構造学習が可能な従来の BNC よりも分類精度が有意に高いことを示した．

参考文献

[Carvalho 11] Carvalho, A. M., Roos, T., Oliveira, A. L., and Myllymäki, P.: Discriminative Learning of Bayesian Networks via Factorized Conditional Log-Likelihood, *Journal of Machine Learning Research*, Vol. 12, pp. 2181–2210 (2011)

[Carvalho 13] Carvalho, A. M., Adão, P., and Mateus, P.: Efficient Approximation of the Conditional Relative Entropy with Applications to Discriminative Learning of Bayesian Network Classifiers, *Entropy*, Vol. 15, No. 7, pp. 2716–2735 (2013)

[Friedman 97] Friedman, N., Geiger, D., and Goldszmidt, M.: Bayesian Network Classifiers, *Machine Learning*, Vol. 29, No. 2, pp. 131–163 (1997)

[Sugahara 18] Sugahara, S., Uto, M., and Ueno, M.: Exact learning augmented naive Bayes classifier, in *International Conference on Probabilistic Graphical Models*, Vol. 72, pp. 439–450 (2018)

[Yehezkel 09] Yehezkel, R. and Lerner, B.: Bayesian network structure learning by recursive autonomy identification, *Journal of Machine Learning Research*, Vol. 10, pp. 1527–1570 (2009)

[本田 19] 本田和雅, 名取和樹, 菅原聖太, 磯崎隆司, 植野真臣 : 推移性を利用した大規模ベイジアンネットワーク構造学習, Master's thesis, 電気通信大学 (2019)

[名取 18] 名取和樹, 宇都雅輝, 植野真臣 : Bayes factor を用いた RAI アルゴリズムによる大規模ベイジアンネットワーク学習, 電子情報通信学会論文誌 D, Vol. 101, (2018)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

Augmented Naive Bayes Classifierの厳密学習

Exact Learning Augmented Naive Bayes Classifier

菅原聖太　植野真臣
Shouta Sugahara　Maomi Ueno

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

The purpose of this study is improving classification accuracies of Bayesian network classifiers. This study proposes exact learning augmented naive Bayes which is expected to provide stable and high accuracy. Our experiments demonstrate that the proposed method outperforms the other methods to learn discriminative models.

1. はじめに

ベイジアンネットワークは，離散確率変数をノードとし，ノード間の条件付き従属関係を非循環有向グラフ（Directed Acyclic Graph: DAG）で表し，同時確率分布を各ノードの親ノード集合を所与とした条件付き確率パラメータの積に分解する，確率的グラフィカルモデルである．ベイジアンネットワークにおける一つのノードを目的変数とし，その他のノードを説明変数としたベイジアンネットワーク分類器（Bayesian Network Classifier: BNC）は，離散変数を扱う分類器として知られている [Friedman 97]．

一般にベイジアンネットワークの DAG 構造はデータから推定する必要があり，この問題をベイジアンネットワークの構造学習と呼ぶ．構造学習では，候補構造から最適な学習スコアを持つ構造を探索するスコアベースアプローチが従来から行われてきた．一般にこのアプローチでは，漸近一致性を有する，構造の周辺尤度（Marginal Likelihood: ML）を学習スコアとして用いる．

ML を用いると，全変数の同時確率分布をモデル化する生成モデルとして BNC を学習できる．しかし，Friedman ら [Friedman 97] は，BNC の構造学習スコアとして，生成モデルではなく，説明変数を所与とした目的変数の条件付き確率分布をモデル化する識別モデルのためのスコアを用いるべきだと主張した．そのような学習スコアとして，説明変数を所与とした目的変数の条件付き対数尤度（Conditional Log Likelihood: CLL）が提案された．しかし，CLL はスコアの性質上，学習時間が膨大になってしまう．これを解決するため，CLL を用いた BNC の近似学習法が提案されてきた [Carvalho 11, Carvalho 13, Grossman 04]．これらの近似手法で学習した BNC の方が，ML で学習した BNC よりも分類精度が高いことが報告されている．

しかし，ML 最大化より CLL 最大化の方がなぜ良いかという理由については未だ明らかにされていない．ML は推定構造に対して漸近一致性が保証されており，サンプルサイズが大きい時に一致性のない CLL に分類精度が劣るのは奇異である．また，BNC の ML は閉形式で表せるため CLL より計算効率がよく，ML を大域的に最大化する構造を探索する厳密学習を効率的に行える．先行研究の比較実験では，ML を局所的に最大化する構造を探索する近似学習を行なっているため，探索精度の悪さが影響したのかもしれない．

そこで，本研究ではまず ML による厳密学習と CLL による近似学習によって得られた BNC の分類精度を比較する．結果として，ML 最大化による BNC は厳密学習することで，大きく精度が向上することがわかった．特にサンプルサイズが大きいときに，最も分類精度が高いことが示された．しかし，厳密学習ではサンプルサイズが小さくなると ML を最大化する BNC の分類精度が低くなり，最も単純な構造をもつ Naive Bayes よりも低い場合もあった．特に，目的変数の親変数が多く子変数が少ないような構造を学習する場合に分類精度が低くなっていることがわかった．その理由は，目的変数の親変数が多いと，パラメータ数が指数的に増えるため，一つのパラメータ学習のためのサンプルサイズが小さくなり，推定精度が悪くなってしまうからである．一方，目的変数の子変数の増加に対してパラメータ数は線形増加しかしないため，上の問題は緩和される．

この性質を利用して，本論文では，目的変数が親変数を持たず，全説明変数が必ず目的変数の子となる Augmented Naive Bayes (ANB) 構造を制約とした BNC の厳密学習を提案する．さらに変数数が大きい場合に分類に不必要な変数が影響することを避けるために，厳密学習により目的変数のマルコフブランケットを抽出し，その後，ANB 構造を厳密学習する手法を提案した．ANB はこれまで識別モデルとして扱われてきたため，ML を最大化して学習することはなかった．本論の提案は，識別モデルの学習ではなく，生成モデルとしての GBN の学習に，目的変数の親変数が増えないように ANB 構造を制約することである．ベンチマークデータによる比較実験で，提案手法が従来の分類法よりも有意に精度が向上し，小サンプルでも高い分類精度を示せた．

2. ベイジアンネットワーク

2.1 ベイジアンネットワーク

ベイジアンネットワークは，確率変数をノードとし，ノード間の条件付き従属関係を非循環有向グラフで表し，各ノードの親ノード集合を所与とした条件付き確率で表現される確率的グラフィカルモデルである．今，離散確率変数集合 $\{X_0, X_1, \cdots, X_i, \cdots, X_n\}$ において，各変数 X_i は r_i 個の状態集合 $\{1, \cdots, r_i\}$ から一つの値をとるとし，各変数 X_i が値 k をとるとき，$X_i = k$ と書く．また，ベイジアンネットワークの構造を G とし，G における変数 X_i の親変数集合を

連絡先: 電気通信大学大学院情報理工学研究科，調布市調布ヶ丘 1-5-1，042-484-8585，
{sugahara,ueno}@ai.lab.uec.ac.jp

Π_i とする．さらに，Θ をベイジアンネットワークの条件付き確率パラメータ集合とする．ベイジアンネットワークでは，次式のように同時確率分布 $P(X_0, X_1, \cdots, X_n \mid G, \Theta)$ を各変数の条件付き確率パラメータの積に分解して表せる．

$$P(X_0, X_1, \cdots, X_n \mid G, \Theta) = \prod_{i=0}^{n} P(X_i \mid \Pi_i, G, \Theta)$$

2.1.1 ベイジアンネットワークの構造学習

ベイジアンネットワークの構造はデータから推定する必要があり，この問題を構造学習と呼ぶ．構造学習では，候補構造から最適な学習スコアを持つ構造を探索するスコアベースアプローチが従来から行われてきた．一般に学習スコアとして周辺尤度（Marginal Likelihood: ML）を用いる．今，全変数に値が割り当てられたサンプルが N 個あり，t 番目のサンプルを $\mathbf{d}^t = \langle x_0^t, x_1^t, \cdots, x_n^t \rangle$ と表し，学習データを $D = \langle \mathbf{d}^1, \cdots, \mathbf{d}^t, \cdots, \mathbf{d}^N \rangle$ と表す．パラメータの事前分布がディリクレ分布と仮定すると，ML は次のように閉形式で表される．

$$P(D \mid G) = \prod_{i=0}^{n} \prod_{j=1}^{q_i} \frac{\Gamma(N'_{ij})}{\Gamma(N'_{ij} + N^D_{ij})} \prod_{k=1}^{r_i} \frac{\Gamma(N'_{ijk} + N^D_{ijk})}{\Gamma(N'_{ijk})} \quad (1)$$

ここで，N_{ijk} は D において Π_i が j 番目のパターンをとったとき（$\Pi_i = j$ と書く）に $X_i = k$ となる頻度を表し，N'_{ijk} はディリクレ事前分布のハイパーパラメータを表す．また，$N_{ij} = \sum_{k=1}^{r_i} N_{ijk}$，$N'_{ij} = \sum_{k=1}^{r_i} N'_{ijk}$ である．Buntine[Buntine 91] は式（1）のハイパーパラメータを $N'_{ijk} = N'/(r_i \cdot q_i)$ とした尤度等価を満たすスコアを提案しており，このスコアは Bayesian Dirichlet equivalent uniform（BDeu）と呼ばれ，最もよく用いられるスコアである．

一方，次式に示される，ML の近似である最小記述長（Minimum Description Length: MDL）[Rissanen 89] は，ベイジアンネットワークと学習データ D の同時記述長を表す．

$$MDL(D \mid G, \Theta) = \frac{\log N}{2}|\Theta| - \log P(D \mid G, \Theta) \quad (2)$$

MDL を用いた学習では，MDL を最小にする構造を最適解とする．式（2）の第一項は構造の複雑さに対するペナルティ項である．式（2）の第二項は構造のデータへの当てはまりを反映するフィッティング項を表す対数尤度である．

BDeu と MDL は各変数 X_i とその親変数集合 Π_i からなる局所構造のスコアについての総積（MDL の場合は総和）が構造全体のスコアに一致する分解可能なスコアであり，効率的な学習ができる．

2.2 ベイジアンネットワーク分類器

ベイジアンネットワークにおける一つのノードを目的変数とし，それ以外のノードを説明変数とした分類器モデルはベイジアンネットワーク分類器（BNC）と呼ばれ，高い分類精度を持つことが知られている [Friedman 97].

2.2.1 ベイジアンネットワーク分類器のモデル

一般に，BNC の構造学習で探索する候補構造はとりうる全ての構造であり，そのような候補構造に対して BD や MDL などを最適化して学習される BNC は General Bayesian Network（GBN）と呼ばれる．大きいネットワークでは GBN の学習に膨大な時間がかかってしまうため，候補構造に制約を入れて学習することが多い．例えば，GBN の下位構造として，各説明変数が目的変数のみを親に持つと仮定する Naive Bayes や，各説明変数が目的変数を親に持ち，説明変数間で木構造をとると仮定した Tree-Augmented Naive Bayes（TAN）[Friedman 97] などが知られている．また，Naive Bayes や TAN を一般化した，より表現力の高いモデルとして，各説明変数が目的変数を親に持つことのみを仮定する Augmented Naive Bayes（ANB）[Friedman 97]．が知られている．

2.2.2 ベイジアンネットワーク分類器の学習

BDeu や MDL で学習した BNC は，全変数の同時確率分布をモデル化する生成モデルである．しかし，Friedman ら [Friedman 97] は，BNC の構造学習には，説明変数を所与とした目的変数の条件付き確率分布をモデル化する識別モデルのためのスコアを用いるべきだと主張した．そのようなスコアとして，以下で表される，説明変数を所与とした目的変数の条件付き対数尤度（Conditional Log Likelihood: CLL）が提案された．

$$\sum_{t=1}^{N} \log P(x_0^t \mid x_1^t, \cdots, x_n^t, G, \Theta) \quad (3)$$

しかし，CLL は分解可能ではないため，効率的な構造探索アルゴリズムを用いることができない．そこで，Grossman ら [Grossman 04] は近似的な構造探索法として，構造に対しエッジを一つ追加，消去，反転のいずれかの操作を行った時に最もスコアが良くなるようなエッジを選びその操作を行うというプロセスを繰り返して構造を更新する Hill-Climbing アルゴリズム [Heckerman 95] を用いた．Hill-Climbing アルゴリズムでは，任意のエッジの追加，消去，反転のどの操作を行ってもスコアが改善されない時に更新を終了し，その時の構造を解とする．一方，Carvalho ら [Carvalho 13] は，候補構造集合に ANB を仮定し，分解可能となるよう CLL を近似した aCLL（approximate Conditional Log Likelihood）を提案した．

これらの近似手法で学習した BNC の方が，ML（BDeu や MDL など）によって近似的に学習した BNC よりも分類精度が高いことが報告されてきた．

しかし，ML 最大化より CLL 最大化の方がなぜ良いかという理由についてはこれまで明らかにされていない．ML は推定構造に対して漸近一致性が保証されており，サンプルサイズが大きい時に一致性のない CLL に分類精度が劣るのは奇異である．また，BNC の ML は分解可能であるため，ML による厳密学習は CLL による厳密学習とは異なり，現実的な時間で学習できる．先行研究の比較実験では，ML による近似学習を行なっているため，探索精度の悪さが影響したのかもしれない．

そこで，次章では ML によって厳密に学習した BNC と CLL によって近似的に学習した BNC の分類精度を比較する．

3. GBN の厳密学習と識別モデルの比較実験

本章では，BDeu によって厳密に学習した BNC と CLL によって近似的に学習した BNC の分類精度を比較する．この実験で比較する手法は，BDeu を用いて厳密学習した GBN（GBN-BDeu），Naive Bayes，MDL のフィッティング項を CLL に置き換えた Conditional MDL を用いて近似学習した GBN（GBN-CMDL），各変数が最大 2 つまでしか親を持たない構造を候補として，CLL を用いて近似学習した BNC（BNC-2P），aCLL を用いて厳密学習した TAN（TAN-aCLL），BDeu を用いて近似学習した GBN（gGBN-BDeu）である．近似学習の構造探索法としては Hill-Climbing を用い，厳密学習の構造探索手法としては動的計画法 [Silander 06] を用いた．UCI レポジトリ [Lichman 13] の 43 個のデータセットを用いた．

表 1: GBN-BDeu と従来手法の分類精度（太字は最大の分類精度）

No.	Dataset	Variables	Sample size	Classes	Naive-Bayes	GBN-CMDL	BNC2P	TAN-aCLL	gGBN-BDeu	GBN-BDeu
1	Balance Scale	5	625	3	**0.9152**	0.3333	0.8560	0.8656	**0.9152**	**0.9152**
2	banknote authentication	5	1372	2	0.8433	**0.8819**	0.8797	0.8761	**0.8819**	0.8812
3	Hayes-Roth	5	132	3	**0.8182**	0.6136	0.6894	0.6742	0.7525	0.6136
4	iris	5	150	3	0.7133	0.7800	0.8200	0.8200	0.8133	**0.8267**
5	lenses	5	24	3	0.7500	**0.8333**	0.6667	0.7083	**0.8333**	**0.8333**
6	Car Evaluation	7	1728	4	0.8571	**0.9497**	0.9416	0.9433	0.9416	0.9416
7	liver	7	345	2	0.6319	0.6145	0.6290	**0.6609**	0.6029	0.6087
8	MONK ' s Problems	7	432	2	0.7500	**1.0000**	**1.0000**	**1.0000**	0.8449	**1.0000**
9	mux6	7	64	2	0.5469	0.3750	**0.5625**	0.4688	0.4063	0.4531
10	led7	8	3200	10	0.7294	0.7366	**0.7375**	0.7350	0.7297	0.7294
11	HTRU2	9	17898	2	0.7031	0.7096	0.7070	0.7018	0.7188	**0.7305**
12	Nursery	9	12960	3	0.6782	**0.7126**	0.6092	0.5862	**0.7126**	**0.7126**
13	pima	9	768	9	0.8966	0.9086	0.9118	**0.9130**	0.9092	0.9112
14	post	9	87	5	0.9033	0.5823	**0.9442**	0.9177	0.9291	0.9340
15	Breast Cancer	10	277	2	**0.9751**	0.8917	0.9473	0.9488	0.7058	**0.9751**
16	Breast Cancer Wisconsin	10	683	2	**0.7401**	0.6209	0.6823	0.7184	0.7094	0.7184
17	Contraceptive Method Choice	10	1473	3	0.4671	0.4501	**0.4745**	0.4705	0.4440	0.4542
18	glass	10	214	6	0.5561	0.5654	0.5794	**0.6308**	0.4626	0.5701
19	shuttle-small	10	5800	6	0.9384	0.9660	**0.9703**	0.9583	0.9683	0.9693
20	threeOf9	10	512	2	0.8164	**0.9434**	0.8691	0.8828	0.8652	0.8887
21	Tic-Tac-Toe	10	958	2	0.6921	**0.8841**	0.7338	0.7203	0.6754	0.8340
22	MAGIC Gamma Telescope	11	19020	2	0.7482	0.7849	0.7806	0.7631	0.7844	**0.7873**
23	Solar Flare	11	1389	9	0.7811	0.8265	0.8315	0.8229	**0.8431**	**0.8431**
24	heart	14	270	2	**0.8259**	0.8185	0.8037	0.8148	0.8222	**0.8259**
25	wine	14	178	3	0.9270	**0.9438**	0.9157	0.9326	0.9045	0.9270
26	cleve	14	296	2	**0.8412**	0.8209	0.8007	0.8378	0.7973	0.7973
27	australian	15	690	2	0.8290	0.8312	0.8348	0.8464	0.8420	**0.8536**
28	crx	15	653	2	0.8377	0.8346	0.8208	0.8560	**0.8622**	0.8591
29	EEG	15	14980	2	0.5778	0.6787	0.6374	0.6125	0.6732	**0.6814**
30	Congressional Voting Records	17	232	2	0.9095	0.9698	0.9612	0.9181	**0.9741**	0.9655
31	zoo	17	101	5	0.9802	0.9109	0.9505	**1.0000**	0.9505	0.9307
32	pendigits	17	10992	10	0.8032	0.9062	0.8719	0.8700	0.9253	**0.9290**
33	letter	17	20000	26	0.4466	**0.5796**	0.5132	0.5093	0.5761	0.5761
34	ClimateModel	19	540	2	0.9222	**0.9407**	0.9241	0.9333	0.9370	0.9000
35	Image Segmentation	19	2310	7	0.7290	0.7918	0.7991	0.7407	0.8026	**0.8156**
36	lymphography	19	148	4	**0.8446**	0.7939	0.7973	0.8311	0.7905	0.7500
37	vehicle	19	846	4	0.4350	**0.5910**	**0.5910**	0.5816	0.5461	0.5768
38	hepatitis	20	80	2	0.8500	0.7375	**0.8875**	0.8750	0.8500	0.5875
39	german	21	1000	2	0.7430	0.6110	0.7340	**0.7470**	0.7140	0.7210
40	bank	21	30488	2	0.8544	0.8618	0.8928	0.8618	0.8952	**0.8956**
41	waveform-21	22	5000	3	0.7886	0.7862	0.7754	**0.7896**	0.7698	0.7846
42	Mushroom	22	5644	2	0.9957	**1.0000**	**1.0000**	0.9995	**1.0000**	0.9949
43	spect	23	263	2	0.7940	0.7940	0.7903	**0.8090**	0.7603	0.7378
	average				0.7764	0.7721	0.7936	0.7943	0.7867	**0.7963**

各手法，各データセットに対して，10 分割交差検証によるテストデータの平均一致率を求め，分類精度として表 1 に示した．各データセットに対し，各手法の中で最も高い分類精度を太字で示している．

表 1 を見ると，GBN-BDeu はサンプルサイズの大きいデータセット 11 番，12 番，22 番，32 番，40 番について，比較手法 6 つの中で分類精度が最も高い．この結果から，ML によって学習した BNC が必ずしも CLL によって学習した BNC より分類精度が低いとは限らないことがわかる．しかし，サンプルサイズの小さいデータセットである 3 番，9 番，31 番では GBN-BDeu の分類精度が著しく低い．これらのデータセットでは，GBN-BDeu の目的変数の子変数が少なく，親変数が多かった．このように目的変数の親変数が多いと，パラメータ数が指数的に増えるため，一つのパラメータ学習のためのサンプルサイズが小さくなり，推定精度が悪くなってしまう．一方で．目的変数の子変数の増加に対してパラメータは線形増加しかしないため，上の問題は緩和される．

この性質を考慮すると，目的変数の親変数が存在しないような制約の下で BDeu を最大化する構造を探索すれば，分類精度が高く安定した BNC を学習すると期待できる．これを実現できる単純な手法は，目的変数が全ての説明変数を子に持つ ANB を候補構造とすることである．しかし，ANB では，目的変数と無相関な変数が分類に影響を与えてしまう危険があり，その場合，一般に分類精度は下がってしまう．そこで本論では，GBN-BDeu の目的変数に影響を及ぼす変数集合であるマルコフブランケットを取り出し，それらを説明変数とした BDeu を最大化する ANB の厳密学習法を提案する．

4. 評価実験

本章では，提案手法と CLL をベースとした先行研究の手法の分類精度を比較するため，リポシトリデータを用いた評価実験を行う．提案手法とその他の変数選択を適用した各手法との有意性を示すため，分類精度の多重検定手法として標準的に用いられる Hommel の多重検定を行った．検定の p 値を表 2 の最下部に示した．ここで，表 2 において右端の MANB-BDeu が提案手法であり，各手法名の頭文字'M' は変数選択を適用したことを示している．

結果として提案手法は，GBN-BDeu の学習構造の目的変数の子変数が少なく，親変数が多かったデータセット 3 番，9 番，31 番において，GBN-BDeu の分類精度を改善している．この理由は，3 章で述べたパラメータ数増加の問題を提案手法で緩和できるからである．

さらに，表 2 より MANB-BDeu は全比較手法に対して有意水準 5% のもとで有意に分類精度が高いことがわかった．

5. むすび

本論では，最初に ML によって厳密に学習した生成モデルの BNC と CLL によって近似的に学習した識別モデルの BNC

表 2: 変数選択を用いた場合の各手法の分類精度

No.	Dataset	Variables	Sample size	Classes	MNaive-Bayes	MGBN-CMDL	MBNC 2P	MTAN-aCLL	MgGBN-BDeu	GBN-BDeu	MANB-BDeu
1	Balance Scale	5	625	3	**0.9152**	0.3333	0.8560	0.8656	**0.9152**	**0.9152**	**0.9152**
2	banknote authentication	5	1372	2	0.8433	**0.8819**	0.8783	0.8761	0.8812	0.8812	0.8812
3	Hayes-Roth	5	132	3	**0.8333**	0.6136	0.7197	0.7879	0.7980	0.6136	**0.8333**
4	iris	5	150	3	**0.8267**	0.7800	0.8200	0.8200	0.8200	**0.8267**	**0.8267**
5	lenses	5	24	3	0.8333	0.8333	0.8333	0.8333	**0.8750**	0.8333	0.8333
6	Car Evaluation	7	1728	4	0.8559	0.9242	0.9375	0.9363	**0.9416**	**0.9416**	**0.9416**
7	liver	7	345	2	**0.6348**	**0.6348**	0.6000	0.5942	0.6000	0.6087	0.5855
8	MONK ' s Problems	7	432	2	0.7500	**1.0000**	**1.0000**	**1.0000**	0.8194	**1.0000**	**1.0000**
9	mux6	7	64	2	0.5469	0.3750	**0.6250**	0.4688	0.3906	0.4531	0.5469
10	led7	8	3200	10	0.7294	0.7363	**0.7375**	0.7350	0.7303	0.7294	0.7294
11	HTRU2	9	17898	2	0.7083	0.7057	0.7044	0.7070	**0.7305**	**0.7305**	0.7227
12	Nursery	9	12960	3	**0.7126**	**0.7126**	**0.7126**	**0.7126**	**0.7126**	**0.7126**	**0.7126**
13	pima	9	768	9	0.9102	0.9046	0.9076	**0.9141**	0.9083	0.9112	**0.9141**
14	post	9	87	5	0.8996	0.8775	0.9322	0.9103	0.9258	**0.9340**	0.9174
15	Breast Cancer	10	277	2	**0.9751**	0.8909	0.9663	0.9458	0.9429	**0.9751**	**0.9751**
16	Breast Cancer Wisconsin	10	683	2	**0.7184**	**0.7184**	**0.7184**	**0.7184**	**0.7184**	**0.7184**	0.7166
17	Contraceptive Method Choice	10	1473	3	0.4549	0.4542	**0.4555**	0.4535	0.4501	0.4542	0.4549
18	glass	10	214	6	**0.5841**	0.5514	0.5467	**0.5841**	0.5047	0.5701	0.5654
19	shuttle-small	10	5800	6	0.9360	0.9645	0.9666	0.9605	0.9690	**0.9693**	**0.9693**
20	threeOf9	10	512	2	0.8145	0.8750	0.8750	0.8809	0.8652	**0.8887**	0.8711
21	Tic-Tac-Toe	10	958	2	0.7182	**0.8476**	0.7244	0.7213	0.7359	0.8340	**0.8476**
22	MAGIC Gamma Telescope	11	19020	2	0.7520	0.7841	0.7807	0.7699	0.7875	0.7873	**0.7880**
23	Solar Flare	11	1389	9	**0.8431**	**0.8431**	**0.8431**	**0.8431**	**0.8431**	**0.8431**	**0.8431**
24	heart	14	270	2	0.8222	0.8185	0.8148	0.8259	0.7889	0.8259	**0.8296**
25	wine	14	178	3	**0.9607**	0.9494	0.9438	0.9494	0.9326	0.9270	0.9326
26	cleve	14	296	2	**0.8176**	**0.8176**	0.7804	0.8108	0.7905	0.7973	0.8108
27	australian	15	690	2	0.8536	**0.8580**	0.8493	0.8522	0.8507	0.8536	0.8507
28	crx	15	653	2	**0.8622**	0.8545	0.8545	**0.8622**	0.8576	0.8591	**0.8622**
29	EEG	15	14980	2	0.5774	0.6790	0.6389	0.6111	0.6670	0.6814	**0.6935**
30	Congressional Voting Records	17	232	2	0.9353	**0.9698**	0.9655	0.9397	0.9655	0.9655	0.9569
31	zoo	17	101	5	0.9406	0.9406	0.9307	0.9307	**0.9505**	0.9307	**0.9505**
32	pendigits	17	10992	10	0.8032	0.9062	0.8719	0.8700	0.9253	0.9290	**0.9297**
33	letter	17	20000	26	0.4536	**0.5796**	0.5068	0.5036	0.5636	0.5761	0.5779
34	ClimateModel	19	540	2	0.9259	**0.9407**	0.9222	0.9352	0.9370	0.9000	0.8667
35	Image Segmentation	19	2310	7	0.7662	0.7848	0.7918	0.7922	0.8022	0.8156	**0.8203**
36	lymphography	19	148	4	**0.8176**	0.7027	0.7770	0.8041	0.7770	0.7500	0.8108
37	vehicle	19	846	4	0.4634	0.5816	0.5721	0.5922	0.5437	0.5768	**0.6028**
38	hepatitis	20	80	2	**0.8750**	0.8500	0.8625	0.8500	0.8625	0.5875	0.6625
39	german	21	1000	2	0.7210	0.7250	**0.7350**	0.7230	0.7230	0.7210	0.7240
40	bank	21	30488	2	0.8680	0.8955	0.8924	0.8777	0.8954	0.8956	**0.8966**
41	waveform-21	22	5000	3	0.7852	0.7912	0.7806	0.7814	0.7626	0.7846	**0.7920**
42	Mushroom	22	5644	2	0.9970	0.9991	0.9991	0.9972	**1.0000**	0.9949	**1.0000**
43	spect	23	263	2	**0.7865**	0.7303	0.7416	0.7715	0.7715	0.7378	0.7603
	average				0.7867	0.7801	0.7993	0.7981	0.7961	0.7963	**0.8074**
	p-value				0.0089	0.0054	0.0104	0.0057	0.0188	0.0301	-

の分類精度を比較した．その結果，ML を最大化する生成モデルが必ずしも CLL を最大化する識別モデルより分類精度が低いとは限らないことがわかった．しかし，ML は目的変数の親変数が多く子変数が少ないような構造を学習することがあり，その場合は CLL を最大化する BNC より著しく分類精度が低くなっていることがわかった．その理由は，目的変数の親変数が多いと，パラメータ数が指数的に増えるため，一つのパラメータ学習のためのサンプルサイズが小さくなり，推定精度が悪くなってしまうからである．一方で，目的変数の子変数の増加に対してパラメータ数は線形増加しかしないため，上の問題は緩和される．次に本論では，この性質を利用して，ML を最大化する GBN から目的変数のマルコフブランケットを取り出し，それを説明変数として ML を最大化する生成モデルとしての ANB を提案した．リポジトリデータセットを用いた実験を行ったところ，提案手法は ML を最大化する生成モデルの GBN の問題点を改善し，分類精度の著しい低下を防ぐことができた．さらに，提案手法は既存の CLL を最大化する識別モデルの BNC よりも分類精度が有意に高いことを示した．

参考文献

[Buntine 91] Buntine, W.: Theory Refinement on Bayesian Networks, in *Proceedings of the Seventh Conference on Uncertainty in Artificial Intelligence*, pp. 52–60, San Francisco, CA, USA (1991), Morgan Kaufmann Publishers Inc.

[Carvalho 11] Carvalho, A. M., Roos, T., Oliveira, A. L., and Myllymäki, P.: Discriminative Learning of Bayesian Networks via Factorized Conditional Log-Likelihood, *Journal of Machine Learning Research*, Vol. 12, pp. 2181–2210 (2011)

[Carvalho 13] Carvalho, A. M., AdÃčo, P., and Mateus, P.: Efficient Approximation of the Conditional Relative Entropy with Applications to Discriminative Learning of Bayesian Network Classifiers, *Entropy*, Vol. 15, No. 7, pp. 2716–2735 (2013)

[Friedman 97] Friedman, N., Geiger, D., and Goldszmidt, M.: Bayesian Network Classifiers, *Machine Learning*, Vol. 29, No. 2, pp. 131–163 (1997)

[Grossman 04] Grossman, D. and Domingos, P.: Learning Bayesian Network classifiers by maximizing conditional likelihood, in *Proceedings, Twenty-First International Conference on Machine Learning, ICML 2004*, pp. 361–368 (2004)

[Heckerman 95] Heckerman, D., Geiger, D., and Chickering, D. M.: Learning Bayesian Networks: The Combination of Knowledge and Statistical Data, *Machine Learning*, Vol. 20, No. 3, pp. 197–243 (1995)

[Lichman 13] Lichman, M.: UCI Machine Learning Repository (2013)

[Rissanen 89] Rissanen, J.: *Stochastic Complexity in Statistical Inquiry Theory*, World Scientific Publishing Co., Inc. (1989)

[Silander 06] Silander, T. and Myllymäki, P.: A Simple Approach for Finding the Globally Optimal Bayesian Network Structure, in *Proceedings of Uncertainty in Artificial Intelligence*, pp. 445–452 (2006)

General Session | General Session | [GS] J-2 Machine learning

[2Q5-J-2] Machine learning: advanced models

Chair:Masataro Asai Reviewer:Hikaru Kajino

Wed. Jun 5, 2019 5:20 PM - 7:00 PM Room Q (6F Meeting room, Bandaijima bldg.)

[2Q5-J-2-01] Bayesian Inverse Reinforcement Learning for Demonstrations of an Expert in Multiple Dynamics

○Yusuke Nakata[1], Sachiyo Arai[1] (1. Chiba University)

5:20 PM - 5:40 PM

[2Q5-J-2-02] Constructing a Recommender System using Variational Neural Networks

○Tomoki Ohtsuki[1], Shinsuke Sugaya[1], Ohnishi Yuki[1,2] (1. BizReach, Inc., 2. Purdue University)

5:40 PM - 6:00 PM

[2Q5-J-2-03] A Meta-Learning Perspective on Generative Query Network

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

6:00 PM - 6:20 PM

[2Q5-J-2-04] Variational Auto-Encoder On Stiefel Space

○Takaaki Sanjoh[1], Junpei Komiyama[2], Masashi Toyoda[2], Masaru Kitsuregawa[2,3] (1. The University of Tokyo, 2. Institute of Industrial Science, The University of Tokyo, 3. National Institute of Informatics)

6:20 PM - 6:40 PM

[2Q5-J-2-05] A Study of Pseudo-Simultaneous Systems

○Kotone Itaya[1,2], Naoyuki Sakai[3,4], Koichi Takahashi[1,3,4], Hiroshi Yamakawa[3,4] (1. RIKEN BDR, 2. Graduate School for Media and Governance, Keio University, 3. DWANGO AI Laboratory, Dwango, 4. The Whole Brain Architecture Initiative)

6:40 PM - 7:00 PM

©The Japanese Society for Artificial Intelligence

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

エキスパートが複数の環境で生成した軌跡から報酬を推定するベイジアン逆強化学習

Bayesian Inverse Reinforcement Learning for Demonstrations of an Expert in Multiple Dynamics

中田 勇介 *1　荒井 幸代 *2
Yusuke Nakata　Sachiyo Arai

*1千葉大学大学院 融合理工学府 都市環境システムコース
Urban Environment Systems, Graduate School of Science and Engineering, Chiba University

*2千葉大学大学院 工学研究科 都市環境システムコース
Urban Environment Systems, Graduate School of Engineering, Chiba University

Reinforcement Learning has numerous achievements, but it requires a careful specification of a reward function that represents the objective of a problem. There are problems whose objectives are difficult to represent as a function and are easier to give experts' demonstrations. For these problems, Inverse Reinforcement Learning is useful because it estimates a reward function from expert's demonstrations. Most of existing Inverse Reinforcement Learning methods assume that an expert gives demonstrations in a fixed environment, but an expert can provide demonstrations for a specific objective in multiple environments. For example, it is difficult to represent objective for car driving, and the driver can give demonstrations under multiple situations. In such cases, it is natural that we use demonstrations in multiple environments to estimate the rewards of the expert. We formulated and proposed an algorithm for this problem based on Bayesian Inverse Reinforcement Learning. Experimental results show that the proposed method quantitatively overperforms the existing method.

1. はじめに

ある環境におけるタスクに対する最適な方策を学習する方法の一つに強化学習がある．強化学習は一般に，タスクの目的を反映した報酬を与えることによって，環境のモデルに対する事前知識や，逐次的な教師信号なしに，タスクの解法を学習できる方法として注目されてきた．しかし，実問題においては，タスクの目的を適切に反映した報酬の設計が困難な場合がある．この報酬設計を回避する方法に逆強化学習がある．逆強化学習は，あるタスクの解法を知るエージェント（以下，エキスパート）が生成した軌跡などのデータから，「エキスパートの方策が最適となる報酬」を推定する方法である．そのため，推定報酬に対する最適方策を求めることによってエキスパートの方策を学習できる．

逆強化学習のもう一つの用途に，推定報酬の転移がある．推定報酬がエキスパートの報酬と等しい場合，その推定報酬を任意の状態遷移確率の環境に転移することによって，転移先の環境におけるエキスパートの方策を学習できる．報酬の転移が有用な問題としては，特定のゲームにおける複数のステージ間での転移 [Nichol 18]，シミュレータから実環境への転移 [Pinto 17] が挙げられる．また，実データを用いた例に，特定の駐車場における歩行者の軌跡から推定した報酬を用いて，異なる駐車場や歩道における歩行者の方策を学習した研究がある [Kitani 12]．しかし，エキスパートがある一つの環境で生成したデータが十分に得られていても，転移先のエキスパートの方策を学習できる報酬が推定される保証はない．これは，「エキスパートの方策が最適となる報酬」を推定する問題の解が複数存在し，逆強化学習の推定報酬がエキスパートの報酬と必ずしも一致しないからである．

本研究では，既存の逆強化学習手法では扱うことができないデータを用いることによって，よりエキスパートに近い報酬を推定する方法を提案する．具体的には，報酬の転移が要請される場合には，しばしば状態遷移確率の異なる複数の環境（例：ゲームの複数のステージ）におけるエキスパートのデータが取得できることに着目し，エキスパートが複数の環境で生成したデータから報酬を推定する．提案法の定式化は，代表的な逆強化学習手法の一つである Bayesian Inverse Reinforcement Learning（BIRL）[Ramachandran 07] に基づく．複数の環境におけるエキスパートの軌跡から報酬の事後分布を推定する逆強化学習問題を定式化し，報酬の事後分布からのサンプリングを実現するアルゴリズムを提案する．実験では，エキスパートの方策が最適となる報酬が複数存在することが明らかな問題を用いて，BIRL と提案法を比較する．逆強化学習手法の比較に用いられる指標である Expected Value Difference(EVD) [Levine 11] を用いて比較した結果，提案法の推定報酬が，既存手法の推定報酬と比較してエキスパートの報酬に近いことがが確認された．

連絡先: 中田 勇介，千葉大学大学院 融合理工学府 都市環境システムコース，13twnakata@chiba-u.jp

2. 準備

2.1 マルコフ決定過程（MDP）

本研究の対象とするマルコフ決定過程 $\mathcal{M} = (E, R)$ は，環境 $E = \langle\, \mathcal{S}, \mathcal{A}, T, \gamma \,\rangle$ と報酬 R からなる．ここで，$\mathcal{S}$ は状態集合，$\mathcal{A}$ は行動集合，$T(s'|s,a)$ は状態 $s \in \mathcal{S}$ で行動 $a \in \mathcal{A}$ を取ったとき次状態 $s' \in \mathcal{S}$ に遷移する確率である状態遷移確率，$\gamma \in [0,1)$ は割引率，$R : \mathcal{S} \to \mathbb{R}$ は状態 $s \in \mathcal{S}$ の報酬 r を返す報酬関数を表す．エージェントは，状態 s で行動 a を取る確率である方策 $\pi : \mathcal{S} \times \mathcal{A} \to [0,1]$ に基づいて行動を生成する．

報酬 R，方策 π の下での状態 s の状態価値，行動価値をそれぞれ

$$V^{\pi}(s,R) = \mathbb{E}_{\pi}\left[\sum_{t=0}^{\infty} \gamma^t R(s_t) | s_t = s\right] \tag{1}$$

$$Q^{\pi}(s,a,R) = \mathbb{E}_{\pi}\left[\sum_{t=0}^{\infty} \gamma^t R(s_t) | s_t = s, a_t = a\right] \tag{2}$$

と定義する．

報酬 R，最適方策 π^* の下で，状態 s の状態価値は

$$V^*(s,R) = R(s) + \gamma \sum_a \pi^*(a|s) \sum_{s'} T\left(s'|s,a\right) V^*\left(s',R\right) \tag{3}$$

を満たす．また，最適方策の行動価値 Q^* は，最適方策の下での状態価値 V^* を用いて

$$Q^*(s,a,R) = R(s) + \gamma \sum_{s'} T\left(s'|s,a\right) V^*\left(s',R\right) \tag{4}$$

と表される．

提案法のベースとなる BIRL は報酬の分布 $P(R)$ を扱う．そこで，$P(R)$ の下での最適方策を定義しておく．いま，報酬 $P(R)$ の下での方策 π の損失を

$$\mathbb{E}\left[L^p_{policy}(R,\pi)\right] = \mathbb{E}_{P(R)}\left[\left\|\boldsymbol{V}^*(R) - \boldsymbol{V}^\pi(R)\right\|_p\right] \tag{5}$$

と定義する．ここで，$\boldsymbol{V}^\pi(R)$ は報酬 R，方策 π の下での各状態の状態価値をベクトルとして並べ上げたもので，p は任意のノルムを指す．式 (5) を最小化する方策 π^* は，マルコフ決定過程 $\mathcal{M} = (E, \mathbb{E}[R])$ に対する最適方策である [Ramachandran 07]．

2.2 Bayesian Inverse Reinforcement Learning(BIRL)

BIRL は，ある報酬に従うエキスパートが生成した状態行動対 (s,a) のデータセット $D = \{(s_i,a_i)\}_{i=1}^N$ と，報酬に対する事前知識を反映した報酬の事前分布 $P(R)$ を所与として，報酬の事後分布 $P(R|D)$ を推定する [Ramachandran 07]．報酬の事後分布は，ベイズの定理を用いて，

$$P(R|D) = \frac{P(D|R)}{P(D)} P(R), \tag{6}$$

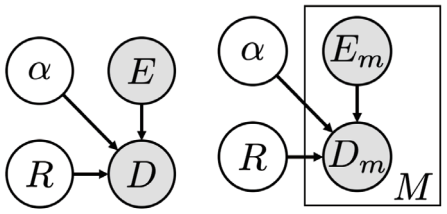
と表される．尤度 $P(D|R)$ は，報酬 R に対する最適方策の行動価値である $Q^*(s,a,R)$ 値を用いてモデル化される．尤度 $P(D|R)$ の定式化を式 (7) に示す．

$$P(D|R) = \frac{1}{Z} \exp\left(\alpha \sum_{(s,a)\in D} Q^*(s,a,R)\right) \tag{7}$$

ここで，Z は分配関数で，α はエキスパートが最適行動を取る確率を調節するパラメータである．パラメータ α は，ボルツマン方策における温度の逆数に相当する．報酬の事後分布 $P(R|D)$ は，式 (6), (7) を用いて，

$$P(R|D) = \frac{1}{Z'} \exp\left(\alpha \sum_{(s,a)\in D} Q^*(s,a,R)\right) P(R), \tag{8}$$

と表される．式 (8) の分配関数 Z' は計算困難だが，分子は報酬 R に対する最適方策の Q 値を求めることによって計算できる．また，$P(R|D) \propto \exp\left(\alpha \sum_{(s,a)\in D} Q^*(s,a,R)\right) P(R)$ が成り立つため，マルコフ連鎖モンテカルロ法（MCMC）を用いて事後分布 $P(R|D)$ から報酬をサンプルできる．BIRL では PolicyWalk を用いて事後分布 $P(R|D)$ から報酬をサンプルする．PolicyWalk とは，GridWalk [Vempala 05] を不要な強化学習を省くことによって効率化した MCMC アルゴリズムである．



(a) Graphical model for BIRL　(b) Graphical model for BIRL-MD

図 1: Graphical models for IRL Problems

3. Bayesian Inverse Reinforcement Learning for Multiple Dynamics (BIRL-MD)

ある報酬に従うエキスパートが，複数の環境で生成した軌跡からエキスパートの報酬の分布を推定する問題を定式化する．BIRL と対象問題のグラフィカルモデルを図 1 に示す．

BIRL は，エキスパートがある環境 E において生成したデータセット D を所与として，報酬の分布 $P(R|D) = P(R|D,E)$ を推定する問題である．一方，本研究が対象とする BIRL-MD は，状態遷移確率が異なる環境 $E_m = \langle \mathcal{S}, \mathcal{A}, T_m, \gamma \rangle$ と，エキスパートが各環境 E_m で生成したデータセット D_m の組からなる集合 $\{(E_m, D_m)\}_{m=1}^M$ を所与として，報酬の事後分布 $P(R|\{(D_m,E_m)\}_{m=1}^M)$ を推定する問題である．図 1 に示すように，報酬 R は環境 E と独立，つまりエキスパートの報酬は環境の状態遷移確率に依存しないものとする．

複数の環境におけるエキスパートのデータ $\{(E_m, D_m)\}_{m=1}^M$ が得られた時の報酬の事後分布 $P(R|\{(D_m,E_m)\}_{m=1}^M)$ を式 (9) に示す．

$$P(R|\{(D_m,E_m)\}_{m=1}^M) = \frac{\Pi_{m=1}^M P(D_m|R,E_m)}{\Pi_{m=1}^M P(D_m|E_m)} P(R), \tag{9}$$

式 (7) に示した BIRL のエキスパートのモデルを，環境 E，報酬 R の下での最適方策の行動価値 $Q^*(s,a,R,E)$ へと拡張すれば，報酬の事後分布は

$$P(R|\{(D_m,E_m)\}_{m=1}^M) = \frac{1}{Z'} \exp\left(\alpha \sum_{m=1}^M \sum_{(s,a)\in D_m} Q^*(s,a,R,E_m)\right) P(R), \tag{10}$$

と表される．

4. アプローチ

提案法は，環境 $E_m = \langle \mathcal{S}, \mathcal{A}, T_m, \gamma \rangle$ と，エキスパートが各環境において生成したデータセット D_m の組からなる集合 $\{(E_m, D_m)\}_{m=1}^M$ を所与として，報酬の事後分布 $P(R|\{(D_m,E_m)\}_{m=1}^M)$ からのサンプリングを実現する．

式 (10) の分子は，各環境 E における報酬 R に対する最適方策の行動価値 $Q^*(s,a,R,E)$ を計算することで求まる．そのため，BIRL-MD においても BIRL と同様に，MCMC を用いて事後分布 $P(R|\{(D_m,E_m)\}_{m=1}^M)$ から報酬をサンプルできる．提案法の MCMC アルゴリズム，PolicyWalk for Multiple Dynamics (PolicyWalk-MD) を Algorithm 1 に示す．

Algorithm 1 PolicyWalk for Multiple Dynamics

INPUT: Environments $\{E_m\}_{m=1}^M$, Demonstrations $\{D_m\}_{m=1}^M$, Prior $P(R)$, Step Size δ
OUTPUT: Sampled Rewards $\{R_i\}_{i=1}^N$

Pick a random vector $R_0 \in \mathbb{R}^{|S|}/\delta$
$\{\pi_m\}_{m=1}^M \leftarrow \{\text{PolicyIteration}(E_m, R_0)\}_{m=1}^M$
for $i = 1$ **do** N
  Pick a reward vector $\tilde{R}$ uniformly at random from the neighbours of $R_{i-1} \in \mathbb{R}^{|S|}/\delta$
  Compute $Q^\pi(s,a,\tilde{R},E) \quad \forall\{s,a,(E_m,\pi_m)\} \in \mathcal{S}\times\mathcal{A}\times\{(E_m,\pi_m)\}_{m=1}^M$
  if $\exists\{s,a,(E,\pi)\} \in \mathcal{S}\times\mathcal{A}\times\{(E_m,\pi_m)\}_{m=1}^M, Q^\pi(s,\pi(s),\tilde{R},E) < Q^\pi(s,a,\tilde{R},E)$ **then** ▷ If any policy is not optimal
    $\{\tilde{\pi}_m\}_{m=1}^M \leftarrow \left\{\text{PolicyIteration}(E_m,\tilde{R})\right\}_{m=1}^M$
    $R_i \leftarrow \tilde{R}$ and $\{\pi_m\}_{m=1}^M \leftarrow \{\tilde{\pi}_m\}_{m=1}^M$ with probability $\min\left\{1, \frac{P\left(\tilde{R},\{(D_m,E_m)\}_{m=1}^M\right)}{P\left(R_{i-1},\{(D_m,E_m)\}_{m=1}^M\right)}\right\}$
  else
    $R_i \leftarrow \tilde{R}$ with probability $\min\left\{1, \frac{P\left(\tilde{R},\{(D_m,E_m)\}_{m=1}^M\right)}{P\left(R_{i-1},\{(D_m,E_m)\}_{m=1}^M\right)}\right\}$

BIRL の MCMC アルゴリズムである PolicyWalk は，$P(R|D,E)$ から誤差 ϵ 以下のサンプリングを $O(|\mathcal{S}|^2 \log \frac{1}{\epsilon})$ のステップ数で実現する [Ramachandran 07]．PolicyWalk-MD のサンプリングの計算量に関して次の定理が成り立ち，提案法は PolicyWalk と同じオーダーで事後分布からのサンプリングを実現する．

補題 1. F を，定義域が $\{x \in \mathbb{R}^n | -d \le x_i \le d\}$ の正の実数関数とする．ここで，d は任意の正の実数である．任意の $\lambda \in [0,1]$ の下で，ある α_f, β_f が存在し，以下の二つの式

$$|f(x) - f(y)| \le \alpha_f \|x - y\|_\infty \quad (11)$$
$$f(\lambda x + (1-\lambda)y) \ge \lambda f(x) + (1-\lambda) f(y) - \beta_f \quad (12)$$

が成り立つとする．ここで，$f(\cdot) = \log F(\cdot)$ である．この時，関数 F に対する GridWalk，PolicyWalk，（そのため，PolicyWalk-MD）は誤差 ϵ 以下のサンプリングを，$O(n^2 d^2 \alpha_f^2 e^{2\beta_f} \log \frac{1}{\epsilon})$ ステップで実現する [Ramachandran 07].

定理 1. 環境 $E = \langle \mathcal{S}, \mathcal{A}, T, \gamma \rangle$，事前分布 $P(R)$ が一様分布 $\mathcal{U}(-R_{\max}, R_{\max})$ で，事後分布 $P(R|\{(D_m,E_m)\}_{m=1}^M)$ が式 (10) に示す式で表されるとする．$R_{\max} = O(\frac{1}{M|D|})$ と仮定すると，PolicyWalk-MD は $P(R|\{(D_m,E_m)\}_{m=1}^M)$ からの誤差 ϵ 以下のサンプリングを，$O(|\mathcal{S}|^2 \log \frac{1}{\epsilon})$ のステップ数で実現する．

Proof.

$$f(R) = \alpha \sum_{m=1}^M \sum_{(s,a)\in D_m} Q^*(s,a,R,E_m) \quad (13)$$

$$f_\pi(R) = \alpha \sum_{m=1}^M \sum_{(s,a)\in D_m} Q^\pi(s,a,R,E_m) \quad (14)$$

ここで，f_π はベクトル化した R について線形で，$f(R) \ge f_\pi(R)$ が成り立つ．また，Q 値について，

$$\max_{s,a} Q^*(s,a) \le \sum_{t=0}^\infty \gamma^t R_{\max} = \frac{R_{\max}}{1-\gamma} \quad (15)$$

が成り立ち，式 (15) と同様に $\min_{s,a} Q^*(s,a) \ge -\frac{R_{\max}}{1-\gamma}$ も言える．式 (15) を用いれば f と f_π の間に

$$f_\pi(R) \ge f(R) - \frac{2\alpha M|D|R_{\max}}{1-\gamma} \quad (16)$$

という関係が成り立つので，

$$f(\lambda R_2 + (1-\lambda)R_2) \ge f_\pi(\lambda R_2 + (1-\lambda)R_2) \quad (17)$$
$$= \lambda f_\pi(R_2) + (1-\lambda) f_\pi(R_2) \quad (18)$$
$$\ge \lambda f(R_2) + (1-\lambda) f(R_2) - \frac{2\alpha M|D|R_{\max}}{1-\gamma} \quad (19)$$

となる．そのため，補題の変数はそれぞれ，

$$\alpha_f = \frac{|f(R_1)-f(R_2)|}{\|R_1-R_2\|_\infty} \le \frac{2\alpha M|D|R_{\max}}{(1-\gamma)O\left(\frac{1}{M|D|}\right)} = O(M|D|) \quad (20)$$

$$\beta_f = \frac{2\alpha M|D|R_{\max}}{1-\gamma} = 2M|D|\frac{O\left(\frac{1}{M|D|}\right)}{1-\gamma} = O(1) \quad (21)$$

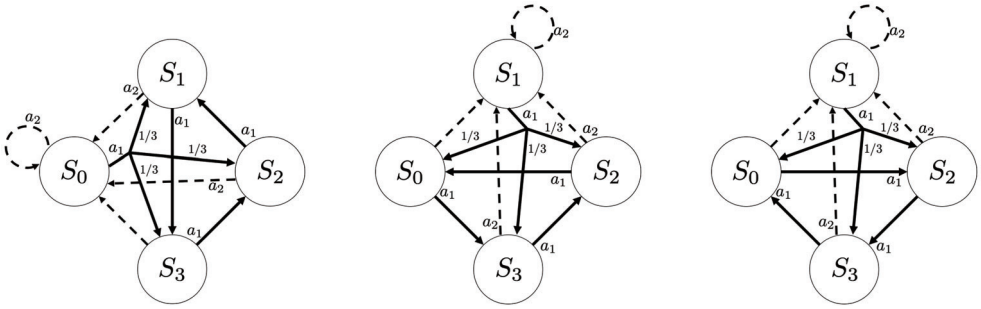
である．よって PolicyWalk-MD は $P\left(R|\{(D_m,E_m)\}_{m=1}^M\right)$ からの誤差 ϵ 以下のサンプリングを，$O(|\mathcal{S}|^2 \frac{1}{(M|D|)^2}(M|D|)^2 \log \frac{1}{\epsilon}) = O\left(|\mathcal{S}|^2 \log \frac{1}{\epsilon}\right)$ のステップ数で実現する． □

5. 実験

5.1 実験設定

本実験では，提案法，BIRL の推定報酬と，エキスパートの報酬の類似度を Expected Value Difference（EVD）[Levine 11] を用いて評価する．EVD は，推定報酬に対する最適方策とエキスパートの方策の近さを表す指標で，EVD の値が小さいほど推定報酬もエキスパートの報酬と類似している．推定報酬の EVD は，エキスパート方策で得られるエキスパートの報酬の期待値から，推定報酬に対する最適方策で得られるエキスパートの報酬の期待値を引くことで求まる．

図 2 に，報酬の推定に用いる三つの環境を示す．ここで，エキスパートの報酬を $R(s_0) = R(s_1) = 0, R(s_2) = R(s_3) = 0.7$ とした．これらの環境は，エキスパートが最適となる報酬の分布の不確実性が大きい環境である．なぜなら，各環境におけるエキスパートの方策（最適方策）は，全状態のうち三つの状態を巡回する方策であり，エキスパートによって巡回されるいずれか，または複数の状態の報酬が大きい場合にエキスパートが最適となるからである．例えば，環境 A では，s_1, s_3, s_2 という順番で状態を巡回する方策がエキスパートの方策で，s_1, s_3, s_2 のいずれか，または複数の状態の報酬が大きい場合に，エキスパートの方策が最適となる．EVD の評価には，状態遷移確率



(a) Environment A (b) Environment B (c) Environment C

図 2: Simple environments for the experiment. The bold lines represent a expert's optimal action a_1, and the broken lines represent some other action a_2. Numbers beside the lines is the probability of the stochastic transition.

を無作為に定めた 100 個の環境を用いる．EVD の評価に用いる環境の状態数，行動数は報酬の推定に用いた環境と同じである．

報酬の推定に用いるエキスパートの軌跡について説明する．エキスパートの方策から，各環境で 10 ステップの軌跡を 30 個生成する．エキスパートの方策は，$\gamma = 0.95$ の最適方策の行動価値を用いた温度 $\kappa = 1/3$ のボルツマン方策とした．

BIRL と提案法で報酬を推定する際には，式 (7), (10) のパラメータ α と事前分布 $P(R)$ を定める必要がある．ここでは，パラメータ α をエキスパートのボルツマン方策の温度に基づいて $\alpha = 1/\kappa = 3$ とし，事前分布 $P(R)$ は，一様分布 $\mathcal{U}(-1, 1)$ とした．また，MCMC のステップ数を 2000，バーンインを 200，ステップサイズ δ を 0.01 とし，サンプルした報酬の平均値を推定報酬として用いた．

5.2 実験結果

既存手法，提案法の推定報酬の EVD の平均値と標準偏差，最大値を表 1 に示す．

Method	BIRL	BIRL-MD(Ours)	
Number of Environments	1	2	3
EVD(Mean)	1.15 ± 0.89	0.17 ± 0.24	0.02 ± 0.06
EVD(Max)	3.93	1.18	0.36

表 1: Evaluation of BIRL and BIRL-MD. BIRL uses only one environment for rewards estimation, and BIRL-MD uses multiple environments.

表 1 の一行目は，報酬の推定に用いた手法を，二行目は，報酬の推定に用いた環境の数を示す．三行目は，EVD の平均値と標準偏差，四行目は EVD の最大値を示す．推定報酬の EVD の平均値，標準偏差，最大値は，図 2 の環境の組み合わせから推定した報酬の評価値である．例えば，表 1 の二列目に示す BIRL の EVD の平均値は，図 2 の環境 A，B，C で推定した三つの報酬の EVD の平均値で，三列目に示す二つの環境におけるエキスパートの軌跡から報酬を推定した結果は，環境 A と B，A と C，B と C，から推定した三つの報酬の EVD の平均値である．

報酬の推定に用いる環境の数の増加に伴い，EVD の平均値，標準偏差，最大値が減少している．EVD が小さいほど推定報酬がエキスパートの報酬に近いことから，ある報酬に従うエキスパートが複数の環境で生成した軌跡を用いて報酬を推定する提案法が有用であると言える．

6. まとめと今後の課題

本研究では，あるタスクの解法を知るエキスパートが，状態遷移確率が異なる複数の環境で生成した軌跡データを所与として，報酬の分布を推定する問題を，ベイジアン逆強化学習問題として定式化した．そして，マルコフ連鎖モンテカルロ法を用いた解法を提案した．実験では，逆強化学習手法の比較に用いられる指標である Expected Value Difference [Levine 11] で提案法と既存手法を比較した．その結果，提案法の推定報酬が，既存手法の推定報酬と比較してエキスパートの報酬に近いことがが確認された．提案法の適用範囲は，その計算量から離散状態行動空間の環境に限られる．今後の課題として，連続状態行動空間の複数の環境から報酬を推定する逆強化学習手法の構築を挙げる．

参考文献

[Kitani 12] Kitani, K. M., Ziebart, B. D., Bagnell, J. A., and Hebert, M.: Activity forecasting, in *European Conference on Computer Vision*, pp. 201–214Springer (2012)

[Levine 11] Levine, S., Popovic, Z., and Koltun, V.: Nonlinear inverse reinforcement learning with gaussian processes, in *Advances in Neural Information Processing Systems*, pp. 19–27 (2011)

[Nichol 18] Nichol, A., Pfau, V., Hesse, C., Klimov, O., and Schulman, J.: Gotta Learn Fast: A New Benchmark for Generalization in RL, *arXiv preprint arXiv:1804.03720* (2018)

[Pinto 17] Pinto, L., Davidson, J., Sukthankar, R., and Gupta, A.: Robust adversarial reinforcement learning, *arXiv preprint arXiv:1703.02702* (2017)

[Ramachandran 07] Ramachandran, D. and Amir, E.: Bayesian inverse reinforcement learning, *IJCAI International Joint Conference on Artificial Intelligence*, pp. 2586–2591 (2007)

[Vempala 05] Vempala, S.: Geometric random walks: a survey, *Combinatorial and computational geometry*, Vol. 52, No. 573-612, p. 2 (2005)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

変分ニューラルネットワークによる推薦システムの構築

Constructing a Recommender System using Variational Neural Networks

大槻 知貴 † 菅谷 信介 † 大西 佑紀 ‡†
Tomoki OHTSUKI Shinsuke SUGAYA Yuki OHNISHI

† 株式会社ビズリーチ ‡ Purdue University
BizReach Inc.

To build a recommender system, it is essential to infer the underlying latent features of users and items from the action logs (i.e., collaborative filtering), simultaneously taking their known attributes into consideration. For this purpose, numerous models have been proposed to naturally interpolate between these two extremes, especially in the context of extending the matrix factorization algorithm. In this work, based on the recent advances in deep learning technology and high-level probabilistic programming software, we propose a model which is extremely simple and easy to implement, yet flexible and robust against over-fitting. We also deploy the proposed model for a real service by combining its prediction with a combinatorial optimization program, and see a significant improvement in certain indicators.

1. はじめに

Web サービスにおける推薦システムの重要性は増すばかりである. 中でも, ビッグデータの時代においては, 手で定義されたスコアリングによることなく, 統計的な手法でもって自動でアイテムをユーザーに推薦することが, 効率化と公平性の観点から求められている [Agarwal 16]. この様な推薦システムの構築においては, ユーザーの行動履歴に基づいて個別化を行う協調フィルタリング的なアプローチと, ユーザー/アイテムの持つ属性による回帰あるいは分類予測という, 二つの極端なアプローチが考えられるが, これらには相補的に長所と短所がある. 行動履歴ベースの方法は, 十分多くの活動を行なっているユーザーや, 露出が多いアイテムについては高い精度での予測が可能な一方, 行動履歴のないユーザー (あるいは露出のないアイテム) に対しては適切な推薦が行えなくなってしまう (コールドスタート問題). また, ユーザーとアイテムの属性特徴量ベースの方法は, 行動履歴の多少には影響されないものの, ユーザーの振る舞いの全てが, 利用可能な特徴量に反映されているとは限らず, データが豊富なユーザーやアイテムに対しての精度は (相対的に) 悪化しがちである. そのため, これらの両極端の間を自然に補間するようなアプローチが求められており, 実際に [Agarwal 09] など, 行列分解の文脈にそった手法が多く提案されてきた.

本論文では, 株式会社ビズリーチ [*1] における, この様な問題の実例と, それに対する取り組みの一端について紹介する. 中でも, 近年発展が著しい深層学習技術と, [Kucukelbir 17] で提唱された自動微分変分推論 (automatic differentiation variational inference, ADVI) を併用することで, シンプルかつ実装も著しく容易でありながら, 高い性能を発揮する (行列分解型とは異なる) モデルを提案し, その実サービスにおける効果について議論する.

本論文の構成は以下の通りである.

2 節では, 本論文で対象とする推薦システムの概要と目的, 及びデータセットについて概説する. 3 節では, 本研究で提唱するモデルについて議論を行う.4 節では, 交差検証による提案モデルの評価と, モデルの予測値を組み合わせ最適化の手法と併用することで, 実サービスに応用した結果について議論する.

連絡先: tomoki.otsuki@bizreach.co.jp

∗1 https://bizreach.biz

2. サービスの目的とデータの概要

本実験で予測対象とするのは, 株式会社ビズリーチが運営する, 大学生と採用企業向けのマッチングサービス「ニクリーチ」[*2] で得られたデータの一部である. 本サービスの一つの機能として, 登録されているユーザー (大学生) は, システムによって配信される推薦企業リストの中から, 興味がある企業に対してアピールを送信することができる. そこで, 企業側から返信があれば両者が (主に牛肉を中心とした会食を伴う) 面談に進むことができる. より多くのハンドシェイク (マッチング) の機会をユーザーとクライアントである企業に提供するためには, まずはその確率を予測することが欠かせない. そのため, この機能が作られた初期段階より, データの蓄積と, データ分析に基づく推薦システムの運用が行われてきた (初期から 3. 節でのモデル導入まで用いられてきたロジックについては 4. 節にて触れる).

ハンドシェイク確率の予測に用いるデータは, 主に表 2. のような分量と内訳である:

内容	サイズ	列の属性値
ユーザー	$\sim 5 \times 10^4$	ID, 登録日, 英語レベル (3 段階), 文系/理系, 希望職種
企業	$\sim 10^2$	ID, 登録日, 従業員規模
ハンドシェイク	$\sim 2 \times 10^5$	ユーザー ID, 企業 ID, ハンドシェイクの成否, アクション日

表 1: ニクリーチにおけるハンドシェイクデータの概要

この様に, 企業については登録日の他には従業員数が知られているのみであり, 企業ごとの個別因子を抜きにした予測は難

∗2 https://29reach.com

しいのが現状である. また, ハンドシェイクの確率はデータ取得期間全体で 3 割弱と低めになっており, 予測器の性能は精度 (accuracy), 対数尤度の他にも, F1 値や ROC-AUC で測る必要がある.

3. 提案手法

以下では本論文で提案する手法 (以降, 変分ニューラルネットワークと呼称する) について述べる. 考えるデータセット D は, ユーザーとアイテムの識別子, それらのマッチングの結果 (2 値分類値やレーティング), アイテム/ユーザーの属性値, そしてそのマッチングに特有の情報 (e.g., マッチングが (不) 成立した日時) を含んでいるとする.

まずは, ベイズ的な協調フィルタリングの例に漏れず, 各ユーザー/アイテムに対して何らかの潜在因子が存在し, それらはある分布からのサンプルになっていると仮定する. ここではさらに, その他のカテゴリ属性値に対しても, それぞれ何らかの特徴量が存在するとして事前分布からサンプリングを行う. すなわち, D の全ての列 $c \in [$ `user_id`, `item_id`, $\cdots$ (other attributes) $\cdots]$ に対して,

$$\vec{v}_{c,j} \sim \mathcal{N}(\vec{\mu}_c, \vec{\sigma}_c) \quad (j = 1, \cdots, N_c) \tag{1}$$

とする. ここで $\vec{\mu}_c, \vec{\sigma}_c$ は正規事前分布の中心と分散を表すパラメータ (実験では, これらも事前分布からサンプリングしたものとする), N_c は列 c が取りうる値の数である. この意味でユーザーやアイテムの識別子は, その他の特徴量と対等であり, 単に (時として非常にクラス数が多くなる) カテゴリ変数とみなせる.

こうして得られた特徴量を結合し, 多層パーセプトロンにより適切な形へ変換したものを予測値とする. すなわち, D の各行 r において,

$$x_0 := \mathrm{Concat}([v_{c,r_c}]_{c \in \mathrm{columns}})$$

から, ウェイト $W_0, \cdots, W_L$ とバイアス $b_0, \cdots, b_L$ パラメータでもって,

$$x_{i+1} = \mathrm{activate}_i(W_i x + b_i)$$

によって変換されたものを予測値とする (L は隠れ層の数, $\mathrm{activate}_i$ は i 層目での活性化関数である). 本論文では, ウェイトやバイアス自体も事前分布からサンプリングされていると仮定する. ここではベイズ的な立場を取っているので, このデータ点の観測値 y は x_L を中心とした正規分布 $\mathcal{N}(x_L, \sigma)$ や二項分布 $\mathrm{Bernoulli}(\sigma(x_L))$ に従うとして, 確率モデルが完成する.

この様なモデルは途中に非線形な活性化関数 $\mathrm{activate}_i$ を含むため, 厳密な事後分布の導出は不可能であり, 推論のためにはマルコフ連鎖モンテカルロ法や, 変分推論に訴えることになる. とりわけ, データ D のサイズが大きい場合は, 計算時間の観点から変分推論に訴えざるをえないが, 中でも, 本論文では [Kucukelbir 17] によって提案された, (ガウス型) 自動微分変分推論による方法を用いる. この近似法においては, 事後分布の近似形は一般の平均場近似よりさらく強く, 正規分布に制限する必要があるが, 近年発展が著しい自動微分ソフトウェア (や GPU などのデバイス) をフルに活用することができるため, 一般に高速である.

この様に, 本モデルは行列分解のような協調フィルタリングと, 一般的な回帰や分類問題の中間的なアプローチであり, それぞれに対して

- スコア値が内積で与えられる一般的な行列分解よりも, より複雑なユーザー/アイテム/属性値の相性を表現できる可能性がある.
- ベイズ的なアプローチをとることで, 回帰問題とすると膨大になってしまうパラメータに対してのか学習を防ぐことができる. また, 未知データに対しては事前分布からのサンプルをその特徴ベクトルとする, という明確な指針がある.

というアドバンテージがある. また, 運用面でも, 実装のシンプルさや, パラメータ調整にかける労力の少なさ, というメリットがある.

他方で, 推論の方法が実質 ADVI に限られ, 事後分布の関数系に対して強い制限を設ける必要があるのはデメリットではあるものの, 特にマッチングの文脈においては, 異なるアイテムやユーザーの特徴は独立と考えられるため, 他の応用と比べると影響は少ないと考えられる (但し, 同一のベクトルの異なった成分の間の相関も無視されてしまう, という問題は残る). また, 運用面でのデメリットとしては, 一つの予測を行うのにも, 精度を追求するためには多数のサンプルを発生させる必要があるため, 計算コストが大きいことが挙げられる.

4. 実験

本節では, 2. 節で述べたデータに対して, 3. 節のモデルを適用し, ベースラインとなるモデル (2018 年 12 月 19 日まで用いられていたモデル) との性能比較と, 実運用での効果について議論する.

4.1 ベースラインとなるモデル

結果の比較のため, まずはベースラインとなるモデルとその特徴量エンジニアリングについて述べる.

これらのモデルでは, 潜在因子を推論する代わりに, 手で行動履歴 (訓練データにおけるハンドシェイク履歴) から以下の統計量を算出し, 特徴量を補っている:

- 各企業への応募件数
- ユーザーと等しい英語力, 希望職種を持つ人材は, 対象企業とマッチングしたユーザー全体の何割を占めるか
- 各ユーザーが受け取ったスカウト数
- ユーザーの登録日からアクションまでの時刻

これらによってユーザーと企業の特徴量を補った後は, L1 正則化ロジスティック回帰や, LightGBM[Ke 17] などの一般的に用いられる分類モデルを用い, ハンドシェイク確率を予測することができる.

4.2 変分ニューラルネットワークの詳細設定

3. 節の変分ニューラルネットワークについては, 以下の要領で数値列のカテゴリ化を行った (準連続な数値型に対しての扱いは容易であるが, 実装を簡潔にするため)

- ユーザーが登録してから各々の面談リクエストに至るまでの日数は, 頻度ベースのパーセンタイルで 20 カテゴリに変換する
- 従業員数はパーセンタイルで 5 カテゴリに分割する

以下でモデルのパラメータについて述べる. ユーザー ID, 企業 ID を含む合計 8 個の各属性値には, 全て事前分布から (1) 式のようにサンプルされた, 5 次元のベクトルが対応するとした. 事前分布のパラメータとなる $\vec{\mu}_c, \vec{\sigma}_c$ については, それぞれ独立に分散 10^2 で中心が 0 の正規分布, スケールファクター 10 の片側コーシー分からサンプルされるとした. また, 多層パーセプトロン部分については隠れ層の次元を一層目で 16, 二層目で 8 とした (このチョイスや層数は結果に大きな影響を与えないことは確認済みである). 隠れ層での活性化関数はいずれもシグモイド関数とした.

ADVI の実行には, PyMC3 [Salvatier 16] の機能を用いた. 学習の際には, サイズ=2048 のミニバッチ化を用い, 確率的勾配降下法 (学習率などは PyMC3 の既定値を用いる) を用いて変分下界 (evidence lower bound, ELBO) を最大化する. いずれの場合も ELBO の値は速やかに収束した.

この枠組みで各データ点に対して得られるのは, 単一の予測値ではなく, 事後分布からのサンプルされた値であるため, 予測値としては, それらの数値的な平均値を用いた. 尚, モデルの非線形性のため, 各特徴量のサンプル平均にニューラルネットワークを適用した結果と, 各サンプルにニューラルネットワークを適用してから平均をとった結果は異なる. 後者の方が本来あるべき近似であるため, 計算量は増えるものの, こちらを予測値とする (後者の方が性能が高い傾向も確認済みである). 本論文では, サンプル数=100 を一貫して用いる.

4.3 Train-test split によるスコア比較

上述の設定のもと, 本節では, 2. 節のデータセットを学習データとテストデータに分割し, テストデータに対するモデルの性能を比較することとする. 学習-テストの分割は, 未知のケース (新規ユーザーと新規企業) に対応する能力を測るため, 日付ベースで昇順に 90%を学習データセット, 残りの (直近)10%をテストセットに分配した.

以下にテストデータに対するモデルの性能を対数尤度, ROC-AUC 値, F1 値について測定したものを示す.

Model	Log Loss	ROC-AUC	F1-score
Base-L1	0.536	0.561	N/A
Base-LGBM	0.510	0.625	0.153
Base-L1-balanced	0.652	0.560	0.335
VNN-Full	**0.502**	**0.707**	**0.385**
VNN-User	0.558	0.608	0.239
VNN-Company	0.534	0.652	0.345

表 2: 直近 10%テストデータに対する各モデルの性能

上記の表で, Base-L1 は, 4.1 の様に追加した特徴量のもとで L1 正則化 *3 ロジスティック回帰を適用したもの, 同様に Base-LGBM は LigthGBM を適用したもの *4 である. 尚, 正例が 3 割程度であるため, 線形モデルはテストデータに対しては閾値である 0.5 を超える確率を出力することはなく, そのため F1 値は測定不能である. この回避のため, ロス関数に重みを付与して正負のバランスをとったのが Base-L1-balanced の結果であり, これが 2018 年 12 月 20 日まで用いられてきたロジックに相当する.

*3 L2 正則化を用いても結果はほとんど同様であった

*4 学習データをさらに 8:2 に分割し, 2 割を検証セットとした. 尚, ハイパーパラメータに関しては, 弱学習器の数, 木の葉の数, 及び学習率について, テストデータに対するスコアに対してランダムサーチを行っており, この点で他より若干有利となっている

VNN-Full はユーザー ID, 企業 ID を含む全ての特徴量を用いて学習させた変分ニューラルネットワークの結果であり, VNN-User と VNN-Company はそれぞれユーザー ID と企業 ID のみに対して個別の因子を割り当てたモデルである.

全体を通じて, 全ての特徴量を用いた VNN-Full モデルが考えている全てのスコアで他を上回っていることが見て取れる. また, VNN-User, VNN-Company 共に性能が低下していることから, ユーザー, 企業どちらの因子も個別化によって取り込む必要性が見て取れる.

4.4 組み合わせ最適化による運用の結果

ここでは, 実際に上のモデルをニクリーチのサービスに適用した結果について議論する. ニクリーチのようなマッチングサービスでは, 一部の企業や一部のユーザーに対してスカウトや面談リクエストが集中することを防ぐ必要がある. そのため, 制約を考えながらマッチングの期待値を最大化するため, 以下のような整数計画問題を解くことで配信対象を決定する.

maximize

$$\sum_{(i,j)\in P} p(i,j)x_{i,j}$$

subject to

$$x_{i,j} \in \{0,1\} \text{ for each } (i,j) \in D$$

$$\sum_j x_{i,j} = N \quad \text{for each } i$$

$$L \leq \sum_i x_{i,j} \leq U \quad \text{for each } j$$

ここで, i はアクティブなユーザー, j は企業を走るインデックスであり, $p(i,j)$ が前節のモデルで計算させるユーザー i と企業 j のハンドシェイクする確率値である. また, D はユーザー, 企業の考えられる組み合わせから, 既にアクションがあった組み合わせは除く, などの処理を行った集合である. N, U, L は定数で, N は一回にユーザーに推薦される企業数を表し, L, U は特定の企業に露出が集中しすぎないよう, 最小値と最大値を制限する. このタイプの問題は典型的な二部グラフからなる組み合わせ最適化問題であり, 元の問題は二値変数の整数計画問題であるが, $[0,1]$ の範囲の実数値をとる線形計画問題に緩和すれば, かならず最適解 (の一つ) は整数解となる. こうして緩和した問題は, CBC プロジェクト [Forrest 05] の線形計画法ソルバーである, CLP を用いて単体法で求解する.



図 1: ニクリーチ推薦機能による, ハンドシェイク/アプローチ比の推移. 新モデルの導入と同時に, 顕著な増大が見て取れる.

図 1 に, 2018 年 9 月 1 日より, 2019 年 1 月 20 日までの期間における, ハンドシェイク数/アプローチ数 (推薦結果を受けてユーザーが企業にアプローチした数) の比率の推移を示す.

図にあるオレンジの縦線は変分ニューラルネットによる新ロジックの導入日である 2018 年 12 月 20 日を表しており, この日を境にして急激にハンドシェイク率が上がっていることが分かる (緑と赤の横線は, それぞれ 2018 年 12 月 19 日までのハンドシェイク率の平均値と 20 日以降の平均値を表している). また, 当然ながら, 数理計画問題のパラメータである N, L, U の値は不変である. 尚, 本論文では割愛するが, 2017 年 12 月-2018 年 1 月期のデータには, 特にこの様なハンドシェイク率の著しい改善は見られておらず, 季節変動の可能性については低いと判断できる.

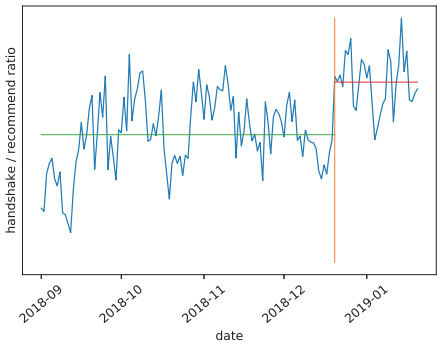


図 2: ハンドシェイク/レコメンド数の推移. こちらも新モデルの導入と同時に増大が見て取れる.

また, 図 2 には, 図 1 と同期間における, ハンドシェイク数/レコメンド数の比率の推移を示す. この指標については, 「ユーザーが推薦された企業に対して興味を持つか」という要因が絡むため, アプローチ → ハンドシェイクという確率値を予測するモデルとは本来ターゲットが異なるものの, 若干の増大が見て取れる.

5. 結論

本論文では, 実サービスのデータを用いて, 変分推論などベイズ的なアプローチの有効性を論じた. 特に, ADVI や深層学習技術の進展を取り込むことで, 特徴量エンジニアリングを行うことなく, ユーザーやアイテム (企業) に対する個別化をシンプルな実装で実現できることを示した.

謝辞

本プロジェクトの遂行にあたり, ご支援頂いた株式会社ビズリーチの皆さま, 特に, ロジックのデプロイを大いに助けて頂いた AI 室の渡會恭平氏, 効果測定でお力添えを頂いたニクリーチの木下真氏へ御礼申し上げます.

参考文献

[Agarwal 09] Agarwal, D. and Chen, B.-C.: Regression-based latent factor models, in *Proceedings of the 15th ACM SIGKDD international conference on Knowledge discovery and data mining*, pp. 19–28ACM (2009)

[Agarwal 16] Agarwal, D. K. and Chen, B.-C.: *Statistical methods for recommender systems*, Cambridge University Press (2016)

[Forrest 05] Forrest, J. and Lougee-Heimer, R.: CBC user guide, in *Emerging theory, methods, and applications*, pp. 257–277, INFORMS (2005)

[Ke 17] Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., and Liu, T.-Y.: Lightgbm: A highly efficient gradient boosting decision tree, in *Advances in Neural Information Processing Systems*, pp. 3146–3154 (2017)

[Kucukelbir 17] Kucukelbir, A., Tran, D., Ranganath, R., Gelman, A., and Blei, D. M.: Automatic differentiation variational inference, *The Journal of Machine Learning Research*, Vol. 18, No. 1, pp. 430–474 (2017)

[Salvatier 16] Salvatier, J., Wiecki, T. V., and Fonnesbeck, C.: Probabilistic programming in Python using PyMC3, *PeerJ Computer Science*, Vol. 2, p. e55 (2016)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

メタ学習としてのGenerative Query Network

A Meta-Learning Perspective on Generative Query Network

谷口 尚平 *1　岩澤 有祐 *1　松尾 豊 *1
Shohei Taniguchi　Yusuke Iwasawa　Yutaka Matsuo

*1東京大学
The University of Tokyo

Generative Query Network (GQN) is a novel deep generative model for three-dimentional modelling, making it possible to render images from unknown viewpoints. However, properly training GQN requires huge learning costs (including both computational time and hardware), and it is severally sensitive to hyper-parameters. Moreover, the lack of studies on GQN from a probabilistic view makes it difficult to interpret the neural network architecture. In this paper, we formulate the probabilistic model of GQN using meta-learning framework, and based on the formulation, we propose a new method that significantly reduces learning costs, and improves the accuracy of generated images, learning efficiency and robustness against hyper-parameters. We show the effectiveness through experiments using the Shepard Metzler dataset.

1. 研究の背景と目的

Generative Query Network (GQN) [Eslami 18] は，画像と視点座標という 2 つのセンサー情報のみから環境に関する抽象表現 (シーン表現) を獲得し，未知の視点座標からの観測画像を予測する深層生成モデルであり，Structure from Motion (SfM) などの従来の 3 次元モデリング手法に代わる新しい手法として注目を集めた．しかし，GQN は学習にかかる時間的・計算リソース的なコストが大きく，また結果がハイパーパラメータに強く依存するため学習が安定しないという課題がある．また，確率モデルとしての検証が不十分であるために，モデルアーキテクチャの解釈性が低く，発展研究の妨げとなっている．本研究では，これらの課題を解決するため，GQN の確率モデルをメタ学習のフレームワークを用いて定式化し，それに基づいて，学習のコストと不安定性を改善する手法の提案を行う．評価実験では Shepard Metzler データセットを用いてその有効性を検証する．

2. 前提知識

2.1 Generative Query Network

Generative Query Network(GQN) [Eslami 18] は，深層生成モデルの 1 種で，3 次元空間上のある視点からの観測画像がいくつか与えられた状況において，別の視点からの観測画像を予測して生成するモデルである．学習においては，多数あるシーンの中から 1 つをランダムに選び，その中からモデルに事前に与えるコンテキストと予測させるクエリを選択する．モデルは，コンテキストとクエリの視点座標を入力され，クエリに対応する観測画像を予測して生成する．

GQN は，大きく分けて 2 つのニューラルネットワークで構成される．1 つはコンテキストからシーン表現 $\boldsymbol{r}$ を抽出する**表現ネットワーク** (**representation network**)，もう 1 つはシーン表現 $\boldsymbol{r}$ とクエリ視点 $\boldsymbol{v^q}$ からクエリ画像 $\boldsymbol{x^q}$ を出力する**生成ネットワーク** (**generation network**) である．生成ネットワークは，さらに $\boldsymbol{r}$ と $\boldsymbol{v^q}$ から正規分布に従う確率的な潜在変数 $\boldsymbol{z}$ を出力するネットワーク ($\pi\left(z|r,v^q\right)$) と $\boldsymbol{r}$，$\boldsymbol{v^q}$，$\boldsymbol{z}$ から $\boldsymbol{x^q}$ を出力するネットワーク ($p\left(x^q|z,r,v^q\right)$) の 2 段階で構成される．

学習においては，潜在変数 $\boldsymbol{z}$ の周辺化を回避するために，別のニューラルネットワークで定義される近似事後分布 $q(\boldsymbol{z}|\boldsymbol{x^q},\boldsymbol{v^q},\boldsymbol{r})$ を用意し，以下の対数尤度の変分下限を目的関数として最大化するように確率的勾配降下法アルゴリズムでパラメータの最適化を行う．

$$\mathbb{E}_{q(z|x^q,r,v^q)}\left[\log p\left(x^q|z,r,v^q\right)\right] - \mathrm{D}_{\mathrm{KL}}\left[q\left(z|x^q,r,v^q\right)||\pi\left(z|r,v^q\right)\right] \quad (1)$$

2.2 メタ学習

メタ学習とは，複数のデータセットが与えられ，それぞれのデータセットごとにドメインやタスクが異なるような状況において，学習対象のドメインやタスクに応じて学習器のバイアスを決定するためのメタ知識を獲得する枠組みを指す [Vilalta 2002]. [Gordon 2018] では，メタ学習を統一的に理解するためのフレームワーク ML-PIP を提案しており，ML-PIP ではメタ学習において仮定する確率モデルを以下のようなグラフィカルモデルで表現する．

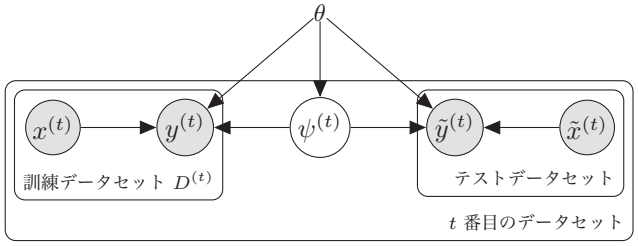


図 1: ML-PIP のグラフィカルモデル

メタ学習で期待されるのは，未知のデータセットに対して，少数の訓練サンプル $D^{(t)}$ からデータセットに固有のパラメータ (もしくは変数) である $\psi^{(t)}$ を推定し，$\psi^{(t)}$ を用いてテストデータ $\tilde{x}^{(t)},\tilde{y}^{(t)}$ に対して正しい予測を行うことである．この $\psi^{(t)}$ の推定を近似事後分布 $q(\psi^{(t)}|D^{(t)};\phi)$ で行い，以下の尤

連絡先: 谷口 尚平，東京大学，〒 113-8656 東京都文京区本郷 7-3-1，taniguchi@weblab.t.u-tokyo.ac.jp

度を目的関数として最大化することで，メタ学習の手法を統一的に定式化することができる．

$$
\begin{aligned}
&p\left(\tilde{y}^{(t)}|\tilde{x}^{(t)}, D^{(t)}; \theta\right) \\
&\quad = \int p\left(\tilde{y}^{(t)}|\tilde{x}^{(t)}, \psi^{(t)}; \theta\right) p\left(\psi^{(t)}|D^{(t)}; \theta\right) \\
&\quad \simeq \int p\left(\tilde{y}^{(t)}|\tilde{x}^{(t)}, \psi^{(t)}; \theta\right) q\left(\psi^{(t)}|D^{(t)}; \phi\right) \qquad (2)
\end{aligned}
$$

3. メタ学習としての GQN の定式化

GQN において対象とするタスクは，メタ学習のフレームワークに当てはめて解釈することが可能である．つまり，モデルは未知のシーン i に関して，少数のコンテキスト $D_i = \{(\boldsymbol{v_i^k}, \boldsymbol{x_i^k})\}_{k=1}^M$ からシーンに固有な変数 $\boldsymbol{r_i}$ を推論し，それを用いてクエリの視点座標から対応する観測画像の予測を行う．すると，GQN において，コンテキスト D_i を入力としてシーン表現 $\boldsymbol{r_i}$ を出力する表現ネットワークは，2.2 節における近似事後分布 $q(\psi^{(t)}|D^{(t)}; \phi)$ のモデルとなっていると解釈することができる．すると，GQN の確率モデルは以下のように表現することができる．

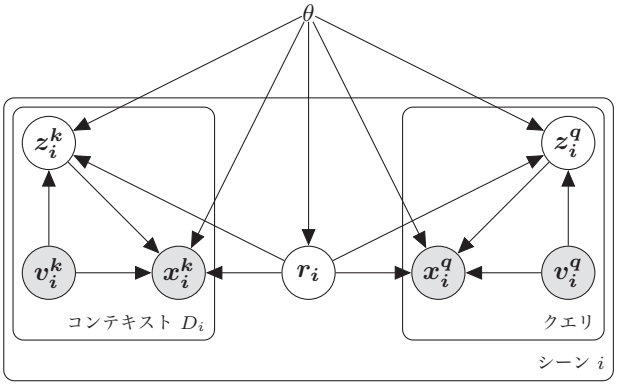


図 2: メタ学習としての GQN のグラフィカルモデル

図 1 と比較するとわかるように，GQN では通常のメタ学習とは異なり，シーン表現 $\boldsymbol{r_i}$ に加えて，個別のデータ $(\boldsymbol{v_i^k}, \boldsymbol{x_i^k})$ に依存する確率的な潜在変数 $\boldsymbol{z_i^k}$ をさらに定義している．それに伴い，式 (2) の目的関数は，GQN においては変数 $\boldsymbol{r_i}$，$\boldsymbol{z_i^q}$ を用いて以下のように変化する．

$$
\begin{aligned}
&\log p(\boldsymbol{x_i^q}|\boldsymbol{v_i^q}, D_i; \theta) \\
&\simeq \log \int p(\boldsymbol{x_i^q}|\boldsymbol{v_i^q}, \boldsymbol{r_i}; \theta) q'(\boldsymbol{r_i}|D_i; \phi') \mathrm{d}\boldsymbol{r_i} \qquad (3) \\
&= \log p(\boldsymbol{x_i^q}|\boldsymbol{v_i^q}, \boldsymbol{r_i}; \theta) \quad (\boldsymbol{r_i} = f(D_i; \phi')) \qquad (4) \\
&= \log \int p(\boldsymbol{x_i^q}|\boldsymbol{v_i^q}, \boldsymbol{z_i^q}, \boldsymbol{r_i}; \theta) \pi(\boldsymbol{z_i^q}|\boldsymbol{v_i^q}, \boldsymbol{r_i}; \theta) \mathrm{d}\boldsymbol{z_i^q} \\
&\geq \mathbb{E}_{\boldsymbol{z_i^q} \sim q(\boldsymbol{z_i^q}|\boldsymbol{x_i^q}, \boldsymbol{v_i^q}, \boldsymbol{r_i}; \phi)} [\log p(\boldsymbol{x_i^q}|\boldsymbol{v_i^q}, \boldsymbol{z_i^q}, \boldsymbol{r_i}; \theta)] - \mathrm{D_{KL}}(q||\pi) \\
& \qquad (5)
\end{aligned}
$$

これは，式 (1) と一致する (ただし，式 (1) では，シーンの表記 i を省略している)．GQN ではシーン表現 $\boldsymbol{r_i}$ を推論する近似分布 $q'(\boldsymbol{r_i}|D_i; \phi')$ を決定論的な表現ネットワークでモデル化しているため，式 (4) において，変数 $\boldsymbol{r_i}$ に関する周辺化が省略されていることに注意されたい．

このように，メタ学習として GQN の確率モデルを解釈すると，以下のような不十分な点が存在することがわかる．

不確実性の考慮が不明瞭

GQN では，観測されない潜在的な変数として，$\boldsymbol{r_i}$ と $\boldsymbol{z_i^k}$ の 2 つを定義しており，$\boldsymbol{r_i}$ は表現ネットワークによって決定論的に推論し，$\boldsymbol{z_i^k}$ は正規分布を仮定して確率的な推論を行なっている．$\boldsymbol{z_i^k}$ において，確率的な推論を行うのは，コンテキストからシーン固有の知識を推論する際に含まれる不確実性を考慮するためであると考えられる (例えば，コンテキストとして 1 つの視点からの観測のみが与えられた場合，物体の影となっていて観測できない部分の情報はそれのみから得ることはできず，不確実である)．しかし，$\boldsymbol{z_i^k}$ は各データ点 $\boldsymbol{v_i^k}, \boldsymbol{x_i^k}$ に依存する変数となっているため，ここで考慮される不確実性はシーンに関する知識自体のものではなく，各データ点でのレンダリングにおける不確実性となっている．一方で，シーン表現 $\boldsymbol{r_i}$ の推論は決定論的に行い，ここでは不確実性は考慮されないため，GQN ではシーン固有の知識そのものについての不確実性は明示的にはモデル化されていない．このような不確実性についての不明瞭なモデル化は，モデルの解釈性を下げるだけでなく，観測不可能な変数を増やすことで，多くの学習パラメータが必要となり，学習にかかるコスト増大の原因になっていると考えられる．

冗長な近似

GQN では，式 (3) における $q'(\boldsymbol{r_i}|D_i; \phi')$ による $p(\boldsymbol{r_i}|D_i; \theta)$ の近似に加えて，式 (5) において $q(\boldsymbol{z_i^q}|\boldsymbol{x_i^q}, \boldsymbol{v_i^q}, \boldsymbol{r_i}; \phi)$ による $p(\boldsymbol{z_i^q}|\boldsymbol{x_i^q}, \boldsymbol{v_i^q}, \boldsymbol{r_i}; \theta)$ の近似が発生しており，学習時には 3 つのパラメータ θ，ϕ，ϕ' を同時に最適化することが必要となっている．GQN の学習の不安定性はこのような冗長な近似による複雑な最適化が主な原因となっていると考えられる．

4. 提案手法

前章の議論を踏まえて，GQN の問題点を改善する手法の提案を行う．提案手法では，GQN におけるシーン表現 $\boldsymbol{r_i}$ と潜在変数 $\boldsymbol{z_i^k}$ を正規分布に従う 1 つの確率的な潜在変数 $\boldsymbol{z_i}$ に統合し，冗長な近似分布の排除と潜在変数の確率的な推論を可能にする．提案手法の確率モデルは，以下のようなグラフィカルモデルで表現される．

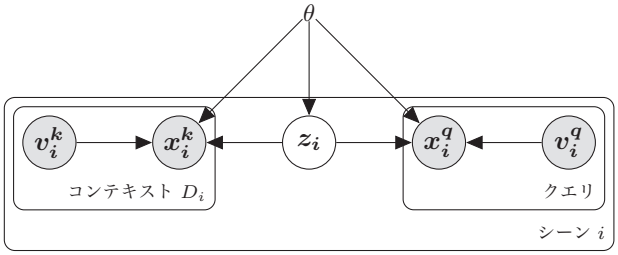


図 3: 提案手法のグラフィカルモデル

これに伴い，最大化する目的関数は以下のような対数尤度の近似下界となる．

$$
\begin{aligned}
\log p(\boldsymbol{x_i^q}|\boldsymbol{v_i^q}, D_i; \theta) &= \log \int p(\boldsymbol{x_i^q}|\boldsymbol{v_i^q}, \boldsymbol{z_i}; \theta) p(\boldsymbol{z_i}|D_i; \theta) \mathrm{d}\boldsymbol{z_i} \\
&\simeq \log \int p(\boldsymbol{x_i^q}|\boldsymbol{v_i^q}, \boldsymbol{z_i}; \theta) q(\boldsymbol{z_i}|D_i; \phi) \mathrm{d}\boldsymbol{z_i} \\
&\geq \mathbb{E}_{\boldsymbol{z_i} \sim q(\boldsymbol{z_i}|D_i; \phi)} [\log p(\boldsymbol{x_i^q}|\boldsymbol{v_i^q}, \boldsymbol{z_i}; \theta)] \quad (6)
\end{aligned}
$$

ただし，式 (6) の期待値計算は，分布 $q(\boldsymbol{z_i}|D_i;\phi)$ からサンプルした $\boldsymbol{z_i}$ を用いた生成画像 $\boldsymbol{x_i^q}$ の尤度の平均でモンテカルロ近似する．

5. 評価実験

提案手法の有効性を検証するため，評価実験によって Generative Query Network と提案手法の比較を行う．

5.1 データセット

実験では，DeepMind 社がインターネット上で公開している Shepard Metzler データセットを用いる [GQN Dataset]. Shepard Metzler データセットでは 7 つのパーツで構成される物体が 3 次元空間上に存在するようなシーンが 200 万用意され，シーンごとに物体のパーツの構成や色が異なる．データセットはそれぞれのシーンで様々な視点から物体を観測した 15 枚の 64 × 64 ピクセルの画像で構成されている．データセットの概要は図 4 を参照．実験では，このデータセットを 9 : 1 の割合で訓練用と検証用に分けて使用する．訓練時には，まず 200 万のシーンの中から 1 つをランダムにサンプリングする．そして，そのシーン i の中からコンテキストとして用いる画像の枚数を 1 ∼ 15 の中からランダムに選び，その枚数 (M) 分の画像をデータセットからランダムに抽出して，$D_i = \left\{\left(\boldsymbol{v_i^k}, \boldsymbol{x_i^k}\right)\right\}_{k=1}^{M}$ とする．さらに，残りの画像の中から予測の対象とするものを 1 つランダムに選び，クエリ $(\boldsymbol{v_i^q}, \boldsymbol{x_i^q})$ として用いる．この操作を毎ステップ行い，そのデータを用いてミニバッチ学習を行う．

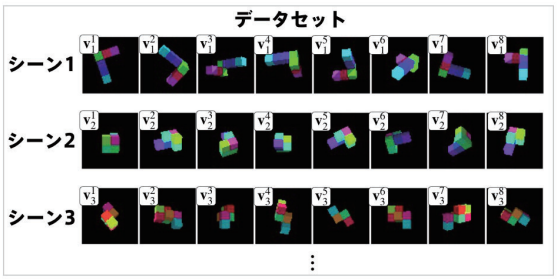


図 4: データセットの概要

5.2 評価指標

今回は，両手法の生成画像の定性的な評価に加えて，検証用データセットからコンテテキストが 3 つ与えられた場合におけるクエリの予測画像の精度を定量評価指標として用いる．ここでは，予測精度として，平均をモデルの予測画像のピクセル値，分散を 1 とした正規分布に対する正解画像のピクセル値の負の対数尤度を用いる．これは，ピクセル値の平均二乗誤差と等価である．

また，これに加えて，ハイパーパラメータに対する頑健性を評価するために，潜在変数の次元数 (チャンネル数) を 3 段階 (3, 32, 128) に変化させた場合の学習過程における予測誤差の推移を比較する実験も行う．

5.3 結果

5.3.1 定性評価

図 5 は，提案手法による画像生成結果を示している．最上段が予測対象の正解画像で，中段・下段が各学習ステップ数における提案手法の生成画像である．学習が進むにつれてより鮮明な画像生成ができていることがわかり，253,400 ステップ後の生成画像は，正解画像と見比べても遜色のない画像が生成できていることが見て取れる．

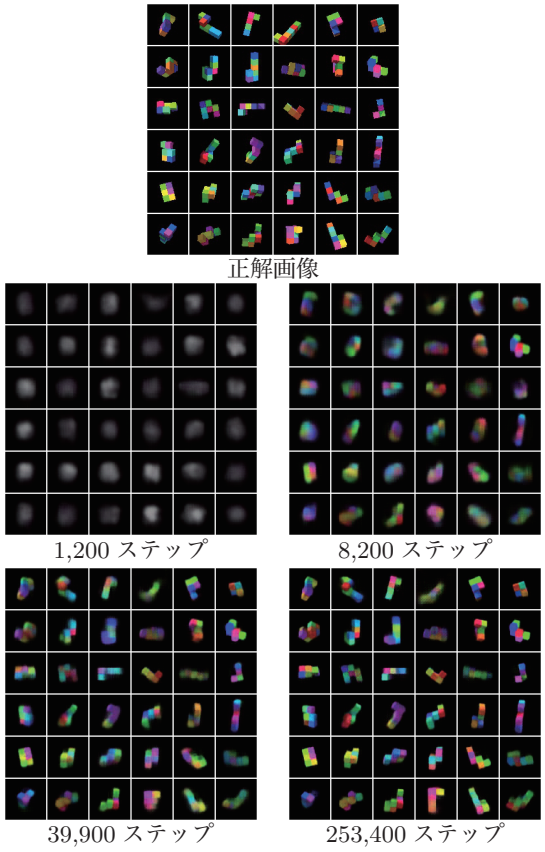


図 5: 提案手法による検証用データに対する画像生成結果

5.3.2 定量評価 (精度・パラメータ数)

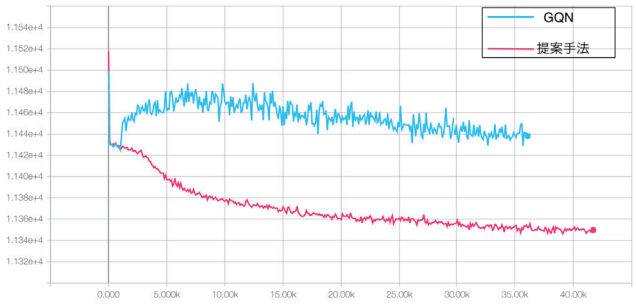


図 6: 検証用データに対する負の対数尤度の推移比較
横軸はステップ数，縦軸は予測誤差 (負の対数尤度) を表す．

図 6 は，提案手法と GQN の検証用データに対する予測誤差 (負の対数尤度) の推移を示している．青線が GQN，赤線が提案手法の値の推移を表している．図からも明らかなように，GQN は目的関数に対数尤度に複数の近似を行なった変分下限を用いて，生成分布 $p(\boldsymbol{x_i^q}|\boldsymbol{v_i^q}, \boldsymbol{z_i^q}, \boldsymbol{r_i}; \theta)$ と 2 つの近似分布 $q(\boldsymbol{z_i^q}|\boldsymbol{x_i^q}, \boldsymbol{v_i^q}, \boldsymbol{r_i}; \phi)$, $q'(\boldsymbol{r_i}|D_i; \phi')$ の 3 つパラメータ θ, ϕ, ϕ' を同時に最適化しているために，予測誤差の推移が学習過程において不安定になってしまっている．一方で，提案手法では必要

最低限な推論分布 $q(\boldsymbol{z}_i|D_i;\phi)$ の近似のみを行なっているために，安定して予測誤差が減少していることがわかる．

表 1 では，GQN と提案手法についての定量的な評価指標の値を比較している．負の対数尤度の項は両手法を 35,000 ステップ学習させたときの検証用データに対する値を表している．負の対数尤度は小さいほど予測誤差が小さいことを表すため，この指標でも提案手法は GQN よりも良い結果を残していることがわかる．

また，パラメータ数の項は，両手法の学習において最適化の対象となるニューラルネットワークのパラメータの総数を表している．提案手法のパラメータ数は GQN の 40%未満となっており，負の対数尤度の項と合わせて考えると，少ない計算リソースで GQN を上回る精度を実現できていることがわかる．これは，GQN の潜在変数 $\boldsymbol{z}$ の近似分布 $q(\boldsymbol{z}_i^{\boldsymbol{q}}|\boldsymbol{x}_i^{\boldsymbol{q}},\boldsymbol{v}_i^{\boldsymbol{q}},\boldsymbol{r}_i;\phi)$ をモデル化するニューラルネットワークなどがなくなり，モデルの冗長性が排除されたことによる効果である．パラメータ数を減らすことの利点は，最適化が容易になる，計算機リソースが限られるような場合にもモデルの学習を行うことができる，などが挙げられる．特に GQN のような深層生成モデルの場合には，一般に大きなモデルアーキテクチャを使用することが多く，必然的にパラメータ数が増大しやすい傾向にあるため，少ないパラメータで良い精度が得られることは，利点であると言える．多くの場合，パラメータ数を削減することは，モデルの表現力を下げることに相当するため，精度とのトレードオフになるが，提案手法では，パラメータ数を削減した上で，GQN を上回る精度を達成しているため，この結果は提案手法の有効性を裏付けていると言える．

表 1: 手法ごとの定量評価指標 (パラメータ数，尤度)

手法	パラメータ数	負の対数尤度
GQN	$49,469,343$	1.1439×10^4
提案手法	$\mathbf{18,713,091}$	$\mathbf{1.1353 \times 10^4}$

5.3.3 ハイパーパラメータへの頑健性

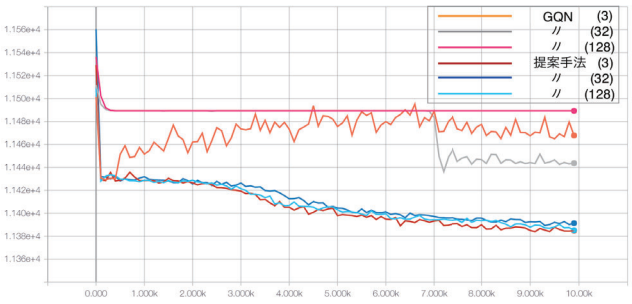


図 7: 潜在変数のチャンネル数を変化させた場合の検証用データに対する負の対数尤度の推移比較
横軸はステップ数，縦軸は予測誤差 (負の対数尤度) を表す．凡例の括弧内の数字は潜在変数のチャンネル数を示している．

最後に，ハイパーパラメータへの頑健性の検証実験の結果が図 7 である．GQN では，潜在変数のチャンネル数によって結果が大きく変化しており，特にチャンネル数が 128 の場合には，学習の初期段階で予測誤差の改善が止まり，学習に失敗していることがわかる．これは，GQN では，潜在変数 $\boldsymbol{z}_i^{\boldsymbol{q}}$ のサンプリングを近似分布 $q(\boldsymbol{z}_i^{\boldsymbol{q}}|\boldsymbol{x}_i^{\boldsymbol{q}},\boldsymbol{v}_i^{\boldsymbol{q}},\boldsymbol{r}_i;\phi)$ から行なっており，パラメータの更新に用いる式 (5) の目的関数では，その近似分布を $p(\boldsymbol{x}_i^{\boldsymbol{q}}|\boldsymbol{v}_i^{\boldsymbol{q}},\boldsymbol{z}_i^{\boldsymbol{q}},\boldsymbol{r}_i;\theta)$ に対して近づけるカルバックライバー距離の項が存在するため，$\boldsymbol{z}_i^{\boldsymbol{q}}$ の次元数 (チャンネル数) が大きくなった場合に，この項を過剰に最小化する局所解に陥り，学習がうまく進まなくなってしまうことが原因として考えられる．一方で，提案手法の目的関数には，潜在変数 $\boldsymbol{z}_i$ の確率分布間の距離を測る項が存在しないため，潜在変数の次元数の変化に対して頑健であり，実際にどのチャンネル数の場合にもうまく学習が進んでいることがわかる．

6. 考察

評価実験を通して，提案手法が GQN と比較して，予測精度，学習効率，ハイパーパラメータに対する頑健性において，優れた性能を発揮することが示された．これは，GQN の課題であった学習コストの高さや学習の不安定性を大きく改善していることを表している．

本研究では，シミュレータ環境のみで実験を行なったが，今後はこれを実環境のデータセットを用いて検証していくことが必要である．また，本手法の 3 次元構造の把握能力を活用して，実ロボットによる複雑な物体の把持タスクの強化学習などに応用することも，今後の研究課題として検討できる．

7. 結論

本研究では，Generative Query Network をメタ学習の観点から検証し，その確率モデルを定式化することで，課題である学習コストの高さや学習の不安定性の原因を解明し，それらを改善する手法の提案を行なった．評価実験では，Shepard Metzler データセットを用いて，GQN と提案手法の予測精度，パラメータの総数，ハイパーパラメータへの頑健性を定量的に比較し，提案手法の有効性を示した．今後は，本手法を実環境のデータセットに対して適用する，実ロボットの強化学習に応用するなどの発展研究が期待される．

8. 謝辞

本研究は株式会社ドワンゴより提供の GPU サーバー「紅莉栖」を使用して行われました．

参考文献

[Eslami 18] SM Ali Eslami, Danilo Jimenez Rezende, Frederic Besse, Fabio Viola, Ari S Morcos, Marta Garnelo, Avraham Ruderman, Andrei A Rusu, Ivo Danihelka, Karol Gregor, et al. Neural scene representation and rendering. Science, Vol. 360, No. 6394, pp. 1204-1210, 2018.

[Vilalta 2002] Ricardo Vilalta and Youssef Drissi. A perspective view and survey of meta-learning. Artificial Intelligence Review, Vol. 18, No. 2, pp. 77-95, 2002.

[Gordon 2018] Jonathan Gordon, John Bronskill, Matthias Bauer, Sebastian Nowozin, and Richard E Turner. Meta-learning probabilistic inference for prediction. arXiv preprint arXiv:1805.09921, 2018.

[GQN Dataset] `https://github.com/deepmind/gqn-datasets`

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

Stiefel空間上の変分オートエンコーダ

Variational Auto-Encoder On Stiefel Space

三條 嵩明 *1 Takaaki Sanjoh　小宮山 純平 *2 Junpei Komiyama　豊田 正史 *2 Masashi Toyoda　喜連川 優 *2*3 Masaru Kitsuregawa

*1東京大学 大学院情報理工学系研究科
Graduate School of Information Science and Technology, The University of Tokyo

*2東京大学 生産技術研究所
Institute of Industrial Science, The University of Tokyo

*3国立情報学研究所
National Institute of Informatics

This paper presents a reformulation of Variational Auto-Encoder (VAE) framework on a non-Euclidean manifold, the Stiefel space $\mathcal{V}_{m,k}$. By assuming the latent space to be Stiefel manifold, we can use its intrinsic orthonormality to impose structure on the learned latent space representations. We derive an objective function and gradient descendant method for learning VAE using a probabilistic distribution on the Stiefel space.

1 はじめに

変分オートエンコーダ (Variational Auto-Encoder; VAE) は，教師無し生成モデルとして最も広く用いられる手法の一つであり，画像生成など様々な分野に応用されている [Kingma 14, Rezende 14]．VAE は自己符号化器に変分推論の手法を取りこんだモデルであり，何らかの事前分布を仮定して，それに KL divergence の意味で近くなるような正則化を行いながら確率分布を推定する．

この VAE の学習の際には，計算を簡単にするために，データがユークリッド空間 $\mathbb{R}^m$ 上に分布することを仮定し，事前，事後分布としてガウス分布を用いるのが一般的である．しかし，この仮定は $\mathbb{R}^m$ と同相でない標本空間上に分布するデータを学習する際には不適切である．

ユークリッド空間と同相でない標本空間の例として超球面が挙げられる．例えば，タンパク質構造の二面角や風向きといった方向データを扱う上では超球面の標本空間を用いた方が適切であることが古くから知られている [Mardia 75, Fisher 87]．また近年の自然言語処理や画像処理の分野においても，cos 類似度を重視したい等の理由により特徴量ベクトルのノルムによる正規化が行われるような場合は，方向データとして扱われる方が適切である．実際に，いくつかの機械学習タスクについて，ガウス分布の代わりに超球面上の確率分布である von Mises-Fisher 分布を事前分布として用いた VAE の方が安定して学習を行えることが報告されている．[Hasnat 17, Davidson 18, Xu 18].

この超球面を一般化した空間として，Stiefel 空間と呼ばれる空間を考えることができる．Stiefel 空間は空間上の一点が k 個の正規直交基底の組に対応するような空間であり，この空間上の統計に関する研究が近年進められてきた．映像など，それぞれのデータ点が潜在的に正規直交性を持つデータについては，Stiefel 空間上の統計を取り入れることで機械学習手法の性能が向上することが報告されている [Turaga 08].

VAE の学習に Stiefel 空間上の確率分布を用いることで，獲得される潜在表現に正規直交性を課すことができる．そのため，もし取り扱うデータが正規直交性を持つと分かっている場合，Stiefel 空間上の VAE を用いることでその本質的な構造を損なわずに確率的生成モデルを学習できると考えられる．

そこで本稿では，matrix Langevin 分布と呼ばれる，ガウス分布を Stiefel 空間上に制限した，Stiefel 空間上の代表的な確率分布を利用することで，Stiefel 空間を埋め込み空間として持つような VAE の学習手法を構成し，正規直交性を持つようなデータを扱うことを可能とする確率的生成モデルを提案する．

連絡先: {sanjoh, jkomiyama, toyoda, kitsure}@tkl.iis.u-tokyo.ac.jp

2 関連研究

VAE の拡張の多くは，取り扱うデータに適した事前分布と事後分布を潜在空間に課すことによって行われる．代表的な手法としては normalizing flow が挙げられる [Rezende 15]．この手法では，事後確率分布に変形を施すことで，学習可能な確率分布の表現力を高め，より複雑な事後分布を扱うことを可能にしている．しかしながら，この手法は依然としてユークリッド空間上のガウス分布を仮定している．

非ユークリッド空間上で確率モデルの学習を行う手法は，明示的に幾何学的構造を仮定するかどうかで大きく二分される．幾何学的構造を明示しない場合については，RSVGD と呼ばれる手法によって一般のリーマン多様体上で変分推論を行う手法が提案されている [Liu 18]．この手法では多数のパーティクルによって事後分布を近似するため，ノンパラメトリックに確率分布の近似を行うことができ，表現力が高い一方で，高次元での計算量は急峻に増大してしまう．

幾何学的構造を明示する場合については，超球面や双曲空間などの空間を標本空間に持つような確率モデルの学習手法が研究されている [Davidson 18, Ovinnikov 18]．それぞれ，規格化されたベクトルとして表現されるようなデータや階層構造を持つデータに対して，リンク予測などのタスクで低次元でも良い性能が達成されることが報告されている．

Stiefel 空間と呼ばれる，空間の一点が k 個の正規直交基底の順序付き集合に対応する空間上で機械学習手法を考えることで，正規直交性を持つデータに対しては良い性能が得られることが知られている．例えば，[Turaga 08] では状態空間モデルの観測方程式中の行列に正規直交性を課し，Stiefel 空間上の確率分布を用いて行動認識タスクを解くことで，低次元でも良い性能を達成できることを示している．

以上の研究ではいくつかのタスクについて，VAE に対する

非ユークリッド空間上の確率分布を考慮することの有効性と，Stiefel 空間上の機械学習の有効性とが示されてはいるものの，VAE に Stiefel 空間上の統計を取り入れた研究は知りうる限り存在しない．

3 変分オートエンコーダ

VAE では，生成モデルとして潜在状態からデータが生成されているようなモデルを考える．潜在状態を Z として，n 個の潜在状態 $\boldsymbol{Z}$ の分布を $P(\boldsymbol{Z})$ とする．また，n 個の潜在状態 $\boldsymbol{Z}$ それぞれから n 個の観測データ $\boldsymbol{x}$ が生成される確率を $p_\phi(\boldsymbol{x}|\boldsymbol{Z})$ として条件付確率で表す．VAE ではこの条件付確率は $\boldsymbol{Z}$ を入力とし，$\boldsymbol{x}$ を出力とする，パラメータ ϕ を持つニューラルネットとしてあらわされる．目的関数はデータ $\boldsymbol{x}$ が生成される対数尤度 (evidence 関数) $\log \int p_\phi(\boldsymbol{x}|\boldsymbol{Z})p(\boldsymbol{Z})d\boldsymbol{Z}$ であり，この関数を最大化するようにニューラルネットのパラメータ ϕ を学習する．しかし，$\boldsymbol{Z}$ について積分をして直接この関数を計算することは不可能であることが多く，代わりに以下のような evidence 関数の下限 (Evidence Lower BOund; ELBO) の最大化を行うことで，目的関数の最大化を行う．

$$\begin{aligned}&\log \int p_\phi(\boldsymbol{x}|\boldsymbol{Z})p(\boldsymbol{Z})d\boldsymbol{Z}\\&\geq \mathbb{E}_{q(\boldsymbol{Z})}[\log p_\phi(\boldsymbol{x}|\boldsymbol{Z})] - D_{KL}(q(\boldsymbol{Z})||p(\boldsymbol{Z})).\end{aligned} \tag{1}$$

ここで，$q(Z)$ は潜在状態 Z の事後分布 $p_\phi(Z|x)$ の近似事後分布であり，実際に $q(Z) = p_\phi(Z|x)$ となるときに上記の不等式の等号が成立し，evidence 関数が最大化される．しかし，通常は正確に $q(Z) = p_\phi(Z|x)$ を求めることはせず，現実的な計算量で最適化できるように $q(Z)$ の関数クラスを制限し，$q_\psi(Z|x;\theta)$ というようにパラメータ ψ を持つニューラルネットで $q(Z)$ のパラメタ θ を出力することによって近似的に $q(Z)$ の推論をできるようにモデルを組み，そのようなアーキテクチャの下で ELBO の最大化を行う．結局，最終的な目的関数は以下のようになる．

$$\mathcal{L}(\phi,\psi) = \underbrace{\mathbb{E}_{q_\psi(\boldsymbol{Z}|\boldsymbol{x};\theta)}[\log p_\phi(\boldsymbol{x}|\boldsymbol{Z})]}_{\text{reconstruction error}} - \underbrace{D_{KL}(q_\psi(\boldsymbol{Z}|\boldsymbol{x};\theta)||p(\boldsymbol{Z}))}_{\text{KL divergence}}. \tag{2}$$

この目的関数を最大化するようにエンコーダネットワークのパラメタ ψ とデコーダネットワークのパラメタ ϕ の最適化を行う．この目的関数は，推定事後分布 $q_\psi(Z|x;\theta)$ が事前分布 $p(Z)$ から離れ過ぎないように KL divergence によって正則化を行いながら，データ x を生成する尤度を reconstruction error の項によって最大化しようとしている式として理解できる．この目的関数によって VAE の学習を行い，生成モデル $p_\phi(x|Z)p(Z)$ を得ることができる．事前分布 $p(Z)$ や近似事後分布 $q_\psi(Z|x;\theta)$ の関数クラスには正規分布が広く用いられているが，この事前分布分布をデータに適した分布にすることにより，VAE の性能が向上することが報告されている．この事前分布と近似事後分布に Stiefel 空間上の確率分布を適用することを試みる．

4 Stiefel 空間と Stiefel 空間上の確率分布

k 個の m 次元正規直交基底の順序付き集合を k-frame (枠) といい，空間の一点が k-frame 一つに対応するような空間を Stiefel 空間という．この節ではまず Stiefel 空間について説明をした後，Stiefel 空間上で定義される一様分布と，代表的な非一様分布である matrix Langevin distribution について説明する．

4.1 Stiefel 空間

Stiefel 空間 $\mathcal{V}_{m,k}$ は k 個の m 次元正規直交ベクトルの順序付き集合全体からなる空間であり，以下のように定義される．

$$\mathcal{V}_{m,k} = \left\{X \in \mathbb{R}^{m\times k} : X^T X = \boldsymbol{I}_k\right\}. \tag{3}$$

ただし，$\mathbb{R}^{m\times k}$ は $m\times k$ 実行列全体からなる空間であり，$\boldsymbol{I}_k$ は $k\times k$ の単位行列とする．$\mathcal{V}_{m,k}$ はコンパクトな $mk-k(k+1)/2$ 次元リーマン多様体であり，mk 次元ユークリッド空間 $\mathbb{R}^{mk}$ の部分多様体である．$k=1$ の場合に $\mathcal{V}_{m,k}$ は $(m-1)$ 超球面 $\mathbb{S}^{m-1}$ となり，$k=m$ の場合に $O(m)$ となる．ただし，$O(m)$ は m 次元直交群であり，$m\times m$ 実直交行列全体からなり，積が行列積として定義されるような群である．つまり，Stiefel 空間 $\mathcal{V}_{m,k}$ は m 次元正規直交縦ベクトルを k 個順に横に並べたものの全体からなる空間として考えることができて，更に特殊な場合として，$k=1$ の時に正規化された m 次元ベクトル全体からなる空間，$k=m$ の時に m 次元直交行列全体からなる空間として考えることができるような空間である．

4.2 Stiefel 空間上の一様分布

$X \in \mathcal{V}_{m,k}$ として，$\mathcal{V}_{m,k}$ 上の微分形式 $(X^T dX) = \bigwedge_{i=1}^{k}\bigwedge_{j=i+1}^{m} x_j^T dx_i$ は不変測度 (Haar 測度) を定める．これにより，$\mathcal{V}_{m,k}$ の表面積は以下のように計算できる．

$$Vol(\mathcal{V}_{m,k}) := \int_{\mathcal{V}_{m,k}} (X^T dX) = \frac{2^k(\sqrt{\pi})^{mk}}{\Gamma_k(m/2)}. \tag{4}$$

ただし，$\Gamma_m(a)$ は multivariate gamma function と呼ばれるものであり，以下のように定義される．

$$\begin{aligned}\Gamma_m(a) &:= \int_{S>0} \exp\left(\mathrm{tr}\left(-S\right)\right)|S|^{a-(m+1)/2}(dS)\\&= \pi^{m(m-1)/4}\prod_{i=1}^{m}\Gamma\left[a-\frac{1}{2}(i-1)\right],\\&\quad with \qquad a > \frac{1}{2}(m-1).\end{aligned}$$

式 (4) より Stiefel 空間 $\mathcal{V}_{m,k}$ 上で一様な基準測度を以下のように定めることができる．

$$[dX] := \frac{(X^T dX)}{Vol(\mathcal{V}_{m,k})}. \tag{5}$$

4.3 Matrix Langevin 分布

Matrix Langevin ($\mathcal{ML}$) distribution は $\mathcal{V}_{m,k}$ 上の確率密分布として広く用いられており，[Downs 72] によって導入され，その後，[Khatri 77, Jupp 79] による初期研究により，古典的状況下でのパラメタの最尤推定量について調べられた．また，漸近性などその他の性質について [Chikuse 03] に良くまとめられている．$\mathcal{ML}$ distribution は $F \in \mathbb{R}^{m\times k}$ によってパラメタライズされ，基準測度 $[dX]$ に対する確率密度関数 $f_{\mathcal{ML}}(X;F)$ は以下によって与えられる．

$$f_{\mathcal{ML}}(X;F) = \frac{\exp\left(\mathrm{tr}\left(F^T X\right)\right)}{{}_0F_1\left(;\frac{1}{2}m;\frac{1}{4}F^T F\right)}. \tag{6}$$

ただし，${}_0F_1\left(;\frac{1}{2}m;\frac{1}{4}F^T F\right)$ は行列引数超幾何関数である [James 64, Khatri 77].

この分布は多変量正規分布を $X^TX = \boldsymbol{I}_k$ によって条件付けた条件付き確率分布として得られる．また，モーメント $\mathbb{E}[X]$ を定めた時に最大エントロピーを達成する分布として得ることもできる．$F = 0$ の時に一様分布と一致し，$k = 1$ の時に von Mises-Fisher 分布と一致する．

X の期待値はスコア関数の期待値が 0 になることを利用して以下のように求めることができる．

$$\begin{aligned}
&\mathbb{E}\left[\frac{\partial}{\partial F}\log\frac{\exp\left(\mathrm{tr}\left(F^TX\right)\right)}{{}_0F_1\left(;\frac{1}{2}m;\frac{1}{4}F^TF\right)}\right]\\
&=\mathbb{E}\left[\frac{\partial}{\partial F}\mathrm{tr}\left(F^TX\right)-\frac{\partial}{\partial F}\log{}_0F_1\left(;\frac{1}{2}m;\frac{1}{4}F^TF\right)\right]\\
&=\mathbb{E}\left[\frac{\partial}{\partial F}\mathrm{tr}\left(FX^T\right)-\frac{\partial}{\partial F}\log{}_0F_1\left(;\frac{1}{2}m;\frac{1}{4}F^TF\right)\right]\\
&=\mathbb{E}\left[X\right]-\frac{\partial}{\partial F}\log{}_0F_1\left(;\frac{1}{2}m;\frac{1}{4}F^TF\right)\\
&=0,\\
&\therefore\mathbb{E}[X]=\frac{\partial}{\partial F}\log{}_0F_1\left(;\frac{1}{2}m;\frac{1}{4}F^TF\right).
\end{aligned}\tag{7}$$

5 $\mathcal{ML}$ 分布を用いた VAE の学習

4 章の議論により，Stiefel 空間上の VAE の学習手法を構成できる．まず 5.1 節では目的関数の具体的な表式を求める．次に 5.2 節では目的関数の最適化に必要となる勾配計算について議論する．最後に 5.3 節では勾配計算でネックとなる行列引数超幾何関数 ${}_0F_1$ の偏微分の数値計算について説明する．

5.1 目的関数の導出

VAE の目的関数式 (2) について，事前分布 $p(Z)$ に $\mathcal{V}_{m,k}$ 上の無情報分布として一様分布 U を用い，近似事後分布 $q_\psi(Z|x;\theta)$ に $\mathcal{ML}$ 分布を用いることで，Stiefel 空間上の VAE を学習できることが期待される．

目的関数式 (2) の第一項の reconstruction error については以下のように書くことができる．

$$\mathbb{E}_{q_\psi(Z|x;\theta)}[\log p_\phi(x|Z)]=\mathbb{E}_{f_{\mathcal{ML}}\left(Z;F_\psi(x)\right)}[\log p_\phi(x|Z)].\tag{8}$$

ただし，$F_\psi(x)$ はパラメータ ψ を持つエンコーダニューラルネットに対し，あるデータ x を入力した時の出力とする．また，$p_\phi(x|Z)$ はパラメータ ϕ を持つデコーダニューラルネットに対し，$\mathcal{ML}$ 分布からサンプリングした潜在変数 Z を入力して，エンコーダへの入力 x がどの程度復元されそうかを表す尤度である．

次に，目的関数式 (2) 中の第二項の KL divergence を求める．パラメータ F，G を持つ 2 つの $\mathcal{ML}$ 分布 f，g 間の KL divergence は以下の形となる．

$$\begin{aligned}
&D_{KL}(f_{\mathcal{ML}}(Z;F)||g_{\mathcal{ML}}(Z;G))\\
&=\mathrm{tr}\left((F-G)^T\frac{\partial}{\partial F}\log{}_0F_1\left(;\frac{1}{2}m;\frac{1}{4}F^TF\right)\right)\\
&\quad+\log\frac{{}_0F_1\left(;\frac{1}{2}m;\frac{1}{4}G^TG\right)}{{}_0F_1\left(;\frac{1}{2}m;\frac{1}{4}F^TF\right)}.
\end{aligned}$$

これは以下のように導出できる．

$$\begin{aligned}
&D_{KL}(f_{\mathcal{ML}}(Z;F)||g_{\mathcal{ML}}(Z;G))\\
&=\int_{\mathcal{V}_{m,k}}f(Z;F)\log\frac{f(Z;F)}{g(Z;G)}[dZ]\\
&=\int_{\mathcal{V}_{m,k}}f(Z;F)\left(\mathrm{tr}\left(F^TZ\right)-\mathrm{tr}\left(G^TZ\right)\right)[dZ]\\
&\quad+\int_{\mathcal{V}_{m,k}}f(Z;F)\log\frac{{}_0F_1\left(;\frac{1}{2}m;\frac{1}{4}G^TG\right)}{{}_0F_1\left(;\frac{1}{2}m;\frac{1}{4}F^TF\right)}[dZ]\\
&=\mathbb{E}_{f(Z;F)}\left[\mathrm{tr}\left((F-G)^TZ\right)\right]+\log\frac{{}_0F_1\left(;\frac{1}{2}m;\frac{1}{4}G^TG\right)}{{}_0F_1\left(;\frac{1}{2}m;\frac{1}{4}F^TF\right)}\\
&=\mathrm{tr}\left((F-G)^T\mathbb{E}_{f(Z;F)}[Z]\right)+\log\frac{{}_0F_1\left(;\frac{1}{2}m;\frac{1}{4}G^TG\right)}{{}_0F_1\left(;\frac{1}{2}m;\frac{1}{4}F^TF\right)}\\
&=\mathrm{tr}\left((F-G)^T\frac{\partial}{\partial F}\log{}_0F_1\left(;\frac{1}{2}m;\frac{1}{4}F^TF\right)\right)\\
&\quad+\log\frac{{}_0F_1\left(;\frac{1}{2}m;\frac{1}{4}G^TG\right)}{{}_0F_1\left(;\frac{1}{2}m;\frac{1}{4}F^TF\right)}.
\end{aligned}$$

ここで，$G = 0$ とすれば分布 g が一様分布となるため，$\mathcal{ML}$ 分布と一様分布 U の間の KL divergence を求めることができる．これにより，式 (2) の第二項の KL divergence の項は以下の形となる．

$$\begin{aligned}
&D_{KL}(f_{\mathcal{ML}}(Z;F)||U)\\
&=\mathrm{tr}\left(F^T\frac{\partial}{\partial F}\log{}_0F_1\left(;\frac{1}{2}m;\frac{1}{4}F^TF\right)\right)-\log{}_0F_1\left(;\frac{1}{2}m;\frac{1}{4}F^TF\right).
\end{aligned}\tag{9}$$

5.2 勾配降下法による学習

目的関数の最適化には勾配降下法を用いる．そのため，式 (8)，式 (9) の勾配を求める必要がある．ここで，$\mathcal{ML}$ 分布からのサンプリング手法として，提案分布を Stiefel 空間上の一様分布 U とした棄却サンプリング法を用いるとする．この時，式 (8) の勾配推定には VAE で広く用いられる期待値の勾配推定法である reparameterization trick[Kingma 14] を用いることができない．そのため，代替として score function estimator を用いて期待値の勾配推定を行う．score function estimator による reconstruction error の勾配推定は以下のようになる．

$$\begin{aligned}
&\frac{\partial}{\partial F}\mathbb{E}_{f_{\mathcal{ML}}\left(Z;F_\psi(x)\right)}[\log p_\phi(x|Z)]\\
&=\mathbb{E}_{f_{\mathcal{ML}}\left(Z;F_\psi(x)\right)}\left[\log p_\phi(x|Z)\cdot\frac{\partial}{\partial F}\log f_{\mathcal{ML}}\left(Z;F_\psi(x)\right)\right].
\end{aligned}\tag{10}$$

式 (9) の勾配の計算については，$\frac{\partial}{\partial F}\log{}_0F_1$ や $\frac{\partial^2}{\partial F^2}\log{}_0F_1$ の項の計算を除けば通常の自動微分によって計算することができる．

5.3 ${}_0F_1$ の偏微分計算

式 (9) の勾配や式 (10) を求める際に，$\frac{\partial}{\partial F}\log{}_0F_1$ や $\frac{\partial^2}{\partial F^2}\log{}_0F_1$ の項の計算が問題となる．この項に含まれる ${}_0F_1$ は特殊関数となっており，偏微分の式を陽に求めることができない．そのため数値微分によって計算する．

[Khatri 77] によれば，${}_0F_1$ は以下のように単純化できる．

$${}_0F_1\left(;\frac{1}{2}m;\frac{1}{4}F^TF\right)={}_0F_1\left(;\frac{1}{2}m;\frac{1}{4}\Lambda^2\right).$$

ただし，Λ は $F = M\Lambda V^T$ として F を特異値分解した際の特異値対角行列 Λ である．

ここで，$D := \Lambda^2/4$，$D = \mathrm{diag}(d_1, \cdots, d_k)$ と書くとする．${}_0F_1\left(;\frac{1}{2}m; D\right)$ には低次元において効率的な近似的数値計算手法が存在する [Koev 06]．そのため，${}_0F_1\left(;\frac{1}{2}m; D\right)$ の $(d_1, \cdots, d_k)$ による二階までの偏微分は，以下のように刻み幅 h として中央差分による数値微分を用いて求めることができる．

$$\begin{aligned}&\frac{\partial}{\partial d_i}{}_0F_1\left(;\frac{1}{2}m; D\right)\\&= \frac{1}{2h}\left({}_0F_1\left(;\frac{1}{2}m; \mathrm{diag}(d_1, \cdots, d_i + h, \cdots, d_k)\right)\right.\\&\qquad\left.-{}_0F_1\left(;\frac{1}{2}m; \mathrm{diag}(d_1, \cdots, d_i - h, \cdots, d_k)\right)\right). \quad (11)\end{aligned}$$

$$\begin{aligned}&\frac{\partial^2}{\partial d_i \partial d_j}{}_0F_1\left(;\frac{1}{2}m; D\right)\\&= \frac{1}{4h^2}\left({}_0F_1\left(;\frac{1}{2}m; \mathrm{diag}(d_1, \cdots, d_i + h, \cdots, d_j + h, \cdots, d_k)\right)\right.\\&\qquad- {}_0F_1\left(;\frac{1}{2}m; \mathrm{diag}(d_1, \cdots, d_i + h, \cdots, d_j - h, \cdots, d_k)\right)\\&\qquad- {}_0F_1\left(;\frac{1}{2}m; \mathrm{diag}(d_1, \cdots, d_i - h, \cdots, d_j + h, \cdots, d_k)\right)\\&\qquad\left.+{}_0F_1\left(;\frac{1}{2}m; \mathrm{diag}(d_1, \cdots, d_i - h, \cdots, d_j - h, \cdots, d_k)\right)\right). \quad (12)\end{aligned}$$

式 (11)，式 (12) の結果と自動微分を組み合わせることにより，最終的に目的関数式 (2) 中の reconstruction error(式 (8)) と KL divergence(式 (9)) の勾配計算を行うことができる．

6 おわりに

本稿では，matrix Langevin 分布を用いて Stiefel 空間を埋め込み空間として持つような VAE の学習手法を提案した．

今後の課題としては，(1) synthetic なデータで Stiefel 空間上に分布するデータについて，その構造をこの手法によって捉えることができるのかについての検証，(2) 実データを用いた検証，が挙げられる．

謝辞

本研究は JSPS 科研費 16H02905, 17K12736 の助成を受けたものです．

参考文献

[Chikuse 03] Chikuse, Y.: *Statistics on Special Manifolds*, Vol. 174, Springer Science & Business Media (2003)

[Davidson 18] Davidson, T. R., Falorsi, L., De Cao, N., Kipf, T., and Tomczak, J. M.: Hyperspherical Variational Auto-Encoders, in *34th Conference on Uncertainty in Artificial Intelligence* (2018)

[Downs 72] Downs, T. D.: Orientation Statistics, *Biometrika*, Vol. 59, No. 3, pp. 665–676 (1972)

[Fisher 87] Fisher, N. I., Lewis, T., and Embleton, B. J. J.: Statistical analysis of spherical data, *Cambridge: University Press, 1987* (1987)

[Hasnat 17] Hasnat, M. A., Bohné, J., Milgram, J., Gentric, S., and Chen, L.: von Mises-Fisher Mixture Model-based Deep learning: Application to Face Verification (2017)

[James 64] James, A. T.: Distributions of Matrix Variates and Latent Roots Derived from Normal Samples, *The Annals of Mathematical Statistics*, Vol. 35, No. 2, pp. 475–501 (1964)

[Jupp 79] Jupp, P. and Mardia, K.: Maximum likelihood estimators for the matrix von Mises-Fisher and Bingham distributions, *The Annals of Statistics*, Vol. 7, No. 3, pp. 599–606 (1979)

[Khatri 77] Khatri, C. G. and Mardia, K. V.: The Von Mises-Fisher Matrix Distribution in Orientation Statistics, *Journal of the Royal Statistical Society. Series B (Methodological)*, Vol. 39, No. 1, pp. 95–106 (1977)

[Kingma 14] Kingma, D. P. and Welling, M.: Auto-Encoding Variational Bayes, *Proceedings of the 2nd International Conference on Learning Representations (ICLR)* (2014)

[Koev 06] Koev, P. and Edelman, A.: THE EFFICIENT EVALUATION OF THE HYPERGEOMETRIC FUNCTION OF A MATRIX ARGUMENT, *Mathematics of Computation*, Vol. 75, No. 254, pp. 883–846 (2006)

[Liu 18] Liu, C. and Zhu, J.: Riemannian Stein Variational Gradient Descent for Bayesian Inference, in *AAAI* (2018)

[Mardia 75] Mardia, K. V.: Statistics of Directional Data, Technical Report 3 (1975)

[Ovinnikov 18] Ovinnikov, I.: Poincaré Wasserstein Autoencoder, in *Third workshop on Bayesian Deep Learning (NeurIPS 2018)* (2018)

[Rezende 14] Rezende, D. J., Mohamed, S., and Wierstra, D.: Stochastic Backpropagation and Approximate Inference in Deep Generative Models, in *ICML*, pp. 1278–1286 (2014)

[Rezende 15] Rezende, D. J. and Mohamed, S.: Variational Inference with Normalizing Flows, in *ICML* (2015)

[Turaga 08] Turaga, P., Veeraraghavan, A., and Chellappa, R.: Statistical analysis on Stiefel and Grassmann Manifolds with applications in Computer Vision Pavan Turaga , Ashok Veeraraghavan and Rama Chellappa Center for Automation Research University of Maryland , College Park, *Cvpr* (2008)

[Xu 18] Xu, J. and Durrett, G.: Spherical Latent Spaces for Stable Variational Autoencoders, in *Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing*, pp. 4503–4513 (2018)

The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

分散システムにおける擬似同時化の検討

遅延があっても機械学習を使うために

A Study of Pseudo-Simultaneous Systems

Using Machine Learning with Delay

板谷琴音 *1*2 Kotone Itaya　坂井尚行 *3*4 Naoyuki Sakai　高橋恒一 *1*3*4 Koichi Takahashi　山川宏 *3*4 Hiroshi Yamakawa

*1理研 BDR RIKEN BDR　*2慶應義塾大学大学院 政策・メディア研究科 Graduate School for Media and Governance, Keio University

*3ドワンゴ ドワンゴ人工知能研究所 DWANGO AI Laboratory, Dwango　*4全脳アーキテクチャ・イニシアティブ The Whole Brain Architecture Initiative

深層学習の技術が成熟するに従い，既存の機械学習アルゴリズムを柔軟に組み合わせた複合システムを開発することで，より高度な知的システムを構築することが期待されている．複合システムをリアルタイムかつ分散的に動作させる場合，アルゴリズム間の時間的整合性を考慮する必要があり，それが改変や大規模化の際に弊害となりうる．本研究では，各アルゴリズムの出力をあらかじめ予測して転送することによって複合システム内の遅延を補償する仕組みを検討した．通常の誤差逆伝播法では情報の伝播に遅延を含んだ人工ニューラルネットワークの学習は機能しないが，Followdictive Coding と呼ばれる提案手法を用いて遅延を補償することで学習が収束することを示した．

1. 背景

近年の深層学習 [LeCun 15] の発展に伴い，機械学習を様々な実用システムで利用することが多くなった．一方で，現在の IT システムの大きな流れとして，物理的なセンサやアクチュエータがネットワークにつながる傾向が高まっている．関連して，サイバーフィジカルシステム，組み込みシステムの複雑性の増大，IoT とエッジコンピューティングなどがあるだろう．

多くのこうしたシステムにおいては分散的かつリアルタイムに処理を行う必要がある．具体的な例としては同時通訳の遅延解消，動画と音声の同期，予測的なノイズキャンセリングなどが考えられる．さらにマルチモーダルなタスクに適用する場合，複数のアルゴリズムを組み合わせて動作させる必要も想定される [Karpathy 14, Vinyals 14, Mnih 15]．

しかし，多くの機械学習アルゴリズムにおいては，それ全体が同期して学習し動作させることが前提となっている．このためにリアルタイム分散システムにおいては定常的に生ずる，処理時間や通信時間に起因するレイテンシに対処できない問題がある．例えば強化学習などを実行する際，環境から得られる入力信号の受信や行動の出力に遅延が生じた時にアルゴリズムが意図通りに動作しないことがありうる．遅延を考慮したアルゴリズムを設計することも可能であるとはいえ，システムの変更によって新たに生じた遅延に対して脆弱であるため漸進的なシステム開発が困難となる．特に，分岐や合流を含む計算グラフを分散化した場合，任意のノードが受け取る複数の入力間で生ずる遅延の差異を考慮することは相当に難しくなる．

今回我々は，分散システムにおいて要素間の遅延を内部で補償することよって，見かけ上は遅延が発生しない疑似同時性を持った分散システムを構築する実現可能性についての検討を行った．先行する関連研究としては，End-to-end で学習されるモデル分散化や誤差逆伝播法に代わる学習手法 [Jaderberg 16] が存在すが，それらは特定の計算手続きに限定されている．

連絡先: 山川宏,（株）ドワンゴ，ドワンゴ人工知能研究所

2. 疑似同時化の検討

任意の計算手続き f が時刻 τ でシステムに入力された x_τ を受け取って計算した出力を $f(x_\tau)$ とする．この出力値を入力として受け取り計算を行う g があった時，逐次的に処理される場合，g は $f(x_\tau)$ を受け取り $g(f(x_\tau))$ を即時に出力することができる (図 1-a)．しかし分散システムにおいては g の実行時に $f(x_\tau)$ は計算されていない．任意の計算手続きの実行に必要な時間を一定時間である Δt とした場合 g は f が時刻 $\tau - \Delta t$ の時点で受け取った入力で計算した $f(x_{\tau-\Delta t})$ を受け取ることになり，計算が Δt 遅れたように見える (図 1-b)．更に時刻 τ の時点では $g(f(x_{\tau-\Delta t}))$ が計算されていないため，g の出力を参照する計算手続きは全て $g(f(x_{\tau-2\Delta t}))$ を受け取ることになる．このように単純に n 個の計算手続きが連結された場合，時刻 τ で入力された値に対応する計算結果が出力されるのは時刻 $\tau + n\Delta t$ となる．

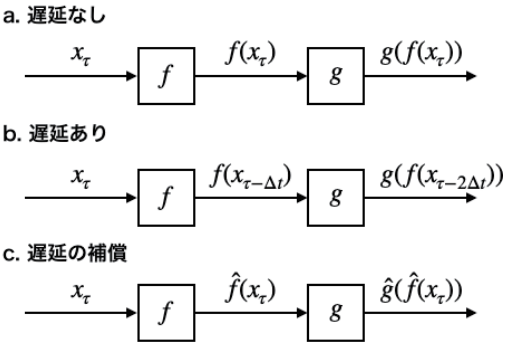


図 1: 時刻 τ における各処理方法における遅延

逐次処理における遅延．遅延がない場合はある時刻で入力された値に対応する出力が瞬時に計算される (a)．遅延がある分散システムでは計算時間 Δt 分の遅延が発生する (b)．入力の時間発展により未来の出力が予測可能な計算手続きの場合，f や g の次時刻の出力値を予測する $\hat{f}$ と $\hat{g}$ の出力を用いることで見かけ上の遅延を補償できる (c)．

本研究においては「遅延を補償すること」を，時刻 τ で入力された値に対応する計算結果を時刻 τ で得ることができる

ことと定義する．無遅延を実現するためには，f や g が時刻 τ の時点でそれぞれ $f(x_\tau)$ や $g(f(x_\tau))$ を出力している必要がある．計算には必ず Δt の時間がかかることを前提としているため，実際の計算によって得られる値を出力することは不可能である．しかし，もしシステムへの入力が規則的に時間発展することが既知な場合，任意の計算手続きの出力結果を予測することは可能である．計算手続き f の次時刻の出力 $f(x_{\tau+\Delta t})$ を，現時刻の入力 x_τ から誤差なく予測できる f^* が存在する場合，その予測器の出力 $f^*(x_\tau) = f(x_{\tau+\Delta t})$ を用いることで，見かけ上は遅延なく計算結果が伝達される（図 1-c）．実際には f^* は未知のため，これを近似する $\hat{f}_\theta$ を以下の規則に従って損失関数 lossfun$(\cdot)$ を最小化するように最適化する必要がある．

$$\theta^* = \underset{\theta}{\mathrm{argmin}}(\mathrm{lossfun}(\hat{f}_\theta(x_\tau), f(x_{\tau+\Delta t}))) \quad (1)$$

$$f^*(x_\tau) = \hat{f}_{\theta^*}(x_\tau) \quad (2)$$

同様の仕組みを g にも導入することによって，任意の数の計算手続きを連結しつつも理論上は遅延のないシステムを構築することができる．本研究ではこのように，随伴予測器が出力した値の伝達によって任意の計算手続きに対応する見かけ上の遅延を補償する手法を Followdictive Coding（FDC）と呼称する．

3. 検討手法の検証

3.1 純粋関数

FDC の基本的な妥当性を検証するため，計算手続きとして計算結果が必ず一意となる純粋関数を用いる二通りの実験を行った．一つ目は最も単純な純粋関数である恒等写像を用い，二つ目は四則演算を加え四つの入力に対して二つの任意の四則演算を適用し，その結果に更に四則演算を適用する複合システムを構築した．いずれの場合も出力の予測を行う随伴予測器には Adam[Kingma 14] によって最適化される Long Short Term Memory（LSTM）[Hochreiter 97] を含む再帰ニューラルネットワークを使用した．一つ目の恒等写像を用いた検証ではサイン波を入力として与え，出力として同位相のサイン波が出力されることを確認した．二つ目の四則演算を用いた検証では異なる周波数のサイン波を入力として与え，遅延なく計算された値と同様の出力が擬似同時分散で計算されることを確認した．

3.2 予測的誤差逆伝播

上記二項では入力に対して出力が常に一意となる純粋関数を計算手続きとして利用したが，我々の想定する複合知的システムやリアルタイムシステムでは学習などにより時間進行と共に計算結果が変化する計算手続きを用いることが想定される．そこで，全結合層のみによって構成される隠れ層を一層持つニューラルネットワークを FDC によって分散的に実行することを試みた．入力層から隠れ層及び隠れ層から出力層への順伝播，そして出力層から隠れ層へ及び隠れ層から入力層への逆伝播をそれぞれ計算手続きとし，前項と同様の随伴予測器をそれぞれの手続きに紐づけた．人工ニューラルネットワークの詳細として，サイン波を一次元ベクトルの入力層として扱い，十次元の中間層に変換し，正負二つのクラスに対応する二次元のため出力層を持つ 2 クラス分類モデルを構築した．各結合パラメータは学習率を 0.1 に固定した確率的勾配降下法を用いて更新した．

情報の転送に遅延があった場合でも，本手法の適用によって学習が収束することを示すため，以下の三つの条件で検証を行った．

a 遅延を含まず・通常の誤差逆伝播法を用いる

b 遅延を含み・通常の誤差逆伝播法を用いる

c 遅延を含み・FDC による予測的誤差逆伝播を用いる

各条件において学習時の予測精度および Sigmoid Cross Entropy 損失値の値を 1000 実行ステップごとにプロットしたグラフを図 2 に示す．遅延がない場合，誤差逆伝播法によって 2000 ステップ程度で予測精度が 1.0 付近で収束する（図 2：赤線）が，層の間の情報の伝播に遅延がある場合，予測精度が 0.75 付近で停滞する（図 2：緑線）．FDC の手法を適用し各層が出力を予測することで見かけ上の遅延を補償した場合，遅延のない状態での誤差逆伝播に比べて収束が遅れるが，6000 から 7000 ステップ程度で予測精度が 1.0 付近で収束した（図 2：青線）．これらの結果から，通常の誤差逆伝播法による学習の際は，遅延がない場合は収束するのに対し遅延がある場合には収束しないこと，そして FDC を用いて遅延を補償した場合は収束速度は遅いが無遅延の誤差逆伝播と同等の性能に収束することが示された．

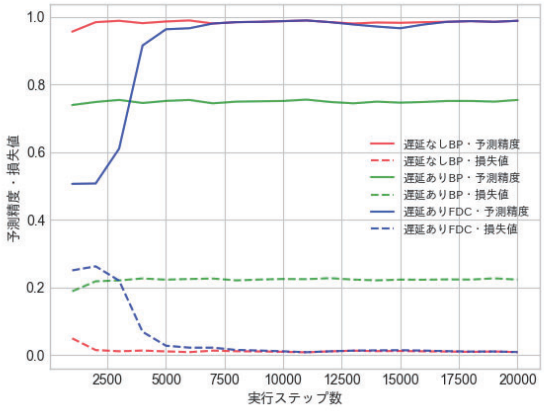


図 2: 誤差逆伝播法を用いた学習の進行

横軸に実行ステップ数，縦軸に損失値（破線）と予測精度（実線）をプロットした．線の色はそれぞれの検証条件に対応しており，赤が遅延を含まない通常の誤差逆伝播法による学習，青が遅延を含んだ通常の誤差逆伝播法による学習，緑が遅延を含んだ予測的誤差逆伝播による学習である．

4. まとめ

本研究では，分散システムにおいて疑似同時性を実現する手法として，予測の伝達によって見かけ上の遅延を補償する Followdictive Coding を提案し，その妥当性を検証した．実験の結果，時間発展をする入力に対して随伴予測樹の仕組みを適用した関数を組み合わせることで見かけ上の遅延を補償できるようになった．さらにクラス分類を獲得する学習のために，内包する計算手続きが時間進行と共に変化する場合であっても，随伴予測器の学習を同時に動作させることでレイテンシを補償しながら分類器としての性能を獲得できることを示した．

本手法を用いれば，リアルタイムで動作する多数の計算手続きからなる大規模分散系においても，実行の遅延のみならず通信の遅延まで補償できる．すると全体としてあたかも同時刻

に実行されているように動作することで，柔軟に機械学習アルゴリズムを組み合わせることができるようになるだろう．より複雑な問題に応用するためには本手法が適用可能な計算手続きの条件を明確にする必要がある．今後取り組む発展的な応用としては，学習を含む制御問題がある．例えば，レイテンシのある分散モジュールで構成された強化学習のアルゴリズムにおいても FDC を導入することで，報酬を最大化する学習が可能となりうるか検証したい．

参考文献

[Hochreiter 97] Hochreiter, S. and Schmidhuber, J.: Long short-term memory, *Neural Comput*, Vol. 9, No. 8, pp. 1735–1780 (1997)

[Jaderberg 16] Jaderberg, M., Czarnecki, W. M., Osindero, S., Vinyals, O., Graves, A., and Kavukcuoglu, K.: Decoupled Neural Interfaces using Synthetic Gradients, *CoRR*, Vol. abs/1608.05343, (2016)

[Karpathy 14] Karpathy, A. and Li, F.: Deep Visual-Semantic Alignments for Generating Image Descriptions, *CoRR*, Vol. abs/1412.2306, (2014)

[Kingma 14] Kingma, D. P. and Ba, J.: Adam: A Method for Stochastic Optimization, *CoRR*, Vol. abs/1412.6980, (2014)

[LeCun 15] LeCun, Y., Bengio, Y., and Hinton, G.: Deep learning, *Nature*, Vol. 521, pp. 436 EP – (2015)

[Mnih 15] Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., Graves, A., Riedmiller, M., Fidjeland, A. K., Ostrovski, G., Petersen, S., Beattie, C., Sadik, A., Antonoglou, I., King, H., Kumaran, D., Wierstra, D., Legg, S., and Hassabis, D.: Human-level control through deep reinforcement learning, *Nature*, Vol. 518, pp. 529 EP – (2015)

[Vinyals 14] Vinyals, O., Toshev, A., Bengio, S., and Erhan, D.: Show and Tell: A Neural Image Caption Generator, *CoRR*, Vol. abs/1411.4555, (2014)